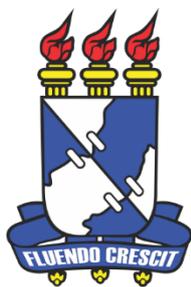




PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

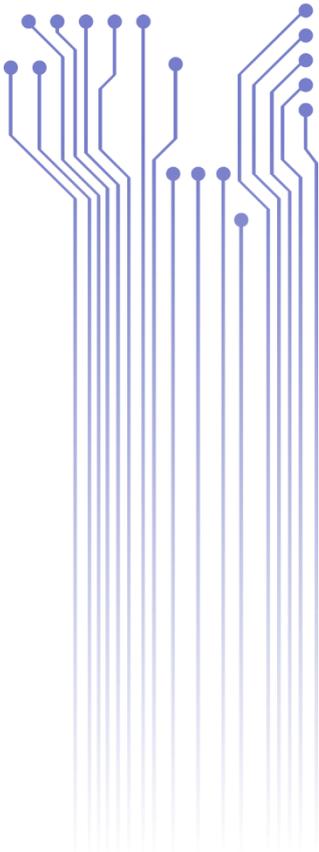
GUSTAVO ARAGÃO RODRIGUES



Universidade Federal de Sergipe



DISSERTAÇÃO DE MESTRADO  
MONITORAMENTO AUTOMATIZADO DE ISOLAMENTOS POR  
IMAGEAMENTO ULTRAVIOLETA EMPREGANDO APRENDIZADO  
PROFUNDO



São Cristóvão  
2023

GUSTAVO ARAGÃO RODRIGUES

MONITORAMENTO AUTOMATIZADO DE ISOLAMENTOS  
POR IMAGEAMENTO ULTRAVIOLETA EMPREGANDO  
APRENDIZADO PROFUNDO

*Dissertação de Mestrado submetida ao  
Programa de Pós-graduação em Engenharia  
Elétrica da Universidade Federal de Sergipe  
como parte dos requisitos necessários para a  
obtenção do título de Mestre em Ciências no  
Domínio da Engenharia Elétrica.*

Orientador:

Professor Tarso Vilela Ferreira, D. Sc.

São Cristóvão  
2023

GUSTAVO ARAGÃO RODRIGUES

MONITORAMENTO AUTOMATIZADO DE ISOLAMENTOS POR  
IMAGEAMENTO ULTRAVIOLETA EMPREGANDO  
APRENDIZADO PROFUNDO

*Dissertação de Mestrado submetida ao  
Programa de Pós-graduação em Engenharia  
Elétrica da Universidade Federal de Sergipe  
como parte dos requisitos necessários para a  
obtenção do título de Mestre em Ciências no  
Domínio da Engenharia Elétrica.*

Aprovado em 22/08/2023

**Professor Eduardo Oliveira Freire, D. Sc.**  
Universidade Federal de Sergipe  
Avaliador

**Professor Jugurta Rosa Montalvão Filho, D. Sc.**  
Universidade Federal de Sergipe  
Avaliador

**Professor Marcus Tullius Barros Florentino, D. Sc.**  
Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco  
Avaliador

**Professor Tarso Vilela Ferreira, D. Sc.**  
Universidade Federal de Sergipe  
Orientador



UNIVERSIDADE FEDERAL DE SERGIPE  
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA  
COORDENAÇÃO DE PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA-PROEE

## TERMO DE APROVAÇÃO

### " MONITORAMENTO AUTOMATIZADO DE ISOLAMENTOS POR IMAGEAMENTO ULTRAVIOLETA EMPREGANDO APRENDIZADO PROFUNDO "

Discente:

**Gustavo Aragão Rodrigues**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Sergipe, como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Elétrica.

Aprovada pela banca examinadora composta por:

**Prof. Dr. Eduardo Oliveira Freire (PROEE/UFS)**  
**Presidente**

**Prof. Dr. Jugurta Rosa Montalvão Filho (PROEE/UFS)**  
**Examinador Interno**

**Prof. Dr. Marcus Tullius Barros Florentino (IFPE)**  
**Examinador Externo**

**Gustavo Aragão Rodrigues**  
**Candidato**

Cidade Universitária "Prof. José Aloísio de Campos", 22 de agosto de 2023.

**FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL  
UNIVERSIDADE FEDERAL DE SERGIPE**

R696s Rodrigues, Gustavo Aragão  
Monitoramento automatizado de isolamentos por imageamento ultravioleta empregando aprendizado profundo / Gustavo Aragão Rodrigues ; orientador Tarso Vilela Ferreira. - São Cristóvão, 2023.  
99 f. : il.

Dissertação (mestrado em Engenharia elétrica) – Universidade Federal de Sergipe, 2023.

1. Sistemas imageadores – Qualidade da imagem. 2. Corona (Eletricidade). 3. Transmissão de imagem. 4. Isoladores e isolamentos elétricos. I. Ferreira, Vilela Tarso orient. II. Título.

CDU 621.3



# RESUMO

A presença de descargas superficiais ou descargas corona nas vizinhanças de equipamentos e componentes do sistema elétrico é, em geral, um indício da ocorrência de algum fenômeno indesejável. Em diversos casos, caracteriza potencialmente um processo que pode levar à falha ou à degradação física dos materiais. Uma das técnicas mais promissoras de monitoramento de efeito corona é o uso de câmeras especializadas na detecção de radiação ultravioleta. Esta dissertação apresenta um algoritmo inovador de classificação da criticidade de isolamentos a partir de atributos extraídos de vídeos registrados com uma câmera capaz de detectar ultravioleta. A metodologia proposta baseia-se na extração de três atributos de cada origem de fâcula detectada: persistência máxima, área e distância mínima entre origem de fâcula e o isolamento. Para obter esse último atributo, propôs-se uma metodologia de segmentação dos isolamentos na imagem a partir da combinação de um modelo de rede neural convolucional profunda e o método de limiarização adaptativa da média. O modelo de aprendizado profundo apresentou precisão de 85,5% na detecção dos isolamentos em uma base de validação com 1985 imagens e 8730 instâncias. Já os resultados da classificação demonstraram que a distância entre o isolamento e a origem de fâcula é um atributo essencial para a análise do vídeo. Essa variável introduz um contexto as descargas registradas e permite diferenciar casos cuja origem da radiação ultravioleta é um isolamento, daquelas em que a localização da descarga é menos crítica.

**Palavras-chave:** Imageamento UV; Monitoramento de Equipamentos Elétricos; Efeito Corona; Visão Computacional.

# ABSTRACT

The presence of surface discharges or corona discharges in the vicinity of equipment and components of the electrical system is, in general, an indication of the occurrence of some undesirable phenomenon. In many cases, it potentially indicates a process that can lead to the failure or physical degradation of materials. One of the most promising techniques of corona effect monitoring is the use of specialized cameras for the detection of ultraviolet radiation. This dissertation presents an innovative algorithm for classifying the criticality of insulation based on attributes extracted from videos recorded with a camera capable of detecting ultraviolet radiation. The proposed methodology is based on extracting three attributes from each detected facula origin: maximum persistence, area and minimum distance between facula origin and isolation. To obtain this last attribute, we proposed a methodology for segmenting insulation in images using a combination of a deep convolutional neural network model and an adaptive thresholding method based on the mean. The deep learning model achieved 85.5% precision in detecting insulation on a validation dataset consisting of 1985 images and 8730 instances. The classification results showed that the distance between insulation and facula origin is an essential attribute for video analysis. This variable provides context for recorded discharges and allows differentiation between cases where ultraviolet radiation originates from insulation and those where discharge location is less critical.

**Keywords:** UV Imager; Conditional Monitoring; Corona Effect; Computer Vision.

# LISTA DE ILUSTRAÇÕES

Figura 1. Descarga corona em cadeia de isoladores de uma LT de 500 kV. ....	15
Figura 2. Manifestação do UV detectado na forma de fâculas na cor magenta. ....	17
Figura 3. Curva de Townsend. ....	21
Figura 4. Distorção do campo elétrico em uma avalanche de elétrons provocada por cargas espaciais. ....	24
Figura 5. Frequência de pulsos por tensão aplicada, para 3 valores de espaçamento na configuração ponta plano. ....	26
Figura 6. Distorção do campo elétrico provocada por cargas especiais na configuração ponta plano com polaridade positiva. ....	27
Figura 7. Exemplo do espectro de emissão de radiação de descargas coronas. ....	31
Figura 8. DayCor Luminar HD. ....	32
Figura 9. Exemplo de aplicação de operações morfológicas. ....	35
Figura 10. Exemplo de aplicação da limiarização adaptativa. ....	37
Figura 11. Exemplo de Arquitetura de uma RNA-C (LeNet). ....	39
Figura 12. Funcionamento da YOLO. ....	41
Figura 13. Arquitetura do YOLO. ....	42
Figura 14. Ilustração da IoU a partir das BBox <i>ground truth</i> e previstas. ....	43
Figura 15. Diagrama de blocos da metodologia. ....	55
Figura 16. Diagrama de blocos da construção do mapa de persistência. ....	57
Figura 17. Exemplos de rotulação do isolamento equipamentos elétricos. ....	59
Figura 18. Exemplos de técnicas de expansão artificial de base de dados. ....	60
Figura 19. Diagrama de blocos da primeira etapa da segmentação. ....	61
Figura 20. Ilustração da primeira etapa da segmentação. (a) Detecção dos isolamentos na imagem original. (b) Detecção dos isolamentos na imagem com rotação ideal. ....	62
Figura 21. Diagrama de blocos da segunda etapa da segmentação. ....	63
Figura 22. Exemplos de extração de fâculas. (a) Quadro original – CH. (b) Fâculas segmentadas – CH. (c) Quadro original – DI. (d) Fâculas segmentadas – DI. (e) Quadro original – IS. (f) Fâculas segmentadas – IS. (g) Quadro original – IP. (h) Fâculas segmentadas – IP. ....	67
Figura 23. Etapas da elaboração do mapa de persistência. ....	69
Figura 24. Comparação entre o resultado do somatório dos quadros e o mapa de persistência final. ....	70
Figura 25. Exemplos de detecção de isolamento. ....	72
Figura 26. Curva de precisão por confiança. ....	73
Figura 27. Curva de <i>recall</i> por confiança. ....	74
Figura 28. Etapas da segmentação do isolamento. ....	75
Figura 29. Exemplos de segmentação. (a) CH. (b) IP. (c) PR. (d) TC. (e) IS. (f) IS. ....	76
Figura 30. Exemplo 1 de aplicação do algoritmo. ....	78
Figura 31. Exemplo 2 de aplicação do algoritmo. ....	78

Figura 32. Exemplo 3 de aplicação do algoritmo. ....	79
Figura 33. Exemplo 4 de aplicação do algoritmo. ....	80
Figura 34. Exemplo 5 de aplicação do algoritmo. ....	80
Figura 35. Exemplo 6 de aplicação do algoritmo. ....	81
Figura 36. Exemplo 7 de aplicação do algoritmo. ....	82
Figura 37. Origem de descarga próxima a coluna isolante de uma CH. ....	83
Figura 38. Exemplos de aplicação do método em vídeos gravados a noite. ....	84
Figura 39. Curva de F1 por confiança. ....	95
Figura 40. Curva de precisão por recall. ....	96
Figura 41. Matriz de Confusão. ....	97
Figura 42. Resultados do treinamento da RNA-C. ....	98
Figura 43. Resultados do treinamento da RNA-C. ....	99

# LISTA DE TABELAS

Tabela 1. Planilha de revisão bibliográfica.....	52
Tabela 2. Peças detectadas por equipamento eléctrico.....	58
Tabela 3. Resultados do treinamento da RNA-C.....	72
Tabela 4. Resultado geral da classificação. ....	82
Tabela 5. Resultado geral da classificação dos dias 1 e 2 em termos percentuais. ....	84

# LISTA DE ABREVIATURAS

ANEEL	Agência Nacional de Energia Elétrica
BBox	<i>Bounding Box</i>
CA	Corrente Alternada
COCO	<i>Common Objects in Context</i>
CH	Chave Seccionadora
DI	Disjuntor
ESDD	<i>Equivalent Salt Deposit Density</i>
IA	Inteligência Artificial
IoU	<i>Intersection over Union</i>
IR	Interferência de Rádio
IS	Isolador de Suspensão
IP	Isolador de Pedestal
LT	Linha de Transmissão
mAP	<i>Mean Average Precision</i>
RNA-C	Redes Neurais Artificiais Convolucionais
RNA	Redes Neurais Artificiais
PDI	Processamento Digital de Imagens
PR	Para-raios
UTEPSI	Unidade Termoelétrica Porto de Sergipe I
SE	Subestação de Energia
TC	Transformador de Corrente
TP	Transformador de Potencial
TR	Transformador de Potência
UV	Ultravioleta
VC	Visão Computacional
YOLO	<i>You Only Look Once</i>
PV	Positivos verdadeiros
FP	Falsos positivos
FN	Falsos negativos

AP	<i>Average Precision</i>
mAP	<i>Mean Average Precision</i>

# LISTA DE SÍMBOLOS

$V_1$	Tensão de saturação da curva de Townsend
$i_0$	Corrente de saturação da curva de Townsend
$V_2$	Tensão de início da avalanche de elétrons
$\alpha$	Primeiro coeficiente de ionização de Townsend
$n$	Número de elétrons
$x$	Distância do cátodo na direção do campo
$dn$	Varição infinitesimal de elétrons
$dx$	Varição infinitesimal da distância do cátodo na direção do campo
$e^{\alpha d}$	Avalanche de elétrons
$V_3$	Terceiro nível de tensão da curva de Townsend
$V_4$	Quarto nível de tensão da curva de Townsend
$\gamma$	Segundo coeficiente de ionização de Townsend
$n_+$	Número de elétrons emitidos pelo cátodo devido ao bombardeamento de íons positivos
$C_{m\acute{a}x}$	Intensidade máxima de cor
$C_{m\acute{i}n}$	Intensidade mínima de cor
$p_{m\acute{a}x}$	Persistência máxima
$a_f$	Área de f\aculha
$d_{m\acute{i}n}$	Distância mínima entre a origem da f\aculha e o isolamento
$F_j$	Matriz de f\aculas
$im_{ref}$	Imagem do quadro de refer\ecncia
$M_p$	Matriz de persist\ecncia
$N_{frames}$	Número de frames do v\eddeo
$M_{bool}$	Matriz booleana do mapa de persist\ecncia
$M_{origens}$	Matriz de persist\ecncia com as origens de f\aculha separadas
$Im_{map}$	Imagem do mapa de persist\ecncia colorido
$R'$	Canal de cor vermelho normalizado de 0 a 1
$G'$	Canal de cor verde normalizado de 0 a 1

$B'$	Canal de cor azul normalizado de 0 a 1
$\Delta$	Varição de intensidade de cor
$A$	Matriz de transformação geométrica genérica
$t_x$	Valor da translação no eixo $x$
$t_y$	Valor da translação no eixo $y$
$c_x$	Valor da escala no eixo $x$
$c_y$	Valor da escala no eixo $y$
$S_v$	Valor da inclinação no eixo vertical
$S_h$	Valor da inclinação no eixo horizontal
$\theta$	Ângulo de rotação
$p$	<i>Precision</i>
$r$	<i>Recall</i>
$im_{seg}$	Imagem com os isolamentos segmentados
$k$	Origem de fábula
$d(k, r)$	Distância entre uma origem de fábula $k$ e um <i>pixel</i> qualquer dos isolamentos
$(x_r, y_r)$	Coordenadas e um <i>pixel</i> qualquer em $Im_{seg}$
$d_{mín}(k)$	Distância mínima entre uma origem de fábula $k$ e o isolamento
$P$	Parâmetro da $p_{máx}$ usado na classificação
$A$	Parâmetro da $a_f$ usado na classificação
$D$	Parâmetro da $d_{mín}$ usado na classificação
$L$	Largura do isolamento considerada pelo algoritmo

# SUMÁRIO

1. Introdução .....	15
1.1. Objetivos .....	18
1.1.1. Objetivos específicos.....	18
1.1.2. Estrutura do trabalho .....	18
2. Fundamentação Teórica .....	20
2.1. Mecanismos de condução de eletricidade em gases .....	20
2.1.1. Mecanismo de Townsend.....	20
2.1.2. Mecanismo de Streamer .....	23
2.2. O Efeito Corona .....	25
2.2.1. Tipos de corona por forma de onda.....	25
2.2.2. Tipos de corona por forma de condução .....	28
2.2.3. Características da Descarga Corona.....	29
2.3. Imageamento Ultravioleta.....	30
2.4. Morfologia Matemática .....	33
2.5. Limiarização Adaptativa da média .....	36
2.6. Redes neurais profundas aplicadas no reconhecimento de objetos .....	37
2.6.1. Redes neurais convolucionais .....	38
2.6.2. <i>You Only Look Once</i> (YOLO).....	40
2.6.3. Métricas para avaliação de modelos de detecção de objetos .....	42
2.6.4. Técnicas de Expansão Artificial da Base de Treinamento .....	44
2.7. Transformações de imagens.....	45
2.7.1. Transformações de Cores .....	45
2.7.2. Conversão de RGB para HSV .....	45
2.7.3. Transformações Geométricas .....	47
3. Revisão Bibliográfica .....	48
4. Metodologia .....	55
4.1. Extração de fâculas .....	56
4.2. Elaboração do Mapa de Persistência .....	57
4.3. Detecção com a RNA-C .....	58
4.4. Segmentação dos Isolamentos .....	61
4.5. Parametrização.....	63
4.6. Classificação .....	64

5. Resultados.....	67
5.1. Extração de Fáculas .....	67
5.2. Mapas de persistência .....	68
5.3. Detecção dos isolamentos .....	71
5.4. Segmentação dos isolamentos .....	74
5.5. Classificação .....	77
6. Conclusão.....	87
6.1. Perspectivas.....	88
6.2. Produções científicas e tecnológicas.....	89
6.2.1. Artigos científicos publicados .....	89
6.2.2. Patentes.....	90
6.2.3. Registro de Software .....	90
Referências .....	91
Apêndice A – Resultados do treinamento da RNA-C .....	95

# 1. INTRODUÇÃO

Em 1838 Michael Faraday publicava seu artigo intitulado “*Experimental Research in Electricity*”, que relatava uma série de experimentos envolvendo descargas disruptivas com uma variedade de eletrodos e polaridades. Em certo ponto, o físico britânico expôs a descoberta de uma “descarga escura” que precedia a formação de uma descarga disruptiva luminosa (Faraday, 1838). Tratava-se de uma das primeiras descrições do efeito corona. Atualmente, sabe-se que as descargas corona são resultado da ionização do ar e se apresentam na forma de descargas parciais entre o condutor energizado e o ar ao seu redor. Trata-se de um fenômeno não-linear que surge em regiões de campo elétrico intenso e não uniforme (Laplante, 2000).

O efeito corona é um tipo de descarga parcial, transitória ou permanente, que surge em campos elétricos não uniformes e pode ou não anteceder uma descarga disruptiva (Stracqualursi, 2021). Para o observador, o efeito é caracterizado por uma luminosidade tipicamente violeta e um ruído audível. Essas descargas podem ter origens diversas, como estruturas metálicas pontiagudas, sobretensões e defeitos em isolamentos. Na Figura 1 pode-se observar uma fotografia de longa exposição do efeito corona em uma cadeia de isoladores de 500 kV. Nota-se que as descargas surgem nas regiões de campo elétrico mais intenso, como por exemplo as quinas do anel equalizador.

Figura 1. Descarga corona em cadeia de isoladores de uma LT de 500 kV.



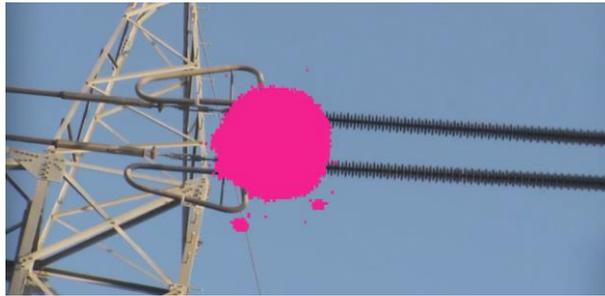
Fonte: (Bhutada, 2020).

A detecção e quantificação do efeito corona é particularmente importante no monitoramento de equipamentos elétricos de alta tensão, visto que nessas aplicações os campos não uniformes são inevitáveis (Kuffel, 2000). Além disso, as descargas corona provocam perdas relevantes em Linhas de Transmissão (LT) e, no longo prazo, podem deteriorar os isolamentos devido ao bombardeamento de íons e pela ação de compostos químicos formados pela descarga, como por exemplo, o ácido nítrico (Gorur, 1999). Uma falha de isolamento pode resultar no desligamento de uma LT, causando descon continuidades no fornecimento de energia elétrica. Como consequência, têm-se prejuízos à operação da concessionária, como a perda de faturamento e a incidência de multas previstas na legislação vigente, além da sensação de desconfiança perante o sistema de transmissão por parte dos consumidores.

Dessa forma, a presença de descargas superficiais ou descargas corona nas vizinhanças dos equipamentos e componentes do sistema elétrico é, em geral, um indício de ocorrência de algum fenômeno indesejável. Sendo este, potencialmente, um processo que pode levar à falha ou à degradação física dos materiais isolantes e das ferragens. Por essas razões, torna-se essencial o monitoramento dessas descargas em Subestações de Energia (SE) e em LTs. Isso pode ser feito a partir de manifestações físicas decorrentes de descargas corona, como a emissão de luz visível, radiação Ultravioleta (UV), ruído audível e ultrassônico, formação de ozônio, dentre outras (Gubanski, 2007).

Em condições bastante específicas, como baixa luminosidade ambiente, por exemplo, pode-se visualizar o efeito corona sem o auxílio de instrumentos. Contudo, durante o dia, esta visualização só é possível para casos extremos em que a descarga corona está próxima de se tornar uma descarga completa (fase-terra), comumente referida como *flashover*. O monitoramento por ruído audível ou ultrassônico também tem suas limitações, visto que dificilmente permitem a localização precisa da origem das descargas (Ferreira, 2012). A ferramenta mais adequada e moderna para esse monitoramento, portanto, é o detector de corona, que se baseia na detecção da radiação UV e representação na forma de imagens. O emprego de câmeras com capacidade de detecção de radiação UV permite, atualmente, a visualização das emissões na forma de fâculas (manchas luminosas), como exemplificado na Figura 2.

Figura 2. Manifestação do UV detectado na forma de fâculas na cor magenta.



Fonte: autoria própria.

A aplicação prática dessas câmeras, contudo, não é garantia de diagnóstico exato, uma vez que a interpretação dos padrões de fâculas requer uma análise subjetiva que depende da habilidade e experiência do inspetor. Além disso, a parametrização das imagens coletadas não é trivial e nem automatizada, sendo a quantização e localização das descargas uma tarefa desafiadora.

Com o intuito de colaborar com o estado da arte no tema, esta dissertação de mestrado apresenta uma metodologia capaz de sumarizar as características do efeito corona a partir de imagens UV, a saber: intensidade, persistência e localização da descarga. Para tanto, são aplicadas técnicas de Processamento Digital de Imagens (PDI) e Visão Computacional (VC). Além disso, propõe-se um algoritmo de classificação que, a partir das características extraídas, classifica as descargas corona detectadas entre 5 casos, os quais foram divididos levando em conta, principalmente, posição, intensidade e intermitência dessas descargas. Esta pesquisa utilizou dados originados em inspeções na SE de 500 kV da Unidade Termoelétrica Porto de Sergipe I (UTEPSI), de propriedade da ENEVA S.A; no município da Barra dos Coqueiros/SE (Brasil).

Este trabalho foi desenvolvido no âmbito do projeto GImpSI - Gestão dos Impactos da Salinidade em Isolamentos com o INESC P&D Brasil e a ENEVA S.A; no Programa de P&D da Agência Nacional de Energia Elétrica (ANEEL), código PD-11278-0001-2021.

## 1.1. OBJETIVOS

O objetivo principal dessa pesquisa é desenvolver uma metodologia capaz de extrair automaticamente características de vídeos UV e classificar a criticidade dos isolamentos monitorados.

### 1.1.1. OBJETIVOS ESPECÍFICOS

Os objetivos específicos são:

- Desenvolver um algoritmo para extrair atributos de filmagens feitas com uma câmera UV, de forma que seja possível sumarizar as características mais relevantes da descarga corona detectada;
- Aplicar algoritmos de VC para detecção e segmentação de isolamentos em imagens feitas com a câmera UV;
- Construir uma base de dados de filmagens UV de equipamentos elétricos em SE para validação da metodologia proposta de extração de atributos e classificação das descargas corona;
- Propor métricas de avaliação da criticidade de isolamentos a partir dos atributos extraídos e elaborar um algoritmo de classificação.

## 1.2. ESTRUTURA DO TRABALHO

Esta dissertação está estruturada em 5 capítulos além da Introdução. No capítulo 2, apresentado a seguir, está a Fundamentação Teórica, na qual são apresentados os principais conceitos para compreensão dessa pesquisa, desde o monitoramento por imageamento UV até as técnicas de VC usadas. No capítulo 3, consta a Revisão Bibliográfica do tema. Em seguida, no capítulo 4, está a metodologia deste trabalho, na qual está descrito, detalhadamente, o aparato experimental aplicado e os algoritmos desenvolvidos. No capítulo 5, são apresentados e discutidos os Resultados dessa pesquisa.

Por fim, a Conclusão da dissertação e as sugestões de trabalhos futuros para a sua continuidade e aprimoramento encontram-se no capítulo 6.

## **2. FUNDAMENTAÇÃO TEÓRICA**

Nesta seção estão apresentados os fundamentos teóricos mais importantes relacionados a temática desta pesquisa. Trata-se inicialmente do efeito corona e o imageamento UV, seguido pelos fundamentos dos algoritmos de visão computacional usados, que são: morfologia matemática; segmentação adaptativa; aprendizado profundo aplicado à detecção de objetos.

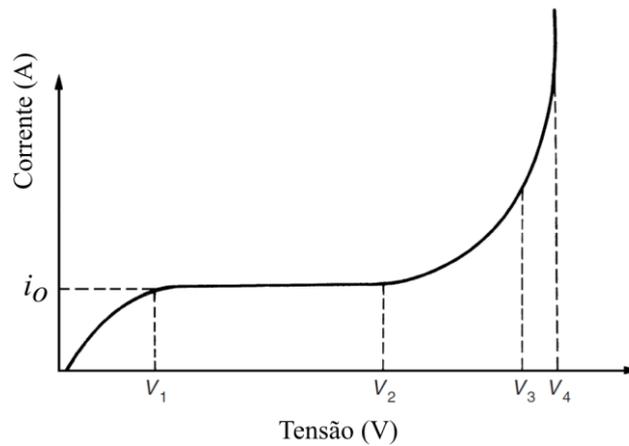
### **2.1. MECANISMOS DE CONDUÇÃO DE ELETRICIDADE EM GASES**

Em um gás ordinário e na ausência de um campo elétrico, a taxa de geração de elétrons e íons positivos é contrabalanceado por processos de decaimento. Esse estado de equilíbrio é perturbado com a aplicação de um campo suficientemente alto que pode ocasionar o deslocamento dos elétrons através do gás, resultando na formação de uma corrente elétrica (Kuffel, 2000). Ao longo dos anos, pesquisadores dedicaram-se a descrever o mecanismo de condução de corrente elétrica em gases. A seguir, estão descritos os dois principais modelos, o Mecanismo de Townsend e o Mecanismo de Streamer ou “Canal”.

#### **2.1.1. MECANISMO DE TOWNSEND**

O mecanismo de formação de descargas foi investigado por Townsend (1915). No seu estudo, o físico irlandês-britânico foi capaz de descrever a corrente entre duas placas paralelas como uma função não linear da tensão aplicada. Essa relação pode ser visualizada no da Figura 3.

Figura 3. Curva de Townsend.



Fonte: adaptado de Kuffel (2000).

Conforme a tensão aplicada aumenta, a corrente cresce até atingir o ponto de saturação ( $V_1$ ), no qual permanece constante em um valor  $i_0$ . Conforme o campo elétrico entre os eletrodos aumenta, os elétrons que saem do cátodo são acelerados cada vez mais até que sua energia seja suficiente para ionizar outros átomos no momento da colisão. A partir desse ponto ( $V_2$ ), inicia-se um processo de avalanche de elétrons, que resulta em um crescimento exponencial da corrente.

#### 2.1.1.1. PRIMEIRO COEFICIENTE DE IONIZAÇÃO DE TOWNSEND

O aumento exponencial da corrente a partir de  $V_2$  é justificado matematicamente pelo primeiro coeficiente de ionização de Townsend ( $\alpha$ ). Esse coeficiente quantifica o número de elétrons produzidos, por elétron, por unidade de comprimento na direção do campo elétrico. A variação de elétrons ( $dn$ ) a uma distância infinitesimal ( $dx$ ), pode ser descrita por

$$dn = \alpha n dx, \quad (1)$$

integrando (1) para a distância do cátodo ao ânodo ( $d$ ), obtém-se o número total de emissões primárias ( $n$ ), conforme a equação (2)

$$n = n_0 e^{\alpha d}, \quad (2)$$

em que  $n_0$  é o número de elétrons primários emitidos pelo cátodo. O termo  $e^{\alpha d}$  é denominado como “avalanche de elétrons” e é a quantidade de elétrons produzido por um

único elétron que percorre a distância entre o cátodo e o ânodo. A corrente ( $I$ ) entre o cátodo e o ânodo passa a ser igual a

$$I = i_0 e^{\alpha d}. \quad (3)$$

### 2.1.1.2. SEGUNDO COEFICIENTE DE IONIZAÇÃO DE TOWNSEND

Em seus experimentos, Townsend percebeu que a equação (3) não é capaz de descrever satisfatoriamente o comportamento da corrente na faixa de tensão entre  $V_3$  e  $V_4$ . Na prática, o crescimento era ainda mais rápido que o previsto pelo seu primeiro coeficiente de ionização. Nessa circunstância, Townsend postulou um segundo coeficiente de ionização ( $\gamma$ ), resultado da liberação de elétrons por colisão de íons positivos e pelo bombardeamento destes íons no cátodo. Adicionalmente, também faz parte do segundo coeficiente de Townsend o aumento de elétrons livres no gás devido a fotoionização, tanto no cátodo quanto no próprio gás.

Sendo  $n$  o número de elétrons que atingem o ânodo por segundo;  $n_0$  o número de elétrons emitidos pelo cátodo por luz UV;  $n_+$  o número de elétrons emitidos pelo cátodo devido ao bombardeamento de íons positivos e  $\gamma$  o número de elétrons emitidos pelo cátodo por incidência de íons positivos; os valores de  $n$  e  $n_+$  podem ser calculados, respectivamente, por

$$n = (n_0 + n_+)e^{\alpha d} \quad (4)$$

e

$$n_+ = \gamma[n - (n_0 + n_+)]. \quad (5)$$

Aplicando substituição em  $n_+$ , obtém-se:

$$n = \frac{n_0 e^{\alpha d}}{1 - \gamma(e^{\alpha d} - 1)}, \quad (6)$$

dessa forma, a corrente ( $I$ ) em regime permanente na região do gráfico da Figura 3, entre  $V_3$  e  $V_4$ , pode ser calculada por:

$$I = I_0 \frac{n_0 e^{\alpha d}}{1 - \gamma(e^{\alpha d} - 1)}. \quad (7)$$

### 2.1.1.3. TRANSIÇÃO ENTRE DESCARGA NÃO-AUTOSSUSTENTADA PARA A RUPTURA DO MEIO DIELÉTRICO

Conforme o gráfico da Figura 3, para valores de tensão superiores a  $V_4$  a corrente transaciona entre uma “corrente escura” para uma descarga autossustentada. Isso ocorre pois o denominador da equação (7) aproxima-se de zero, visto que nessas condições

$$\gamma(e^{\alpha d} - 1) = 1. \quad (8)$$

Nesse ponto, o número de íons produzidos entre os eletrodos pela passagem de uma avalanche de elétrons é tão grande, que a própria colisão destes íons no cátodo é capaz de sustentar a corrente elétrica. Os efeitos secundários passam, portanto, a sustentar a corrente elétrica por si só. Quando o critério da equação (8) é atendido, a corrente cresce indefinidamente. Na prática, essa corrente é limitada pela capacidade do circuito externo.

## 2.1.2. MECANISMO DE STREAMER

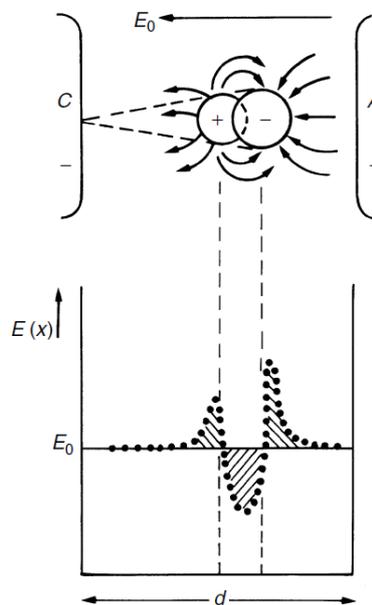
Com o avanço nas pesquisas o Mecanismo de Townsend mostrou-se incapaz de descrever a condução de eletricidade em gases em condições de alta pressão, grande espaçamento entre os eletrodos e campos não uniformes. Nesse contexto, assumindo  $pd$  como a multiplicação entre a distância dos eletrodos e a pressão no gás. Demonstrou-se experimentalmente que para altos valores de  $pd$  a ruptura ocorre muito mais rápido que o tempo necessário para que os íons colidam com o cátodo. Em outras palavras, nessas condições o segundo coeficiente de Townsend não é capaz de explicar a formação da descarga. Além disso, nessas condições, o canal condutivo tem um formato de “zig-zag” e a descarga passa a ser independente do material dos eletrodos. Esses dois fatos também contrariam a teoria de Townsend (Kuffel, 2000).

Foi necessário, então, elaborar um novo modelo, chamado Mecanismo de *Streamer* ou Mecanismo de Canal. Essa nomenclatura foi adotada pois a nova teoria prevê a formação de um canal de alta condutividade no momento da ruptura do gás. O conceito

de *Streamer* positivo foi proposto por Loeb e Meeke (1940), enquanto o conceito do *Streamer* negativo foi proposto por Raether (1939). A teoria baseia-se na ideia de que, em um certo estágio de desenvolvimento de uma avalanche de elétrons, a fotoionização do gás torna-se o mecanismo mais importante para a formação da descarga.

O crescimento de portadores de carga em uma avalanche em um campo uniforme ( $E_0$ ) é descrito por  $e^{\alpha d}$ . Contudo, isso é válido apenas enquanto o campo elétrico das cargas espaciais de íons e elétrons for negligenciável em comparação com  $E_0$ . O fenômeno de distorção do campo, provocado pelas cargas espaciais, pode ser visto esquematicamente na Figura 4.

Figura 4. Distorção do campo elétrico em uma avalanche de elétrons provocada por cargas espaciais.



Fonte: Kuffel (2000).

Raether (1939), observou que, quando a concentração de cargas estava entre  $10^6$  e  $10^8$ , o crescimento da avalanche era enfraquecido. Por outro lado, quando a concentração de íons excedia  $10^8$ , a corrente de avalanche era seguida por um aumento em degrau da corrente e pela descarga disruptiva. Nesses dois casos, essas variações na formação da descarga foram atribuídas às distorções em  $E_0$  pelo campo de carga espacial.

Conforme a Figura 4, no Mecanismo de *Streamer*, assume-se que a carga espacial na cabeça da avalanche é concentrada dentro de um volume esférico, com a carga negativa à frente devido à maior mobilidade dos elétrons. A proximidade dessa carga do ânodo eleva o campo elétrico à frente da avalanche. Já a interação entre os elétrons e íons da

avalanche reduzem o campo  $E_0$ . Na parte de trás da avalanche, o campo eleva-se novamente, devido à variação de potencial entre os íons positivos da avalanche e o cátodo.

O aumento de campo elétrico, provocado pelas distorções causadas pela carga espacial, leva à formação de novas avalanches de elétrons secundários através da fotoionização na extremidade do cone. As avalanches secundárias aumentam ainda mais a carga espacial, que se estende até as proximidades do cátodo e distorce ainda mais o campo  $E_0$ . No lado do cátodo, a elevação do campo elétrico causada pelos íons positivos provoca a liberação de mais elétrons, contribuindo com a formação de um canal condutivo. Por fim, quando o canal se estende por todo o caminho entre os eletrodos, ocorre a ruptura do meio dielétrico (Kuffel, 2000).

## 2.2. O EFEITO CORONA

O efeito corona é um fenômeno não linear resultante da ionização do ar em uma região de campo elétrico intenso e não uniforme. O fenômeno se apresenta na forma de descargas parciais entre o condutor e o ar. Em casos em que a intensidade da descarga é alta pode apresentar, também, luminosidade brilhante tipicamente violeta e ruído audível (Laplante, 2000). As descargas corona podem ser classificadas em termos de forma de onda e tipo de condução.

### 2.2.1. TIPOS DE CORONA POR FORMA DE ONDA

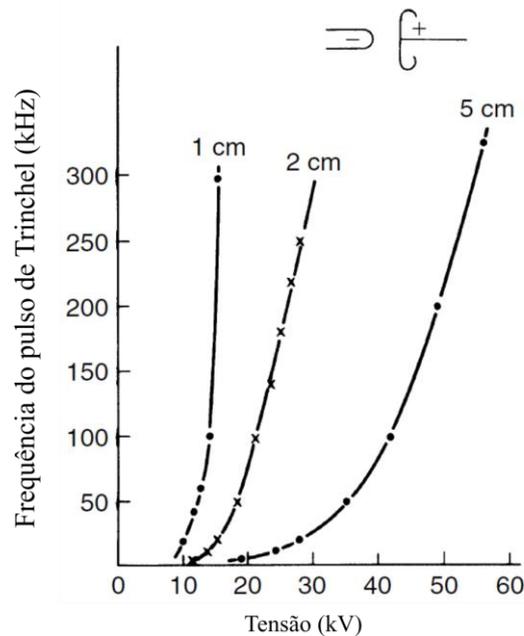
Os tipos de efeito corona podem ser divididos a partir da forma de onda dos eletrodos ativos. A seguir, discute-se o corona positivo, negativo e de corrente alternada (CA).

#### 2.2.1.1. CORRENTE CONTÍNUA COM POLARIDADE NEGATIVA

Ao aplicar uma tensão contínua e com polaridade negativa a um eletrodo, o corona se manifesta inicialmente na forma de pulsos de corrente. Conforme a tensão aumenta, a frequência dos pulsos também aumenta. Na Figura 5 consta um gráfico da frequência

desses pulsos, conhecidos como “Pulsos de Trichel”, por tensão aplicada para três valores de espaçamento diferentes entre eletrodos ponta-plano (Trichel, 1939).

Figura 5. Frequência de pulsos por tensão aplicada, para 3 valores de espaçamento na configuração ponta plano.



Fonte: adaptado de Kuffel (2000).

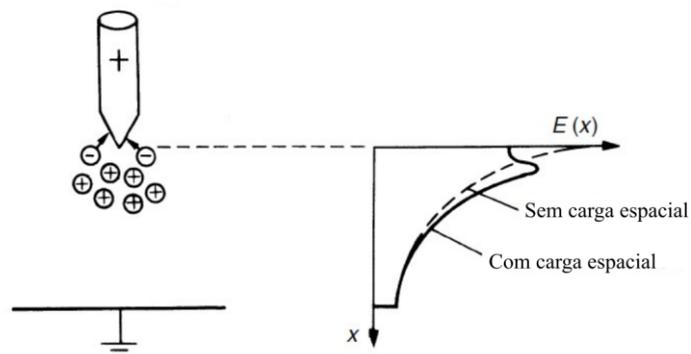
A carga espacial que surge nas proximidades do eletrodo tende a reduzir o campo elétrico localmente até que a carga espacial diminua significativamente e o processo reinicie. Nessa condição, aumentar ainda mais a tensão resulta no surgimento do brilho típico do efeito corona e, quando a tensão se aproxima do valor de ruptura do meio dielétrico, o *Streamer* passa a crescer em direção ao ânodo. Para a polaridade negativa, a ruptura tende a ocorrer para um valor de tensão significativamente superior que em polaridade positiva, exceto em condições de baixa pressão (Stracqualursi, 2021).

#### 2.2.1.2. CORRENTE CONTÍNUA COM POLARIDADE POSITIVA

Para o caso de uma configuração ponta plano, com polaridade positiva, conforme ilustrado na Figura 6, tem-se que, próximo ao eletrodo carregado, a ionização do gás ocorre por colisão de elétrons, os quais, devido a sua grande mobilidade, atingem o ânodo, deixando cargas espaciais positivas para trás. Essas cargas vão provocar um aumento do campo na direção do cátodo e uma redução do campo na direção do ânodo. A região de campo mais intenso se move em direção ao cátodo, o que estende a região de ionização.

Conforme essa carga espacial positiva avança, o campo localmente pode se tornar intenso o suficiente para a formação de um *Streamer* no cátodo, que pode levar a uma descarga disruptiva.

Figura 6. Distorção do campo elétrico provocada por cargas especiais na configuração ponta plano com polaridade positiva.



Fonte: (Kuffel, 2000).

### 2.2.1.3. CORRENTE ALTERNADA

Em CA, a oscilação de tensão provoca oscilação no movimento das cargas espaciais desenvolvidas pelo corona (Giao, 1968). Na análise desses casos, é importante levar em conta a existência de uma distância crítica que depende do valor de tensão de pico e frequência, e que contabiliza o caminho percorrido pelas partículas carregadas durante um quarto de ciclo. Essa distância diferencia os casos em que as cargas espaciais têm tempo de serem neutralizadas (por migração de íons ao eletrodo de polaridade oposta), dos casos em que a carga espacial residual afeta o desenvolvimento dos modos de corona durante o ciclo subsequente (Stracqualursi, 2021). No primeiro caso, observam-se comportamentos típicos de corona CC nos ciclos positivos e negativos.

Como a ruptura do meio dielétrico ocorre em menor tensão na polaridade positiva do que na negativa, em CA, essa ruptura tende a ocorrer na parcela positiva do ciclo (Kuffel, 2000). Dessa forma, em condições normais, a formação do *Streamer* negativo não é observada em CA, visto que a descarga disruptiva ocorrerá antes que seja possível o desenvolvimento desse *Streamer*.

## **2.2.2. TIPOS DE CORONA POR FORMA DE CONDUÇÃO**

Uma descarga corona é, por definição, uma descarga em gás onde a geometria confina os processos de ionização do gás em regiões de alta ionização ao redor dos eletrodos ativos. Em termos de condução, o fenômeno pode ser classificado entre unipolar e bipolar (Goldman, 2009).

### **2.2.2.1. CONDUÇÃO UNIPOLAR**

No efeito corona de condução unipolar, a polaridade predominante dos íons é igual a polaridade do corona, ou seja, íons positivos em descargas positivas e íons negativos em descargas negativas. São exemplos de corona unipolar, as descargas de brilho positivo, o corona negativo de pulso de Trichel e o corona de brilho negativo. Todas essas variações possuem regiões de ionização que ficam concentradas nas proximidades do eletrodo ativo (Goldman, 2009).

Para o corona unipolar com corrente na ordem de microamperes e acima, as descargas são estáveis e contínuas ou, mais frequentemente, são compostas por pulsos curtos de alta frequência que mantém o fluxo de íons praticamente contínuo na região de deriva. Em uma configuração ponta plano, os pulsos de alta frequência na região de ionização tendem a provocar corrosão no eletrodo ponta (negativo), o que pode afetar a região de deriva e o eletrodo plano por pulverização catódica, evaporação do metal ou por subprodutos da corrosão (Goldman, 2009).

Para o corona com corrente ainda mais alta, as cargas espaciais tornam a distribuição do campo elétrico mais uniforme. Esse fator, assim como uma tensão mais alta aplicada aos eletrodos, aumentam acentuadamente o campo da região de deriva, aumentando a taxa de íons negativos.

### **2.2.2.2. CONDUÇÃO BIPOLAR**

O corona de condução bipolar ocorre em correntes ainda mais altas, especialmente na polaridade positiva. Quando a corrente atinge valores elevados em uma configuração ponta-plano de polaridade positiva, a região de ionização produz um plasma condutor a uma taxa mais veloz do que esse plasma pode ser absorvido pelo eletrodo ponta. Nessas

condições, um filamento de plasma condutor cresce a partir do eletrodo ponta em direção ao plano, levando a região de ionização produtora de plasma para próximo do cátodo.

Quando este *streamer* atinge o plano, faz surgir nele uma descarga de brilho pulsado, bombardeando-o com íons positivos. O campo de lacunas é, então, redistribuído ao longo do canal de plasma e este canal é neutralizado por ligação de elétrons, ou se converte em uma descarga disruptiva por ionização térmica (Goldman, 2009).

### **2.2.3. CARACTERÍSTICAS DA DESCARGA CORONA**

O surgimento da descarga corona é acompanhado de fenômenos físicos e químicos que podem ser detectados e monitorados. Trata-se de características que podem ser problemáticas para o SEP, mas ao mesmo tempo podem facilitar o estudo do fenômeno.

#### **2.2.3.1. LUMINOSIDADE**

Em seu estágio mais avançado, o efeito corona emite luz na faixa visível, isto é, entre 380 e 780 nm, apresentando uma luminosidade tipicamente violeta. Em seu estágio inicial, idealmente buscado a partir do uso de técnicas de monitoramento de equipamentos de alta tensão, o efeito corona emite luz nos comprimentos de onda na faixa de 230 a 405 nm (Herzberg, 1950), apresentando um espectro que se encontra contido na faixa UV (100 e 400 nm), o que permite a detecção das descargas por dispositivos sensíveis a esse tipo de radiação, tais como as câmeras UV. Essa característica também despertou o interesse de pesquisadores em investigar o impacto dessas descargas na vida selvagem, visto que alguns animais podem não só enxergar no espectro UV, mas sofrer algum prejuízo devido a presença das LT (Tyler, 2017).

#### **2.2.3.2. RUÍDO AUDÍVEL E ULTRASSÔNICO**

Um efeito adicional da descarga corona é a emissão de ruído no espectro audível (aproximadamente na faixa de 20 Hz–20 kHz). O ruído total emitido é a superposição de componentes de banda larga e de tom único. Os componentes de banda larga estão associados a descargas na superfície do condutor, causando variações rápidas na pressão

do ar devido ao aquecimento local intenso (Stracqualursi, 2021). Já o componente de tom único surge em CA com o dobro da frequência de operação da linha, correspondente aos picos positivo e negativo da senoide. Além do ruído audível, o efeito corona também emite ruído ultrassônico, que pode ser detectado e usado como ferramenta de monitoramento de descargas (Ferreira, 2012).

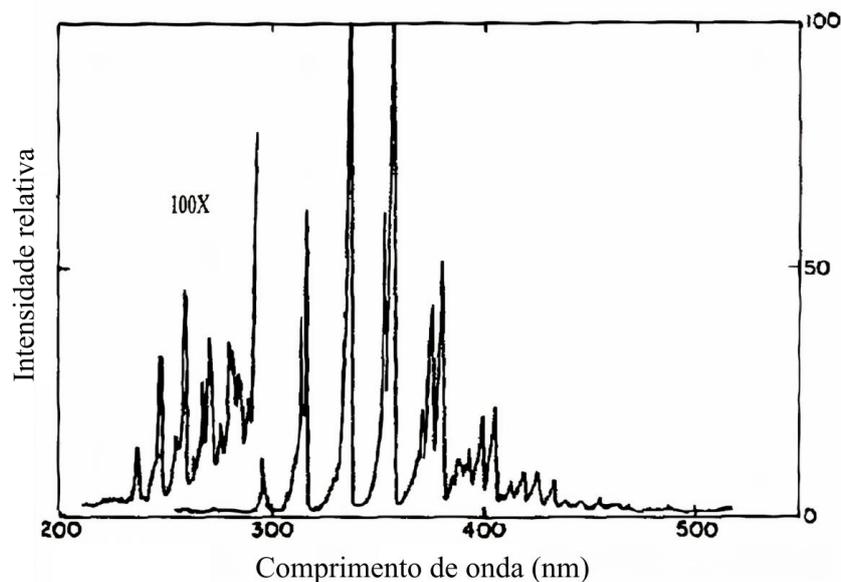
#### 2.2.3.3. INTERFERÊNCIA DE RÁDIO

O efeito corona pode causar Interferência de Rádio (IR) nas proximidades de LT e SE, afetando a qualidade de transmissões. A IR originada por essas descargas ocorre na faixa entre 0,01 MHz e 30 MHz (IEEE Std. 430, 2017). Para avaliar o impacto do corona na transmissão de sinais em frequências de rádio, são considerados três aspectos: a atenuação do campo ao nível do solo na direção perpendicular à fonte, o espectro de frequência e distribuição estatística, conforme procedimentos adequados de medição (Stracqualursi, 2021).

### 2.3. IMAGEAMENTO ULTRAVIOLETA

O imageamento UV é uma das técnicas mais modernas e confiáveis de monitorar o efeito corona em equipamentos elétricos de alta tensão. Esta técnica baseia-se em detectar a radiação UV emitida por descargas corona, as quais emitem radiação na faixa de 230 a 405 nm, sendo os comprimentos de onda com emissões mais intensa: 298 nm, 317 nm, 337 nm e 357 nm (Herzberg, 1950). Um típico espectro de emissão de descarga de corona no ar está ilustrado na Figura 7. Nota-se que a faixa abaixo do pico de 298 nm possui intensidade relativa em torno de 100 vezes menor que o restante do espectro.

Figura 7. Exemplo do espectro de emissão de radiação de descargas coronas.



Fonte: adaptado de Grum (1976).

Os detectores de corona de primeira geração possuíam um intensificador único de imagem UV para capturar tanto as descargas quanto a luz visível. Esses dispositivos capturavam a emissão de corona usando filtros ópticos com transmissão máxima nas frequências de pico, a fim de melhorar o contraste entre as fâculas e as imagens de fundo (Lindner, 1999). Tais dispositivos eram capazes de registrar a atividade corona com nitidez apenas em condições de baixa luminosidade ambiente. Adicionalmente, como a emissão de corona era muito fraca em relação à irradiação solar nessas faixas de emissão, as inspeções não podiam ocorrer sob condições de luz do dia.

Detectores mais sofisticados capturavam a informação UV no pico do ciclo CA e a informação da luz no espectro visível no cruzamento por zero da onda de tensão de alimentação (Voslo, 1977). Um processamento de imagem era então aplicado para exibir a captura da descarga corona com o cenário ao redor. Como qualquer sistema que usa subtração de fundo, o desempenho era limitado pela relação entre o sinal e os níveis de fundo.

Os detectores de corona modernos operam na chamada banda solar cega (240 a 280 nm), que é a banda do UV solar filtrada pela camada de ozônio e que, conseqüentemente, não chega nas camadas baixas da atmosfera (Lindner, 1999). Nota-se que essa faixa está exatamente na região ampliada do gráfico da Figura 7. Ou seja, as câmeras modernas operam longe dos picos de emissão UV do corona, conseqüentemente, precisam agregar tecnologia para amplificar o sinal captado pelo sensor UV. Dessa forma,

ao combinar uma câmera de imagem intensificada com um filtro passa-banda solar cega, obtém-se uma imagem solar cega UV com responsividade limitada a essa banda. Na Figura 8 consta uma fotografia de um detector de corona moderno.

Figura 8. DayCor Luminar HD.



Fonte: autoria própria.

Os detectores de corona representam graficamente a radiação UV mensurada por meio de fâculas (pontos brilhantes na tela). Quanto maior o tamanho da fâcula exibida, mais intensa a radiação UV detectada. Outro aspecto importante do imageamento UV é a intermitência das descargas corona. É por essa razão que essas câmeras são usadas para gravar vídeos ao invés de fotografias, dessa forma, é possível registrar o comportamento do fenômeno ao longo do tempo. Assim, ao avaliar o resultado das inspeções, é imprescindível considerar tanto a intensidade do UV quanto a sua persistência ao longo do tempo.

A câmera UV moderna possui ganho variável. Recomenda-se que para avaliar equipamentos recorrentemente o detector de corona seja ajustado sempre com o mesmo ganho. Em outros contextos, aumentar o ganho pode ser útil para detectar uma emissão de UV fraca e acompanhar sua evolução. Por outro lado, para casos em que há registro de descargas muito intensas, é auspicioso que o ganho seja atenuado visando uma melhor observação da origem da descarga.

Garantir o posicionamento adequado da câmera no momento das filmagens é de suma importância. Quanto mais distante da origem do UV mais atenuado é o sinal, sendo

assim, é importante levar em consideração a distância de monitoramento a fim de minimizar essas variações. Além disso, quando possível, um mesmo equipamento deve ser monitorado a partir de ângulos diversos. Isso permite uma melhor visualização do comportamento das descargas e uma localização mais precisa da sua origem.

Por fim, um parâmetro muito importante e que precisa ser considerado ao operar uma câmera UV é a umidade, já que a descargas corona tendem a ficar mais intensas quando a umidade está alta (Jin, 2017). De preferência, inspeções recorrentes devem ocorrer com umidade dentro de uma faixa específica, de forma que seja possível descartar a influência da umidade em uma avaliação temporal. É possível, também, aproveitar-se da alta umidade para buscar problemas incipientes em isolamentos. Nesse caso há um risco maior de detectar falsos positivos e a interpretação correta das filmagens depende mais ainda da experiência do operador.

Apesar da robustez da técnica, a aplicação das câmeras UV em campo ainda é pouco disseminada e seu uso como ferramenta de monitoramento no SEP ainda é bastante limitado. Isso pode ser justificado pela dificuldade de interpretação das filmagens e de realização de um diagnóstico adequado. Dessa forma, mesmo em situações que o operador da câmera identifique um foco acentuado de fâculas, não é trivial dimensionar a gravidade do registro e muito menos determinar a necessidade de uma intervenção no equipamento. Parte dessa dificuldade está em saber com confiabilidade a origem da descarga corona e se a intensidade dela é ou não relevante.

Devido à relevância do tema, diversas pesquisas vêm sendo desenvolvidas nos últimos anos no sentido de aumentar a eficiência das inspeções por imageamento UV. Uma revisão bibliográfica aprofundada do tema está apresentada no capítulo 3.

## 2.4. MORFOLOGIA MATEMÁTICA

Na biologia, a morfologia é o estudo da estrutura dos animais e plantas. No contexto do PDI, trata-se do estudo da estrutura geométrica das entidades presentes em uma imagem e tem como base a teoria de conjuntos (Marques Filho, 1999). A técnica de morfologia matemática (ou digital) pode ser aplicada em diversas áreas do processamento de imagens, com destaque para filtragem, detecção de bordas, esqueletização, segmentação e afinamento. O princípio de funcionamento da morfologia matemática está

em, por meio de um conjunto definido chamado de elemento estruturante, aplicar uma transformação em uma imagem e com isso extrair informações relativas as suas geometria e topologia. As duas operações básicas da morfologia são a dilatação e a erosão (Talbot, 2013).

Dados os conjuntos  $A$  e  $B$  definidos em um espaço bidimensional  $Z^2$  de uma imagem digital, cujos componentes são  $a = (a_1, a_2)$  e  $b = (b_1, b_2)$ . Realizar a operação de dilatação de  $A$  por  $B$  é obter o conjunto de deslocamentos  $x$  para os quais a intersecção de  $(\hat{B})_x$  e  $A$  inclui pelo menos um elemento diferente de 0. Sendo  $\hat{B}$  a reflexão de  $B$ , obtida por (Marques Filho, 1999):

$$\hat{B} = \{x | x = -b, \text{ para } b \in B\}, \quad (9)$$

e  $(B)_x$  é a translação de  $B$  por  $x = (x_1, x_2)$ , definida por:

$$(B)_x = \{c | c = b + x, \text{ para } b \in B\}. \quad (10)$$

Sendo assim, a operação de dilatação, denotada por  $A \oplus B$ , pode ser definida matematicamente como:

$$A \oplus B = \{x | [( \hat{B} )_x \cap A] \subseteq A\}. \quad (11)$$

A operação de erosão, por sua vez, resulta no conjunto de pontos  $x$  tais que  $B$ , transladado de  $x$ , está contido em  $A$ . Em termos matemáticos, a erosão  $(A \ominus B)$  é obtida por (Marques Filho, 1999):

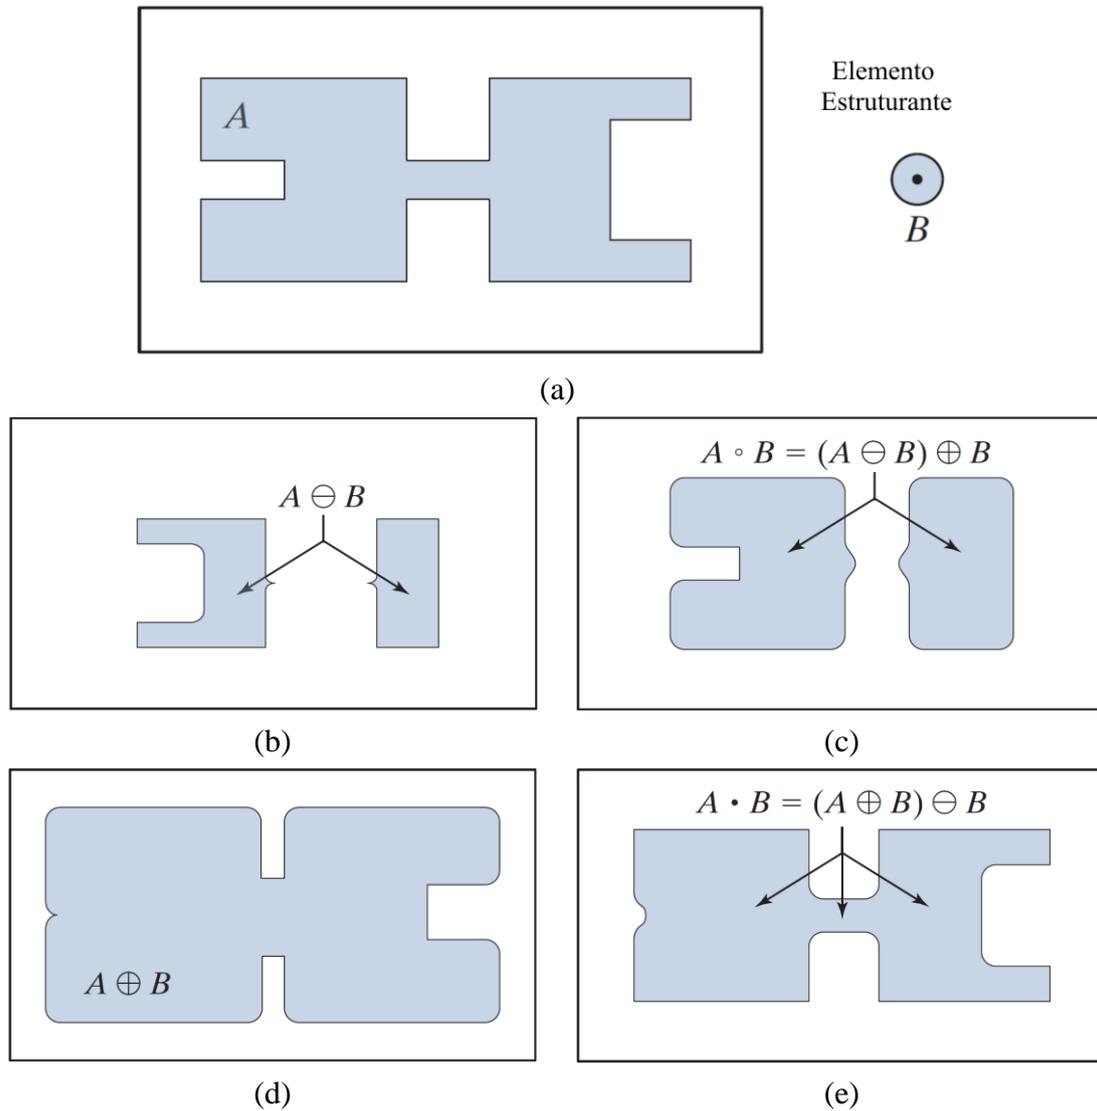
$$A \ominus B = \{x | (B)_x \subseteq A\}. \quad (12)$$

Em linhas gerais, a dilatação expande uma imagem enquanto a erosão encolhe. A combinação dessas duas operações dá origem a mais duas operações morfológicas: a abertura e o fechamento. A abertura consiste em uma erosão seguida por uma dilatação com elemento estruturante espelhado. Sua aplicação suaviza contornos, quebra regiões estreitas e elimina proeminências delgadas. Analogamente, o fechamento é resultado de uma dilatação seguida por uma erosão, também com elemento estruturante espelhado, e tende a fundir pequenas quebras, alargar golfos estreitos, eliminar orifícios e preencher espaços vazios no contorno (Gonzales, 2018b).

Na Figura 9 observa-se um exemplo de aplicação das operações morfológicas apresentadas. A letra *A* indica a imagem original e a letra *B* o elemento estruturante usado. Nota-se que a abertura separou a imagem em duas regiões enquanto o fechamento manteve um formato mais parecido com o original. As bordas externas foram suavizadas pela abertura enquanto as bordas internas foram suavizadas pelo fechamento.

Figura 9. Exemplo de aplicação de operações morfológicas.

(a) Imagem original e elemento estruturante. (b) Erosão. (c) Abertura. (d) Dilatação (e) Fechamento.



Fonte: adaptado de Gonzales (2018b).

## 2.5. LIMIAZIZAÇÃO ADAPTATIVA DA MÉDIA

A limiarização é o processo que determina o limiar ( $T$ ) para a binarização dos *pixels* de uma imagem. Em outras palavras, é um procedimento aplicado para converter uma imagem em tons de cinza em uma imagem em preto e branco. Existem diversas maneiras de calcular  $T$  (Gonzales, 2018b). Tradicionalmente, são aplicados os métodos de limiarização global, os quais calculam um único valor de  $T$  para toda a imagem como, por exemplo, o método desenvolvido por Otsu (1979). Contudo, os métodos globais tendem a perder desempenho quando a imagem possui uma variedade significativa de intensidade de *pixels*, seja por variação de iluminação ou pela própria complexidade das formas na imagem.

Os métodos de limiarização adaptativa minimizam esse problema ao calcular  $T$  para cada *pixel* da imagem de acordo com critérios estatísticos relacionados à vizinhança daquele *pixel*. Existem diversas maneiras de realizar esse cálculo estatístico, destacam-se o método da média aritmética e da média Gaussiana. Para esses métodos, e considerando o operador de média genérico *mean*, o valor de  $T$  é calculado por:

$$T = \text{mean}(I_L) - C \quad (13)$$

em que  $I_L$  é uma região da imagem e  $C$  é uma constante usada para o ajuste fino da segmentação. O tamanho da região  $I_L$  também pode ser ajustado de forma a modificar significativamente resultado da segmentação. Dessa forma, cabe ao usuário definir a melhor janela para cada aplicação do método. Na Figura 10 observa-se exemplos de aplicação da limiarização adaptativa da média aritmética e gaussiana com janela de 501 *pixels* em uma imagem em 4k de um disjuntor, além de um exemplo da aplicação do método de Otsu.

Figura 10. Exemplo de aplicação da limiarização adaptativa.

(a) Imagem original. (b) Imagem binarizada pelo método adaptativo da média. (c) Imagem binarizada pelo método adaptativo da gaussiana. (d) Imagem binarizada pelo método de Otsu.



Fonte: autoria própria.

## 2.6. REDES NEURAIS PROFUNDAS APLICADAS NO RECONHECIMENTO DE OBJETOS

A Inteligência Artificial (IA) é um campo da ciência da computação que se dedica ao estudo e ao desenvolvimento de máquinas e programas computacionais capazes de reproduzir o comportamento humano na tomada de decisões e na realização de tarefas. Atualmente, IAs são usadas em reconhecimento de linguagem natural, controle de

veículos autônomos, controle de processos industriais complexos e até mesmo para derrotar grandes mestres no xadrez. No campo da visão computacional, a IA possui diversas aplicações, com destaque para o reconhecimento, detecção e segmentação de objetos. A maioria dessas aplicações baseia-se em Redes Neurais Artificiais Convolucionais (RNA-C) (Gonzales, 2018a).

O reconhecimento de padrões passa, tipicamente, por 4 etapas: aquisição, pré-processamento, extração de características e classificação. A aquisição consiste em gerar as imagens de entrada para o algoritmo, em geral, imagens de câmeras digital. O pré-processamento é uma etapa opcional que busca melhorar aspectos da imagem e prepará-la para etapas seguintes. Exemplos de pré-processamento são redução de ruído e correções geométricas. A extração de características costuma ser a etapa mais desafiadora e é onde estão dedicados os principais esforços de pesquisa. As RNA-C utilizam grandes bases de dados para ensinar a máquina a extrair automaticamente essas características. Dessa forma, a etapa final classifica a imagem de entrada, ou objetos nessa imagem, em uma ou mais classes pré-definidas (Gonzales, 2018a).

### **2.6.1. REDES NEURAIAS CONVOLUCIONAIS**

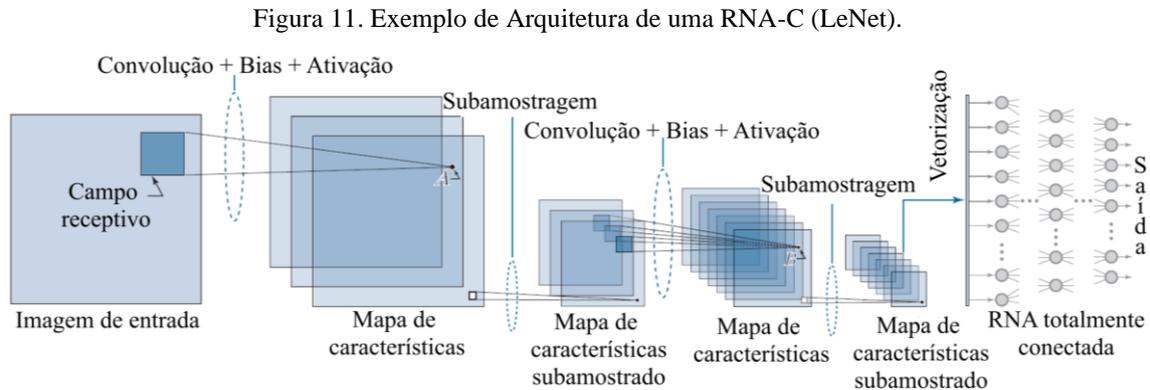
A primeira aplicação do que hoje é chamado de RNA-C foi publicada por LeCun (1989). Os autores aplicaram esse tipo de rede no reconhecimento de números escritos a mão e, mesmo com uma rede pequena, obtiveram resultados animadores que demonstraram a viabilidade da técnica. Décadas depois, com a publicação dos resultados da competição ImageNet de 2012, as RNA-C ganharam destaque e passaram a ser cada vez mais utilizadas até se tornarem o estado da arte no que diz respeito ao reconhecimento de objetos em imagens complexas (Gonzales, 2018b).

As etapas computacionais de um RNA-C são fundamentalmente iguais a uma RNA tradicional:

- 1) Realizar uma soma de produtos;
- 2) Somar um valor de *bias*;
- 3) Passar por uma função de ativação;
- 4) Seguir com esse resultado para a camada subsequente.

A grande vantagem de uma RNA-C, em relação as redes tradicionais, está no compartilhamento de pesos, que é possibilitado pela operação da convolução de uma

máscara de pesos com a imagem. Na Figura 11 está ilustrada didaticamente a arquitetura de uma RNA-C do tipo LeNet. Trata-se de uma rede com duas camadas convolucionais, seguida por uma rede totalmente conectada.



Como ilustrado na Figura 11, a primeira operação realizada por uma RNA-C é a convolução, cujos valores são gerados movendo o campo receptivo sobre a imagem e realizando, em cada ponto, a soma de produtos. Na terminologia das RNA-C, os campos receptivos são uma vizinhança da imagem com as mesmas dimensões de uma máscara (ou *kernel*) (GONZALES, 2018b). Os valores de cada *pixel* dessa máscara são os pesos da rede, que são iniciados de forma aleatória e ajustados automaticamente durante o treinamento da rede. Tradicionalmente, cada camada convolucional usa uma máscara diferente, de forma que a quantidade total de pesos de uma RNA-C depende não só do número de camadas convolucionais, mas também da dimensão das máscaras de cada uma dessas camadas. Já as camadas totalmente conectadas possuem seu próprio conjunto de pesos, de forma que incrementam ainda mais o número total de pesos do modelo.

O processo de convolução em imagens consiste em mover o centro de uma máscara (rotacionada 180°) por uma imagem e calcular a soma dos produtos para cada localização. Matematicamente, a convolução de uma máscara  $w$  com tamanho  $m \times n$  e uma imagem  $f(x,y)$ , denotada como  $w * f(x,y)$ , pode ser calculada por (Gonzales, 2018b):

$$w * f(x,y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s,t) f(x+s, y+t). \quad (14)$$

Em uma RNA-C, soma-se um *bias* ao resultado da convolução em cada combinação  $(x, y)$  da imagem. O resultado dessa soma passa por uma função de ativação.

Essa saída ocupa a posição  $(x, y)$  do mapa de características, que é entrada da camada subsequente.

A etapa após a camada de convolução é a sub amostragem, conhecida como *pooling*. Essa operação reduz a sensibilidade do modelo a translações na imagem de entrada, além de reduzir significativamente o volume de informação processada pela rede. O processo de *pooling* é feito convertendo os valores de uma vizinhança (normalmente  $2 \times 2$ ) em um único valor (Gonzales, 2018b). Esse procedimento normalmente é feito calculando o valor médio da vizinhança ou usando o seu valor máximo ou, até mesmo, calculando a raiz quadrada da soma de todos os valores da vizinhança. O processo de *pooling* dá origem ao mapa de características sub amostrado. De maneira simplificada, pode-se dizer que um mapa de características é o resultado da aplicação de um filtro na imagem, enquanto o mapa de características sub amostrado é a imagem filtrada com resolução reduzida.

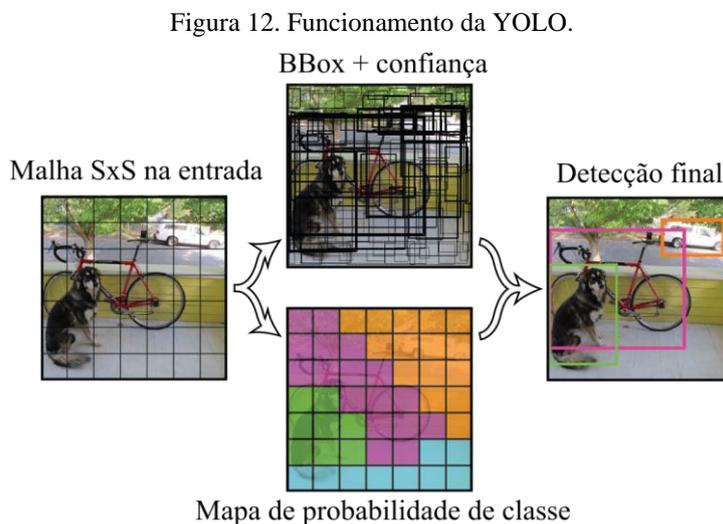
Nas RNA-C a classificação é realizada utilizando o resultado da última camada de *pooling* como entrada para uma RNA totalmente conectada. Como a entrada de uma rede desse tipo precisa ser um vetor e o mapa de características sub amostrado é uma imagem, realiza-se uma vetorização dessa imagem por indexação linear. Esse vetor é então propagado pela rede, que tem uma quantidade de saídas igual a quantidade de classes. Por fim, a classe inferida é aquela com o maior valor entre as saídas.

Atualmente, a principal aplicação das RNA-C está não só na classificação e reconhecimento de padrões em imagens, mas também na segmentação de objetos. Esse processo consiste em definir a qual classe pertence cada *pixel* em uma imagem. Isso pode ser feito por redes totalmente convolucionais, em que os mapas de característica primeiro são reduzidos e depois ampliados. Nessas redes, a saída tem as mesmas dimensões da imagem original, com cada *pixel* rotulado como pertencente a uma determinada classe (Gonzales, 2018b).

### **2.6.2. YOU ONLY LOOK ONCE (YOLO)**

O YOLO é um algoritmo de detecção de objetos baseado em RNA-C profundas e foi originalmente publicado por Redmon (2016). Trata-se de uma metodologia que unifica diferentes aspectos da detecção de objetos em um único modelo, de forma que a rede usa características da imagem inteira para prever cada caixa delimitadora (do inglês,

*Bounding Box*, BBox), além de prever todas as BBox simultaneamente. Isso permite inferências em tempo real com alto desempenho. O funcionamento resumido do algoritmo pode ser visto na Figura 12.

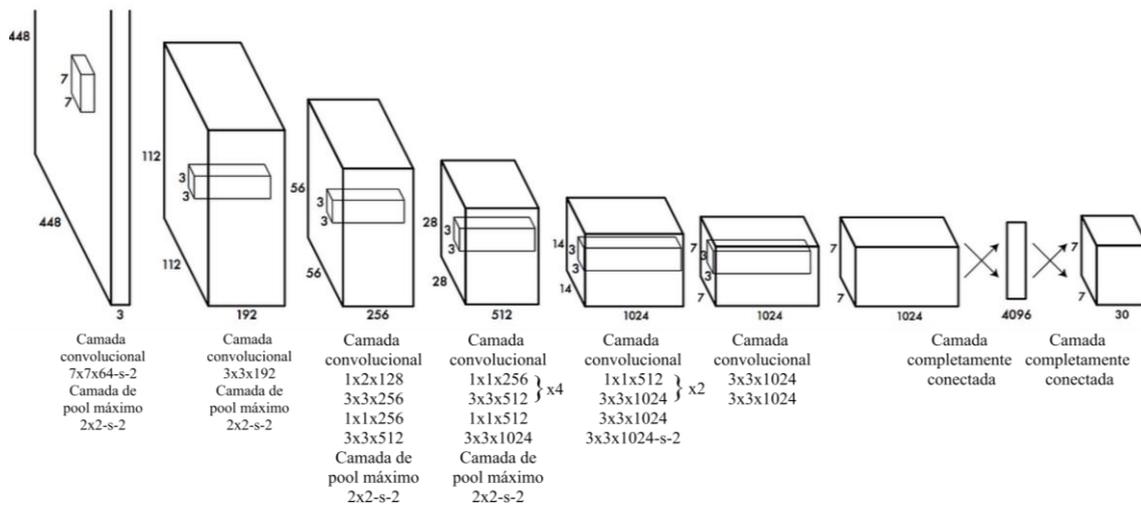


Fonte: adaptado de (Redmon, 2016).

O funcionamento do YOLO pode ser resumido a 3 etapas: redimensionar a imagem; propagar pela RNA-C; limiarizar as detecções resultantes a partir da confiabilidade fornecida pelo modelo.

A primeira etapa do algoritmo é dividir a imagem em uma malha de  $S \times S$  células, em que cada célula prevê uma quantidade de BBox e o fator de confiabilidade para apenas uma classe. As primeiras 24 camadas do modelo são convolucionais, enquanto as 2 últimas são camadas totalmente conectadas. As camadas convolucionais iniciais extraem as características da imagem enquanto as camadas totalmente conectadas preveem a probabilidade e coordenadas da BBox de saída. A arquitetura completa do modelo do YOLO pode ser vista na Figura 13.

Figura 13. Arquitetura do YOLO.



Fonte: adaptado de Redmon (2016).

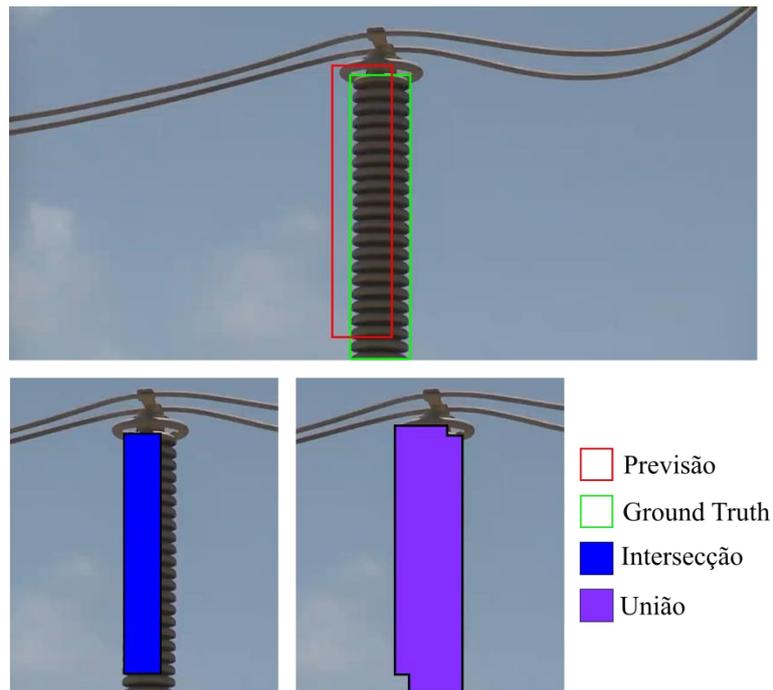
### 2.6.3. MÉTRICAS PARA AVALIAÇÃO DE MODELOS DE DETECÇÃO DE OBJETOS

Algoritmos de detecção de objetos geralmente realizam suas previsões por meio de BBox que indicam que, dentro delas, há o objeto de interesse. No processo de treinamento, é necessário um parâmetro para verificar se as BBox previstas estão em acordo com aquelas rotuladas. Utiliza-se, portanto, a intersecção sob a união (IoU, do inglês *Intersection over Union*), a qual pode ser calculada pela equação

$$IoU = \frac{\textit{intersection area}}{\textit{union area}} \quad (15)$$

Na Figura 14 está ilustrado o significado prático da *intersection area* e da *union area*. Um IoU de 0,5 indica que a previsão só será considerada como correta caso o IoU calculado seja igual ou maior que 0,5.

Figura 14. Ilustração da IoU a partir das BBox *ground truth* e previstas.



Fonte: autoria própria.

De maneira geral, o desempenho de um algoritmo de detecção de objetos é avaliado em termos de *Precision* ( $p$ ), *Recall* ( $r$ ) e *Mean Average Precision* ( $mAP$ ). A  $p$  quantifica o percentual de previsões corretas e pode ser calculado por:

$$p = \frac{PV}{PV + FP}, \quad (16)$$

em que PV é a quantidade de Positivos Verdadeiros, enquanto FP é a quantidade de Falsos Positivos. O  $r$ , por sua vez, quantifica o percentual de positivos encontrados.

$$r = \frac{PV}{PV + FN}, \quad (17)$$

em que FN é a quantidade de Falsos Negativos. A Average Precision (AP) é calculada a partir da área sob a curva do gráfico  $p \times r$ , que pode ser calculada por:

$$AP = \int_0^1 p(r) dr. \quad (18)$$

O  $mAP50$ , então, considera uma *IoU* de 0,5, enquanto o  $mAP50:95$  considera um resultado médio da variação de *IoU* de 0,5 a 0,95, com passos de 0,05.

## 2.6.4. TÉCNICAS DE EXPANSÃO ARTIFICIAL DA BASE DE TREINAMENTO

Uma desvantagem do uso de algoritmos de aprendizado profundo na detecção de objetos está na necessidade de uma grande base de dados para o treinamento. Além disso, o modelo está sempre condicionado à base, de forma que a detecção pode falhar para uma imagem com características distintas da base de treinamento, como por exemplo ângulo, iluminação e escala. O uso de modelos pré-treinados com bases grandes melhora essas problemáticas, mas sozinho não é o bastante.

A ampliação artificial da base de dados é uma etapa crítica no treinamento de modelos de aprendizado profundo. Ela envolve a geração de imagens derivadas da base original e tem o objetivo de melhorar o desempenho do modelo, tornando-o mais generalista e confiável. Existem diversas técnicas de ampliação artificial, como por exemplo modificação de cores, transformações afins, oclusões etc. (Mikolajczyk, 2018).

As transformações geométricas mais utilizadas na expansão de base de dados são: translação, escala, reflexão, rotação, inclinação e mosaico, com esta última sendo feita automaticamente pelo algoritmo de treinamento da YOLOv5 (Yarnell, 2022). Já as transformações de cores mais utilizadas são: mudança de brilho, mudança de saturação, equalização de histograma, conversão para tons de cinza, conversão para outros sistemas de cor além do RGB, binarização, supressão de canal de cor (Mikolajczyk, 2018). Algumas dessas transformações serão discutidas de forma mais aprofundada na Seção 2.7.

A base de dados também pode ser ampliada por meio de técnicas de oclusão de imagem, que consiste em ocultar intencionalmente parte da imagem. A seguir estão algumas das técnicas mais utilizadas de oclusão de imagens:

- a) Apagamento aleatório: consiste em substituir uma região aleatória da imagem por uma forma geométrica com *pixels* de intensidade aleatória.
- b) *Hide and Seek*: divide a imagem em uma matriz  $S \times S$  e apaga aleatoriamente algumas das regiões. Isso permite que o modelo aprenda a identificar um objeto sem precisar enxergá-lo por inteiro.
- c) Máscara em grade: oculta regiões da imagem seguindo uma grade pré-estabelecida. Semelhante ao *Hide and Seek*, isso força o modelo a aprender a reconhecer o objeto a partir de uma informação incompleta.
- d) Mistura: sobrepõe duas imagens e seus respectivos rótulos.

## 2.7. TRANSFORMAÇÕES DE IMAGENS

As transformações de cores e transformações geométricas são dois tipos de operações que podem ser aplicadas em imagens. As transformações de cores envolvem a alteração das cores de uma imagem, enquanto as transformações geométricas envolvem a alteração da posição dos *pixels* em uma imagem.

As transformações de cores podem ser realizadas através de sistemas de cores diferentes, como RGB, HSV, YUV e CMY, entre outros. As transformações geométricas incluem operações como translação, escala e rotação. Essas operações podem ser combinadas para criar efeitos especiais.

### 2.7.1. TRANSFORMAÇÕES DE CORES

As modificações de cores, ou distorções fotométricas, estão entre as técnicas mais usadas para expansão de base de dados. Além da fácil implementação, essas técnicas permitem que o modelo seja menos suscetível a erros provocados por mudanças de iluminação.

### 2.7.2. CONVERSÃO DE RGB PARA HSV

O sistema de cores HSV foi inventado por Alvy Ray Smith (1974) e é caracterizado por ser uma transformação não-linear do sistema de cores RGB. Trata-se de um espaço de cores composto por 3 componentes: matiz, saturação e valor. A matiz (*hue*), descreve o tipo de cor, abrangendo todo o espectro de cores. A saturação define a pureza da cor, em que uma saturação baixa resulta em uma tonalidade mais acinzentada, enquanto uma alta saturação resulta em uma cor mais viva. Por último, o valor define o brilho da cor.

Uma imagem em RGB pode ser convertida para o sistema HSV por meio do equacionamento apresentado a seguir. Primeiramente, deve-se normalizar os 3 canais de cor dividindo seus valores por 255, dando origem aos canais  $R'$ ,  $G'$  e  $B'$ . Calcula-se então a intensidade máxima ( $C_{máx}$ ) e mínima ( $C_{mín}$ ) entre os 3 canais por

$$C_{m\acute{a}x} = \max(R', G', B') \quad (19)$$

e

$$C_{m\acute{i}n} = \min(R', G', B'). \quad (20)$$

Em seguida, calcula-se a variao de intensidade por

$$\Delta = C_{m\acute{a}x} - C_{m\acute{i}n}. \quad (21)$$

O valor de matiz (H)  calculado seguindo o equacionamento a seguir:

$$H = \begin{cases} 60 \frac{G' - B'}{\Delta} + 0, & C_{m\acute{a}x} = R' \text{ e } G' \geq B' \\ 60 \frac{G' - B'}{\Delta} + 360, & C_{m\acute{a}x} = R' \text{ e } G' < B' \\ 60 \frac{B' - R'}{\Delta} + 120, & C_{m\acute{a}x} = G' \\ 60 \frac{R' - G'}{\Delta} + 240, & C_{m\acute{a}x} = B' \end{cases}. \quad (22)$$

A saturao (S)  calculada por:

$$S = \begin{cases} 0, & C_{m\acute{a}x} = 0 \\ \frac{\Delta}{C_{m\acute{a}x}}, & C_{m\acute{a}x} \neq 0 \end{cases} \quad (23)$$

O ltimo parmetro, o valor (V),  igual ao prprio  $C_{m\acute{a}x}$ . Os valores de H so expressos em graus e variam de 0 a 360, j os valores de S e V so expressos em porcentagem e variam de 0 a 255.

### 2.7.2.1. CONVERSO DE RGB PARA YUV

O espao de cor Y'UV, escrito normalmente como YUV, foi inventado no incio da televiso colorida. Sua criao foi motivada pelo desejo dos engenheiros de permitir que uma TV em preto e branco recebesse um sinal de transmisso colorido e fosse capaz de exibi-lo em preto e branco. Isso foi possvel pois a componente (Y')  o sinal em preto e branco em si, enquanto as componentes de crominncia (U e V) so as responsveis pela colorao da imagem.

Uma imagem RGB pode ser convertida para YUV por uma simples multiplicação de matrizes, conforme:

$$\begin{bmatrix} Y' \\ U \\ V \end{bmatrix} = \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ -0,1473 & -0,28886 & 0,436 \\ 0,615 & -0,51499 & -0,10001 \end{bmatrix} \begin{bmatrix} R' \\ G' \\ B' \end{bmatrix} \quad (24)$$

### 2.7.3. TRANSFORMAÇÕES GEOMÉTRICAS

As transformações geométricas modificam o arranjo espacial dos *pixels* em uma imagem. A transformação das coordenadas  $(x, y)$  de uma imagem em  $(x', y')$  pode ser expressa, genericamente, por (Gonzales, 2018b):

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = T \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} t_{11} & t_{12} \\ t_{21} & t_{22} \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix}, \quad (25)$$

em que  $T$  é uma matriz de transformação genérica.

Realizar operações de transformação geométrica em coordenadas homogêneas permite que a operação de translação seja feita como operação linear, o que permite a combinação dessa operação com as outras em uma única multiplicação de matrizes. Para isto basta substituir o vetor  $(x, y, 1)$  por uma matriz de dimensões  $3 \times N$ , em que  $N$  é o número de *pixels* da imagem. Essa matriz deve ser o resultado da concatenação de todas as coordenadas  $(x, y, 1)$  da imagem. Essa operação pode ser definida genericamente a partir da matriz de transformação. Dessa forma, obtém-se as novas coordenadas  $(x', y', 1)$  a partir da equação:

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = A \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}. \quad (26)$$

Para translação o valor de  $A$  é:

$$A = \begin{bmatrix} 1 & 0 & t_x \\ 0 & 1 & t_y \\ 0 & 0 & 1 \end{bmatrix}, \quad (27)$$

em que  $t_x$  é o deslocamento no eixo  $x$  e  $t_y$  é o deslocamento no eixo  $y$ . Já para a operação de escala ou reflexão o valor de  $A$  é:

$$A = \begin{bmatrix} c_x & 0 & 0 \\ 0 & c_y & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad (28)$$

em que  $c_x$  é o fator de escala no eixo  $x$  e  $c_y$  é o fator de escala no eixo  $y$ . Para a reflexão basta definir um fator de escala para  $-1$  e o outro para  $1$  (Gonzales, 2018b). Para rotacionar a imagem em  $\theta$  graus em relação a origem o valor de  $A$  deve ser:

$$A = \begin{bmatrix} \cos(\theta) & -\sin(\theta) & 0 \\ \sin(\theta) & \cos(\theta) & 0 \\ 0 & 0 & 1 \end{bmatrix}. \quad (29)$$

Já para a inclinação no eixo horizontal e vertical, respectivamente, o valor de  $A$  deve ser:

$$A = \begin{bmatrix} 1 & S_v & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (30)$$

e

$$A = \begin{bmatrix} 1 & 0 & 0 \\ S_h & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}. \quad (31)$$

### 3. REVISÃO BIBLIOGRÁFICA

O monitoramento por imageamento UV é a principal ferramenta para detectar as descargas corona em LT e SE. A dificuldade está, contudo, na interpretação do UV representado por fâculas. Nesse contexto, existem casos em que a detecção é clara e o operador da câmera é capaz de diagnosticar o problema de maneira intuitiva. No entanto, para muitos casos, as filmagens são inconclusivas e não permitem deduzir a real natureza da descarga monitorada. Para contribuir com esse aspecto, diversas pesquisas foram desenvolvidas com o objetivo de facilitar ou até mesmo automatizar a interpretação dessas filmagens.

A seguir, está apresentada uma revisão bibliográfica em ordem cronológica referente ao monitoramento de equipamentos elétricos de alta tensão por imageamento UV. Os trabalhos estão organizados em ordem cronológica.

Guedes (2015) propôs um método de classificação da condição operacional de isoladores poliméricos a partir do imageamento UV. Foram usados 9 isoladores de 230 kV com diferentes níveis de degradação. Aplicaram-se métodos de PDI nos vídeos para reduzir o ruído e extrair apenas os 10 quadros com maior registro de descarga. Para a classificação, foi proposto um sistema Fuzzy que diferencia os isoladores em 3 grupos conforme seus níveis de degradação. Esses grupos são: novo, desgaste médio e crítico. Para cada ensaio, cada isolador foi filmado pela câmera UV a partir de 3 ângulos diferentes. O método de classificação proposto apresentou resultados em conformidade com a real condição dos isoladores ensaiados. O estudo, porém, foi realizado apenas em laboratório e não considerou condições práticas, como por exemplo, descargas que se originam em outros equipamentos. Além disso, as características do UV registrado não foram amplamente exploradas, como por exemplo, sua persistência.

Zhang (2016) apresentaram uma contribuição relevante ao monitoramento de isoladores por imageamento UV. Os autores avaliaram o efeito do ganho e da distância de captura das imagens com a quantidade de fótons registrados e a área de fâcula. Nos ensaios, um único isolador polimérico (FCBW - 35/70) foi submetido a uma tensão de 180 kV enquanto a presença de UV foi detectada pela câmera *DayCor Superb*. O ganho do equipamento foi variado entre 110% e 170% e 3 distâncias entre a câmera e o isolador foram adotadas (8 m, 10 m e 12 m). O número de fótons registrados em cada quadro dos vídeos é fornecido pela própria câmera e, adotou-se como referência o número médio de fótons dentre os quadros. Já a área de fâcula precisou ser extraída por processamento digital de imagens. Este processo passa pelas seguintes etapas: conversão das imagens para tons de cinza; ajuste de contraste para diferenciar ainda mais as fâculas do fundo; binarização das imagens; morfologia matemática para eliminar ruído. Com esse processo aplicado a cada quadro das filmagens, adotou-se a área média de fâculas dentre os quadros como referência. Os autores concluíram que ambos os parâmetros – número de fótons e área de fâcula – podem ser usados para estimar a intensidade das descargas corona. Contudo, afirmaram que a área de fâcula tem melhor desempenho nesse quesito.

Ribeiro (2017) desenvolveu uma metodologia para o aprimoramento da classificação de isoladores poliméricos por medições termográficas e radiação UV. Os isoladores foram submetidos a uma tensão de 133 kV por 30 minutos e, em seguida,

passaram por uma inspeção termográfica e foram filmados por uma câmera UV. Algoritmos de PDI foram usados para extrair as informações de densidade de UV, persistência e distância até o isolador. Para a segmentação das fâculas foi utilizado o método de Otsu e, para a classificação, foi proposta uma RNA capaz de diferenciar o nível de degradação dos equipamentos. Concluiu-se que o uso da termografia associada ao imageamento UV resulta numa assertividade maior na classificação com relação ao uso dessas técnicas de maneira independente. No entanto, o método para o cálculo da distância entre a origem de fâculas e o isolador não é automatizado e pode apresentar uma margem de erro relevante.

Jin (2017) utilizaram imagens multiespectrais - visível, infravermelho e ultravioleta - para estimar o nível de poluição de isoladores de média tensão. Ao todo, foram realizadas 4 rodadas de ensaios. Em cada uma delas, 5 isoladores poluídos com diferentes níveis de densidade de depósito de sal equivalente (ESDD, do inglês *Equivalent Salt Deposit Density*) e foram submetidos a tensão de 10 kV e a 5 níveis de umidade relativa. Durante esses ensaios, os isoladores foram fotografados por uma câmera digital e por uma câmera infravermelha e filmados por uma câmera UV por 1 minuto. Em cada rodada de ensaios, o nível de poluição dos isoladores foi modificado. Para fundir e simplificar os dados obtidos nos ensaios, um parâmetro de cada componente espectral foi escolhido. Para a luz visível, a imagem foi convertida para HSV e foi utilizado o valor médio do canal V desse sistema de cor. Para o infravermelho, utilizou-se o valor máximo de temperatura registrado. Para o UV, foram extraídos 200 quadros do vídeo e foi utilizada a área máxima de fâculas registrada. O critério de Fisher foi usado para definir pesos para as imagens de cada espectro, de forma a identificar características com baixa variância interclasse e grande variância entre classes. Adicionalmente, aplicou-se um algoritmo de fusão de imagens multiespectrais baseado nesses pesos variáveis. Os resultados demonstraram que a metodologia proposta no artigo foi superior a um modelo de RNA clássico na previsão dos valores de ESDD tendo como entrada imagens multiespectrais. Além disso, investigaram-se diversas combinações entre os espectros de imagem e concluiu-se que o menor erro médio ( $0,0125 \text{ mg/cm}^3$ ) é atingido quando os 3 espectros são combinados.

Em Florentino (2019) foi realizada a caracterização operacional de isoladores poliméricos a partir de parâmetros extraídos por PDI. Os isoladores foram ensaiados enquanto monitorava-se a emissão de descarga corona por uma câmera UV e por detecção de descargas parciais. Inicialmente, foram estudados os principais parâmetros de captação

da câmera UV (ganho e distância de captação) e avaliada a sensibilidade dos atributos da imagem à variação desses parâmetros. Em seguida, investigaram-se as seguintes características do UV captado pela câmera: área da fâcula integrada; distribuição média de *pixel*/quadro; persistência; número de objetos/quadro; mapa de persistência; contagem de fótons/minuto. Foi possível obter correlações seguras entre os atributos da descarga corona, tanto da imagem quanto dos pulsos, e as condições operacionais dos isoladores, de forma que é possível quantificar as descargas corona com o auxílio da parametrização das imagens UV. Além disso, o autor introduziu ao estado da arte o conceito de mapa de persistência como meio de caracterização de descargas corona. O escopo desse estudo, no entanto, foi limitado a ensaios laboratoriais, de maneira que não foram levados em conta aspectos da aplicação da câmera UV em campo.

Davari (2020) desenvolveu um algoritmo de diagnóstico de falha incipiente em equipamentos de alta tensão baseado no imageamento UV. Os equipamentos são filmados por meio de uma câmera UV (CoroCam 6D2) e, em seguida, são identificados por meio de um algoritmo baseado em aprendizado de máquina (Faster R-CNN). O filtro da mediana é então usado para eliminar o ruído e a presença de descargas parciais é quantificada. A severidade das descargas é classificada a partir da razão entre a área das fâculas e a área da região de interesse, em que foi definido que para uma relação abaixo de 5%, tem-se uma severidade considerada normal, entre 5% e 15% é considerada grave e acima de 15% é considerada crítica. As inspeções foram realizadas ao longo de um ano em linhas de distribuição de 11 kV e 13 kV. Dentre os equipamentos monitorados, destacam-se: isoladores, cabos, para-raios e transformadores. Os pesquisadores realizaram, ao todo, 900 filmagens com duração média de 20 segundos. O Faster R-CNN foi treinado a partir de 1480 imagens, cujo conteúdo englobava, ao todo, 13985 objetos de interesse. Também foi desenvolvida uma metodologia para seguir o equipamento de interesse no vídeo, o que evita erros causados pelo movimento da câmera. Os resultados demonstraram a viabilidade do algoritmo como forma de automatizar o processo de detecção de defeitos em linhas de distribuição. O método de detecção de equipamentos obteve destaque devido a sua boa precisão, superior a 70%. Por outro lado, a forma de avaliar a severidade da descarga corona foi pouco robusta e pode ser melhorada.

Britto (2021) aplicou técnicas de PDI para a extração de características do imageamento UV de isoladores poliméricos (230 kV). A primeira etapa da metodologia é segmentar o isolador na imagem por meio do método de Otsu. Em seguida, as fâculas são extraídas e somadas quadro a quadro. Aplica-se então, operações morfológicas a fim

de eliminar o ruído da etapa anterior. Por fim, calcula-se os seguintes parâmetros da manifestação UV integradas: área, persistência, fator de forma e perímetro. Os resultados então são normalizados e apresentados na forma de um gráfico de radar. Os autores demonstraram que a sumarização proposta é capaz de simplificar o diagnóstico da condição de operação dos equipamentos. Contudo, os parâmetros extraídos não são os mais adequados para avaliar a criticidade das descargas, visto que a área e perímetros são fortemente correlatos e o fator de forma não tem forte correlação com a gravidade da descarga. Além disso, o método de segmentação do isolador proposto é pouco confiável e tende a falhar em condições práticas.

Na Tabela 1 está um comparativo entre os trabalhos abordados nesta revisão bibliográfica e a pesquisa apresentada nesta dissertação. Alguns campos foram marcados como “feito parcialmente”, pois, apesar do autor ter apresentado a contribuição, a técnica usada não apresentou significativa robustez. Por exemplo, a segmentação do isolamento com método de Otsu, que funciona apenas em condições muito específicas.

Tabela 1. Planilha de revisão bibliográfica.

Referência	Contribuições						
	1	2	3	4	5	6	7
Guedes (2015)		✓		✓			✓
Zhang <i>et al</i> (2016)		✓					
Ribeiro (2017)		✓	✓	✓	✓		✓
Jin <i>et al</i> (2017)		✓					✓
Florentino (2019)		✓					✓
Davari e <i>et al</i> (2020)	✓	✓	✓		✓		✓
Britto <i>et al</i> (2021)		✓	✓	✓			
Esta dissertação (2023)	✓	✓	✓	✓	✓	✓	✓

1. Realizou inspeções em campo
2. Extraíu atributos das imagens UV
3. Detectou o isolamento
4. Segmentou o isolamento
5. Quantificou a distância entre as origens de fâcula e o isolamento
6. Realizou uma análise por origem de fâcula
7. Desenvolveu uma metodologia de classificação

✓	Feito	✓	Feito parcialmente
---	-------	---	--------------------

Fonte: autoria própria.

Destacam-se como contribuições importantes desta dissertação o uso de imagens UV feitas em campo sob condições reais, a análise de cada origem de fâcula de forma independente, a detecção/segmentação dos isolamentos a partir de um método resiliente e, por fim, a quantificação da distância entre as origens de fâcula e os isolamentos. Ainda dentro do escopo desta dissertação, alguns pesquisadores também desenvolveram algoritmos para detectar e/ou segmentar isoladores. A seguir, estão apresentados dois trabalhos com essa temática, mas que não tratam especificamente de imageamento UV.

Sampedro (2019) desenvolveram um sistema de algoritmos baseados em *deep learning* capazes de segmentar cadeias de isoladores, a partir de fotografias, e detectar defeitos nos seus discos. Para o processo de segmentação foi usada uma rede totalmente convolucional (Up\_Net\_vgg16) treinada a partir de uma base de dados contendo 160 imagens de cadeias de isoladores, expandida artificialmente para 1920 imagens. Em seguida, um algoritmo de VC foi usado para corrigir a orientação da cadeia, verticalizando-a. Por fim, duas redes distintas são usadas para detectar potenciais defeitos. A primeira é uma RNA-C (CNN3\_7x7) que busca detectar a ausência de um ou mais discos na cadeia. Essa rede foi treinada com 2400 imagens, metade de cadeias normais e metade com cadeias que tiveram discos removidos computacionalmente. Já para o diagnóstico de discos danificados, aplicou-se uma RNA-C siamesa (SCNN-c4-L1\_vgg16). Essa rede foi treinada a partir de uma base de dados com 579 discos íntegros e 18 discos danificados, que foi expandida artificialmente para 802 discos íntegros e 95 discos danificados. Além disso, mais 762 imagens de discos defeituosos foram criadas por *photoshop* para complementar a base. As três arquiteturas de rede escolhidas pelos autores foram resultado de um detalhado estudo que comparou a performance de diversas arquiteturas distintas. A precisão do algoritmo de detecção de disco ausente foi de 97%, enquanto a precisão do algoritmo de detecção de defeitos foi igual a 89%.

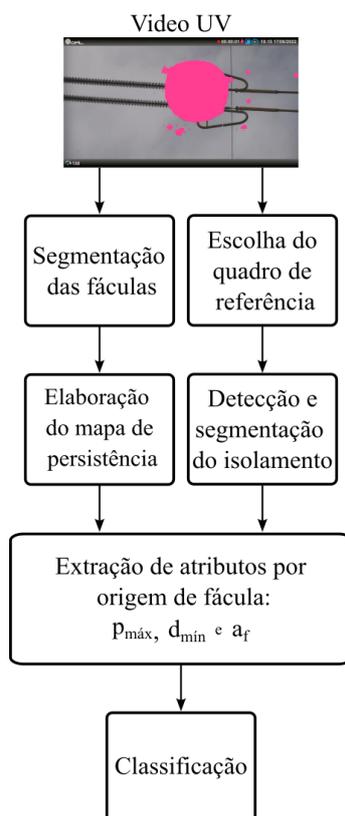
Wang (2020) desenvolveu uma metodologia automatizada de diagnóstico de defeitos em isoladores a partir de imagens infravermelhas. Primeiramente, os autores aplicaram uma rede Mask R-CNN para realizar a segmentação dos isoladores na imagem. Foi usada, especificamente, uma rede pré-treinada com 300.000 imagens, contendo 2.000.000 de objetos divididos em 80 categorias. Em seguida, essa rede foi treinada novamente usando 1200 imagens de isoladores cerâmicos, em que 1000 foram usadas para o treinamento propriamente dito, 100 foram usadas para verificação e 100 para teste. O passo seguinte do algoritmo foi converter as imagens térmicas em imagens em escala de cinza, em que a intensidade de cada *pixel* é proporcional à temperatura registrada

naquele *pixel*. Com esses dados, os autores desenvolveram um sistema de decisão que compara a temperatura máxima do isolador com uma temperatura normalizada e classifica a criticidade do equipamento em 4 categorias. A rede responsável pela segmentação apresentou precisão igual a 90,4% e a conversão para escala de cinza teve erro de apenas 6,6%. Já o algoritmo de diagnóstico de falha foi submetido a apenas um teste com um isolador defeituoso e foi capaz de corretamente classificar o seu tipo de defeito. Os autores ainda precisam aplicar a metodologia proposta a uma maior variedade de isoladores íntegros e defeituosos, a fim de validá-la amplamente.

## 4. METODOLOGIA

A metodologia proposta usa técnicas de PDI e VC para extrair parâmetros das filmagens e usá-los na classificação automática da condição do isolamento. No diagrama de blocos da Figura 15 é descrita, de forma geral, a metodologia proposta.

Figura 15. Diagrama de blocos da metodologia.



Fonte: autoria própria.

A partir do vídeo são extraídas as fâculas quadro a quadro, dando origem a um vídeo que contém apenas a informação UV. Os quadros desse novo vídeo são somados e passam por um processamento para compor um mapa de persistência, o qual agrega toda a informação UV do vídeo em uma única imagem.

Paralelamente, escolhe-se o quadro de referência e aplica-se a metodologia proposta de detecção e segmentação do isolamento. Com o isolamento localizado na imagem e o mapa de persistência construído, extraem-se os parâmetros de interesse e cada origem da fâcula detectada é classificada. Esses parâmetros são: persistência máxima

( $p_{max}$ ), área de fábula ( $a_f$ ) e distância mínima entre a origem da fábula e o isolamento ( $d_{min}$ ).

Os 96 vídeos usados nessa pesquisa foram registrados por uma câmera DayCor Luminar HD e possuem em torno de 30 segundos de duração (750 quadros). As gravações foram feitas em uma SE de 500 kV pertencente à UTEPSI, de propriedade da ENEVA S.A; na cidade da Barra dos Coqueiros (Brasil).

## 4.1. EXTRAÇÃO DE FÁCULAS

A câmera é configurada para exibir as fábula na cor magenta, por ser uma cor dificilmente presente em SE, possibilitando a extração por limiar de cor quadro a quadro de modo simplificado a partir do uso dos seguintes limiares:

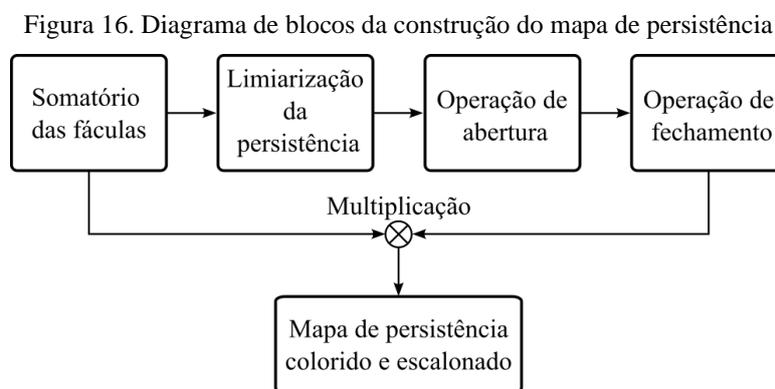
- $R \geq 200$ ;
- $G \leq 100$ ;
- $130 \leq B \leq 160$ .

Com isso, obtêm-se as matrizes de fábula ( $F_j$ ), que são matrizes binárias em que os *pixels* de fábula são tomados como 1 e os *pixels* sem fábula como 0. A letra  $j$  representa o quadro do vídeo. Esse procedimento é realizado quadro a quadro e cada matriz  $F_j$  é salva compondo um novo vídeo, que contém apenas a informação do UV do vídeo original.

O quadro de referência ( $im_{ref}$ ) é aquele com menor registro de *pixels* de fábula, tipicamente zero. Um detalhe prático importante é desconsiderar os primeiros segundos do vídeo, pois o ato de apertar o botão para iniciar a filmagem balança levemente a câmera, o que faz com que os primeiros quadros do vídeo possam ser ligeiramente diferentes do restante.

## 4.2. ELABORAÇÃO DO MAPA DE PERSISTÊNCIA

O mapa de persistência é construído a partir de um processo de integralização, que agrega toda a informação do vídeo em uma única imagem e fornece informações relevantes do UV detectado, permitindo a sumarização das características dispersas no vídeo em um só resultado visual. Na Figura 16 está ilustrado um diagrama de blocos do algoritmo de construção do mapa de persistência.



Fonte: autoria própria.

A primeira etapa é obter a matriz de persistência ( $M_P$ ) somando as matrizes  $F_j$ . Conforme a equação:

$$M_P = \sum_{j=1}^{N_{frames}} F_j, \quad (32)$$

em que  $N_{frames}$  é o número de quadros no vídeo.

A matriz  $M_P$  passa, então, por um processo de limiarização que binariza seus valores de maneira que todo *pixel* com persistência maior que 2% do valor de  $N_{frames}$  recebe valor 1 e o restante valor 0. A matriz booleana resultante ( $M_{bool}$ ) passa por duas operações morfológicas em sequência, abertura e fechamento, com elemento estruturante com formato de disco com dimensão  $15 \times 15$  *pixels*. Por fim, multiplica-se  $M_P$  por  $M_{bool}$ , ponto a ponto, resultando na matriz de persistência ( $M_{origens}$ ) em que as origens de fâcula ficam separadas entre si e melhor destacadas. Para fins de visualização, escalona-se

$P_{origens}$  de (0 a  $N_{frames}$ ) para (0 a 255) e aplica-se um mapa de cores para facilitar a interpretação dos resultados, dando origem a imagem do mapa de persistência ( $Im_{map}$ ).

O mapa de persistência é composto por regiões que representam a detecção de UV ao longo do vídeo. Define-se o termo “origem de fâcula” como o ponto de maior persistência em cada uma dessas regiões. Pela própria natureza do fenômeno, a origem de fâcula tende a ser próxima ao centroide da sua respectiva região. Em muitos casos, a origem de fâcula também coincide com a origem das descargas corona, contudo, é imprudente tomar isso como regra. Afirma-se, portanto, que a origem de fâcula é um palpite aproximado da origem real das descargas.

### 4.3. DETECÇÃO COM A RNA-C

Nesta dissertação foi utilizada o YOLOv5 como modelo de RNA-C para a detecção dos isolamentos nas imagens. Trata-se de uma versão aprimorada do modelo original do YOLO, que foi adotada por ser o estado da arte na detecção de objetos, tanto em termos de velocidade de processamento quanto em precisão. Na Tabela 2 constam os equipamentos considerados e as peças detectadas pela rede.

Tabela 2. Peças detectadas por equipamento elétrico.

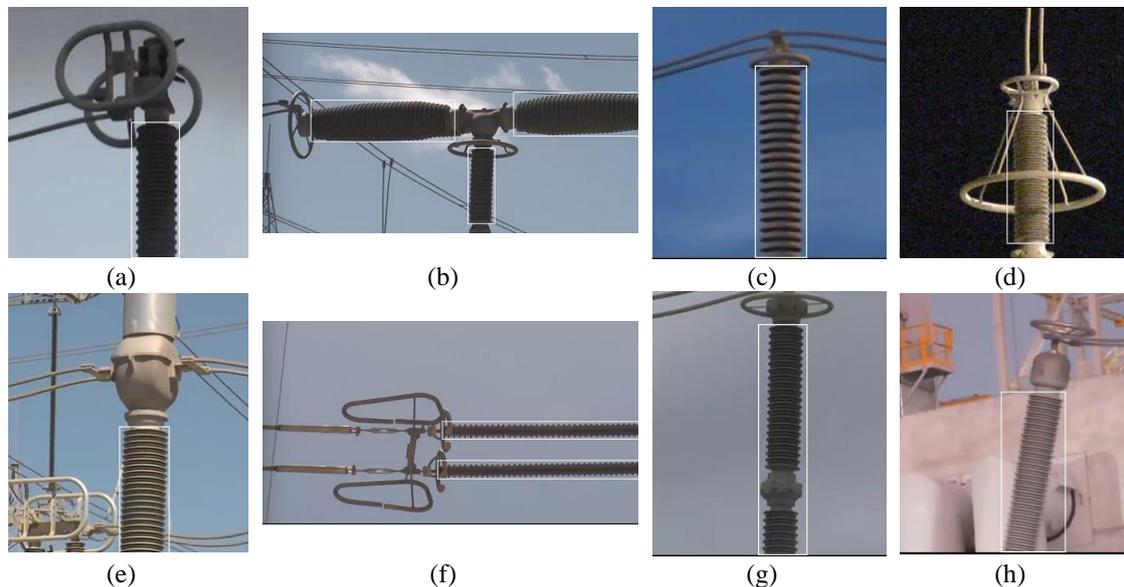
Sigla	Nome do equipamento	Peça detectada
CH	Chave seccionadora	Coluna isolante
DI	Disjuntor	Coluna isolante e bucha
IS	Isolador de suspensão	Polímero
IP	Isolador de pedestal	Coluna isolante
PR	Para-raios	Coluna isolante
TP	Transformador de potencial	Coluna isolante
TC	Transformador de corrente	Coluna isolante
TR	Transformador de potência	Bucha

Fonte: autoria própria.

A base de dados para treinamento foi construída a partir de imagens de 3 origens distintas: quadros de vídeos UV, fotos de câmera digital e imagens térmicas feitas com o

termovisor FLIR T840. Essas imagens tiveram seus isolamentos rotulados por BBox na plataforma *online* makesense.ai, na Figura 17 podem ser vistos exemplos de rotulação.

Figura 17. Exemplos de rotulação do isolamento equipamentos elétricos.  
(a) CH. (b) DI. (c) IP. (d) PR. (e) TC. (f) IS. (g) TP. (h) TR.



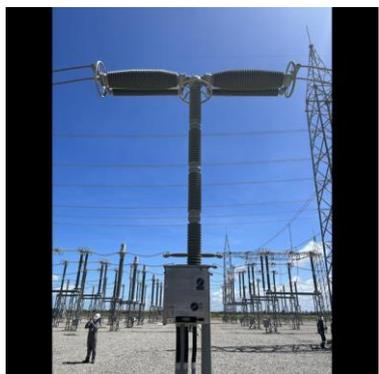
Fonte: autoria própria.

A base de imagens disponível para o treinamento da rede era composta de 2.839 termografias, 3.329 imagens de câmera digital e 452 quadros de vídeos da câmera UV, totalizando 6.620 imagens. Essa base foi dividida aleatoriamente na proporção de 70/30 para treinamento e validação. Para expandir artificialmente a base de treinamento, cada uma das 4.635 imagens foi rotacionada nos ângulos de 60°, 120°, 180°, 240° e 300°, dando origem a 5 novas imagens. Em seguida, aplicou-se uma das seguintes técnicas de transformação de cores em cada uma das imagens: binarização; conversão para tons de cinza; conversão para HSV; conversão para YUV; exclusão do canal vermelho; exclusão do canal verde; exclusão do canal azul.

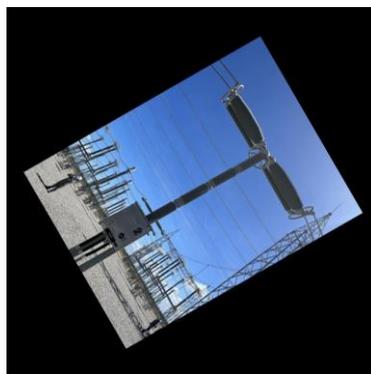
Na Figura 18 estão apresentados exemplos da aplicação das técnicas usadas de ampliação artificial da base de dados. Ressalta-se que a distorção das imagens convertidas para HSV e YUV ocorre pois elas estão sendo exibidas como se fossem RGB. Essa distorção é, portanto, proposital e proporciona uma rede mais generalista após o treinamento.

Figura 18. Exemplos de técnicas de expansão artificial de base de dados.

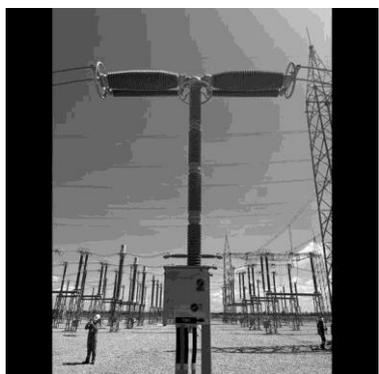
(a) Imagem original de um disjuntor. (b) Imagem rotacional 60°. (c) Imagem em tons de cinza. (d) Imagem em HSV. (e) Imagem em YUV. (f) Canal vermelho suprimido. (g) Canal verde suprimido. (h) Canal azul suprimido. (i) Binarização. (j) Binarização de imagem rotacionada 60°



(a)



(b)



(c)



(d)



(e)



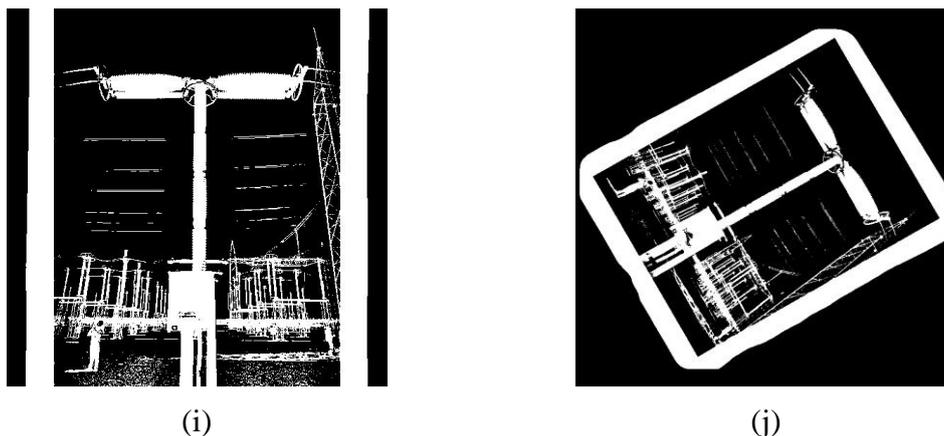
(f)



(g)



(h)



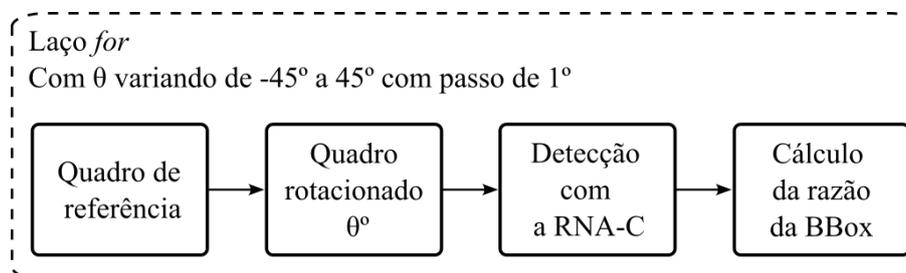
Fonte: autoria própria.

Desta forma, obteve-se uma base com 48.800 imagens para treinamento e 1.985 para validação, o que totaliza 6,12 GB de dados. A YOLOv5, pré-treinada com a base COCO<sup>1</sup>, foi então treinada com essa base expandida para 300 épocas. O treinamento foi realizado localmente em uma máquina com processador Intel(R) 12th Gen Core (TM) i7-12650H (2.70 GHz), memória RAM de 16 GB e placa de vídeo NVIDIA GeForce RTX 3070 Ti (8 GB).

#### 4.4. SEGMENTAÇÃO DOS ISOLAMENTOS

A segmentação dos isolamentos na imagem está dividida em duas etapas. No diagrama de blocos apresentado na Figura 19 está ilustrado o algoritmo da primeira etapa.

Figura 19. Diagrama de blocos da primeira etapa da segmentação.



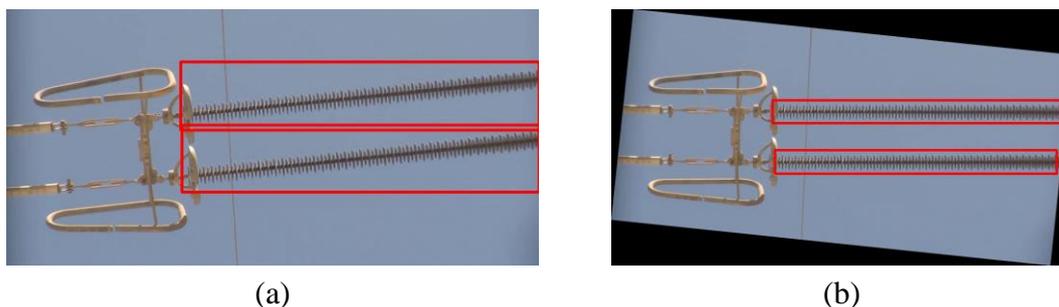
Fonte: autoria própria.

<sup>1</sup> A base de imagens Microsoft COCO (do inglês, Common Objects in Context) possui 328 mil imagens com um total 2,5 milhões de instâncias rotuladas, entre 91 classes distintas. As classes são objetos e animais comuns do dia a dia em um contexto típico. Essa base é amplamente utilizada em pesquisas de detecção de objetos e segmentação (LIN, 2014).

Rotaciona-se o quadro de referência em  $\theta$  graus e realiza-se a detecção com a RNA-C. Em seguida, é calculada a razão entre os lados da BBox detectada com maior confiabilidade. Esse processo é repetido para valores de  $\theta$  de  $-45^\circ$  a  $45^\circ$  com passo de  $1^\circ$  dentro de um laço *for*. Por fim, seleciona-se o ângulo em que a razão entre o maior e menor lado da BBox foi máximo. O objetivo desta etapa é encontrar o ângulo de rotação que deixa o isolamento na posição mais horizontal ou vertical possível. Isso é vantajoso pois as BBox possuem apenas linhas retas, ou seja, detectar isolamentos inclinados é desvantajoso, visto que a BBox passa a ocupar uma área desnecessariamente grande, o que aumenta a incidência de erros na etapa posterior.

Na Figura 20 está ilustrado um exemplo do potencial desse algoritmo. Nesse caso, o ângulo de rotação que maximizou a razão entre os lados da BBox foi de  $22^\circ$ . Comparando as imagens, fica clara a vantagem do algoritmo proposto, as BBox da Figura 20b estão muito mais ajustadas ao isolamento que as da Figura 20a.

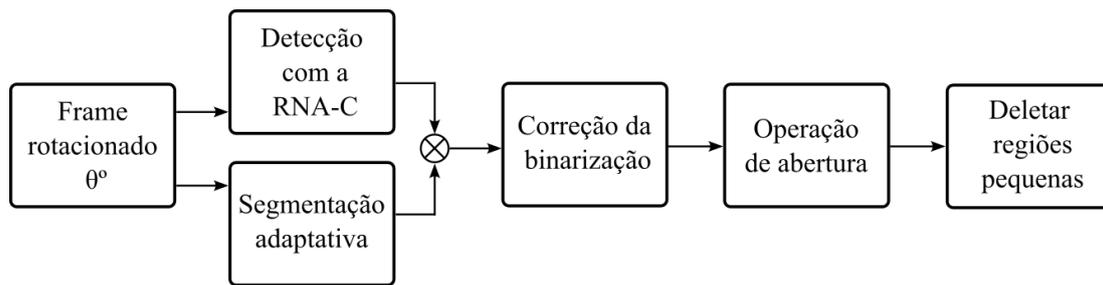
Figura 20. Ilustração da primeira etapa da segmentação. (a) Detecção dos isolamentos na imagem original. (b) Detecção dos isolamentos na imagem com rotação ideal.



Fonte: autoria própria.

Na Figura 21 consta um diagrama de blocos da segunda etapa do algoritmo. Nesta etapa, o quadro de referência rotacionado no ângulo selecionado pela etapa anterior passa pela segmentação adaptativa da média. Os resultados dessa operação é multiplicado pelo resultado da detecção com a RNA-C, o que resulta na imagem dos isolamentos segmentados ( $im_{seg}$ ). Para corrigir possíveis problemas, duas operações são aplicadas, a correção da binarização, que faz uma operação NOT caso o resultado anterior esteja invertido (fundo branco e isolamento preto). Por fim, aplica-se a operação morfológica de abertura e, na sequência, apagam-se todas as regiões muito pequenas em  $Im_{seg}$ .

Figura 21. Diagrama de blocos da segunda etapa da segmentação.



Fonte: autoria própria.

## 4.5. PARAMETRIZAÇÃO

A partir das filmagens e tomando como base as diferentes origens de fâcula destacadas em  $F_{origens}$ , são extraídos os seguintes parâmetros por origem  $k$ :  $p_{máx}$ ,  $a_f$  e  $d_{mín}$ .

Para calcular  $d_{mín}$ , primeiro a matriz  $P_{bool}$  deve ser dividida em regiões por vizinhança 8. Cada uma dessas  $k$  regiões é interpretada como oriunda de uma origem diferente de descarga corona. Dessa forma, localizam-se as coordenadas  $(x_k, y_k)$  do *pixel* de maior persistência de cada região. A distância  $d(k, r)$  entre esse *pixel* e um *pixel* qualquer ( $r$ ) em  $im_{seg}$  é calculada pela equação da distância euclidiana, conforme:

$$d(k, r) = \sqrt{(x_r - x_k)^2 + (y_r - y_k)^2} \quad (33)$$

em que  $(x_r, y_r)$  são as coordenadas de um *pixel* qualquer em  $im_{seg}$  cujo valor é igual a 1. O menor valor da distância entre a origem de fâcula e o isolamento  $d_{mín}(k)$  é o menor valor de  $d(k, r)$  obtido aplicando a equação (33) para todos os *pixels* iguais a 1 em  $im_{seg}$ . Como no mapa de persistência pode haver múltiplas origens de fâcula, esse procedimento deve ser repetido para cada uma delas.

O valor da  $p_{máx}$  por origem de fâcula  $k$  é igual ao valor máximo de cada região na matriz  $F_{origens}$  e é expresso em número de quadros. Já o valor da  $a_f$  por origem  $k$  é a quantidade de *pixels* em cada uma dessas regiões. Normaliza-se  $p_{máx}$  dividindo seu valor por  $N_{frames}$  e multiplica-se por 100 para obter o resultado em termos de porcentagem.

Para facilitar a interpretação dos resultados o valor de  $d_{mín}$  é convertido para centímetros. Como a largura dos isolamentos de cada equipamento é conhecida, é

possível calcular em  $im_{seg}$  a largura (em *pixels*) do isolamento mais próximo de uma determinada origem de fâcula. A partir da proporção dessa largura em *pixels* e em centímetros converte-se a  $d_{min}$  calculada para centímetros.

De maneira similar, a  $a_f$  é convertida para centímetros quadrados. Para isso, o valor da largura do isolamento em centímetros e em *pixels* é elevada ao quadrado e calcula-se a razão. Essa proporção é usada para converter a  $a_f$  de cada região do mapa de persistência para centímetros quadrados. Essa conversão por si só reduz a influência da distância de captação do vídeo no resultado da classificação, visto que a amplitude da radiação UV é inversamente proporcional ao quadrado da distância entre a fonte geradora e o observador.

Nota-se que essas conversões para centímetros e centímetros quadrado partem do pressuposto que a origem de fâcula e o isolamento estão a mesma distância da câmera no momento da filmagem. Evidentemente, esse pressuposto nem sempre é atendido, contudo, as descargas de interesse são aquelas que, de fato, então próximas ao isolamento. Sendo assim, os erros provocados por essa conversão, apesar de poderem ser numericamente expressivos, não serão qualitativamente significantes para a grande maioria dos casos.

Existem técnicas e ferramentas de calibração de câmera que permitem uma estimativa mais precisa das dimensões de objetos em imagens e vídeos (FAN, 2023). No entanto, essas técnicas mais avançadas não puderam ser aplicadas por fugirem do escopo desta dissertação.

## 4.6. CLASSIFICAÇÃO

Como a metodologia proposta nessa dissertação é capaz de extrair informações valiosas do vídeo e agregar contexto ao efeito corona monitorado, é possível realizar uma classificação baseada apenas em limiares condicionais. Para cada um dos três parâmetros foram estabelecidas 3 faixas de valores (0, 1 e 2) e foi proposto um esquema condicional que relaciona cada combinação de faixas a uma classificação. As faixas estabelecidas para cada parâmetros são:

$$P = \begin{cases} 0, & p_{max} < 2\% \\ 1, & 2\% \leq p_{max} < 30\% \\ 2, & p_{max} \geq 30\% \end{cases} \quad (34)$$

$$A = \begin{cases} 0, & a < 150 \text{ cm}^2 \\ 1, & 150 \text{ cm}^2 \leq a < 2000 \text{ cm}^2 \\ 2, & a \geq 2000 \text{ cm}^2 \end{cases} \quad (35)$$

$$D = \begin{cases} 0, & d > 25 \text{ cm} \\ 1, & 25 \text{ cm} \geq d > 10 \text{ cm} \\ 2, & d \leq 10 \text{ cm} \end{cases} \quad (36)$$

Para a classificação, foram definidos 5 casos, dois deles referem-se a situações em que não há corona registrado próximo ao isolamento e os outros 3 contemplam diferentes graus de criticidade de corona.

- **Caso 1:** Não houve detecção significativa de corona.
- **Caso 2:** Houve detecção de corona, mas a origem da descarga está distante do isolamento.
- **Caso 3:** Houve detecção de corona próxima ao isolador e a criticidade é leve.
- **Caso 4:** Houve registro de descarga corona próximo ao isolador e a criticidade é moderada.
- **Caso 5:** Houve registro de descarga corona próximo ao isolador e a criticidade é alta.

O **Caso 1** é diferente dos outros pois é uma classificação para o vídeo como um todo, enquanto os outros dizem respeito especificamente a uma origem de fâcula presente no vídeo. Cada uma dessas origens é classificada independentemente de acordo com os critérios a seguir:

$$\text{Caso 1} \quad P = 0 \text{ e } A = 0 \quad (37)$$

$$\text{Caso 2} \quad D = 0 \quad (38)$$

$$\text{Caso 3} \quad D = 1 e P + A < 3 \quad (39)$$

$$D = 1 e P + A \geq 3$$

$$\text{Caso 4} \quad \text{ou} \quad (40)$$

$$D = 2 e P + A \leq 2$$

$$\text{Caso 5} \quad D = 2 e P + A > 2 \quad (41)$$

Para validar o desempenho do algoritmo de classificação proposto foram realizadas inspeções com a câmera UV em uma SE de 500 kV. Todos os vídeos foram gravados com a câmera apoiada em um tripé, garantindo a estabilização da filmagem, e a câmera foi configurada para ganho UV de 130. Os vídeos foram gravados durante 4 dias de inspeção. O foco principal foram os IS, que nas inspeções realizadas apresentam mais efeito corona e, conseqüentemente, são objetos de estudo de maior interesse técnico-científico. Outros equipamentos, como por exemplo DI, TP e TC, possuem uma estrutura de equalização de campo elétrico melhor e tendem a naturalmente a não apresentar quantidade significativa descarga corona.

No dia 1 de inspeção (13/01/2023) foram gravados 25 vídeos, todos de IS. Neste dia a umidade relativa registrada no momento da inspeção foi de 66,8%. No dia 2 de inspeção (27/01/2023) foram gravados 38 vídeos, novamente todos de IS. Neste dia, a umidade relativa registrada no momento da inspeção foi de 70,9%. No dia 3 de inspeção (14/07/2023), foram gravados 9 vídeos, sendo 5 de CH, 3 de IP, um de IS. Neste dia, a umidade relativa registrada no momento da inspeção foi de 69,1%. No dia 4 de inspeção (27/07/2023) foram gravados 24 vídeos, sendo 11 de CH, 7 de IP, dois de PR, um de TR, um de DI, um de TP e um de TC. Neste dia a umidade relativa registrada no momento da inspeção foi de de 61,2%.

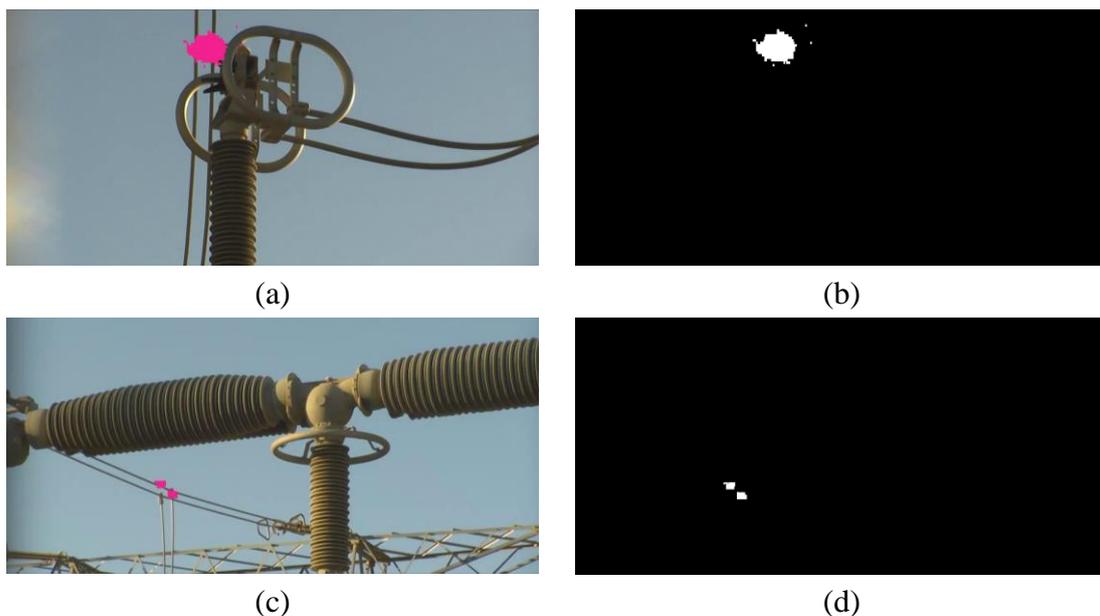
## 5. RESULTADOS

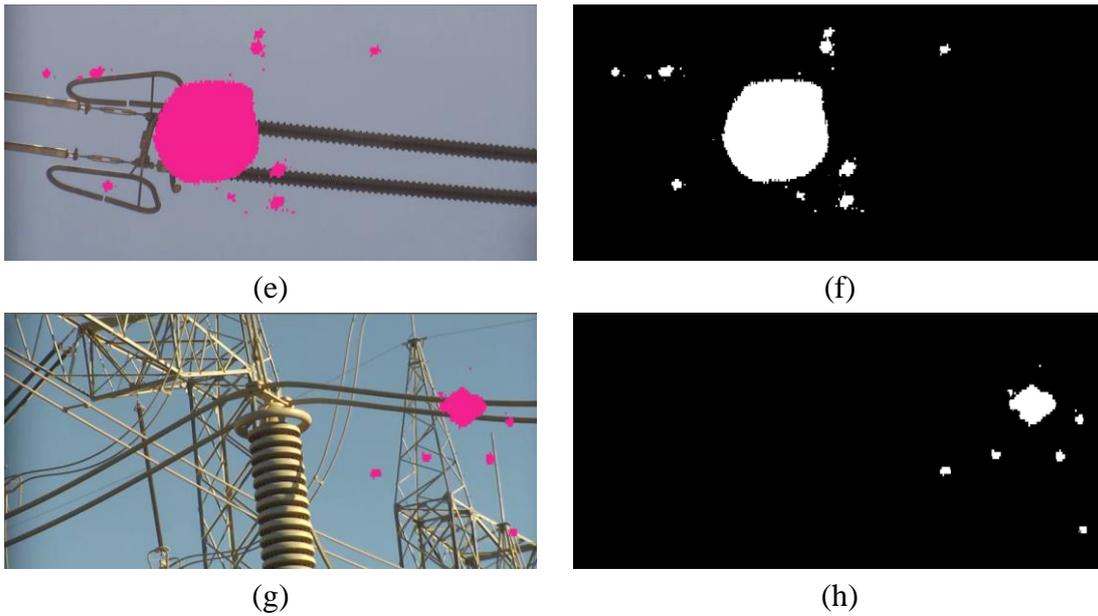
Nesta seção estão apresentados os resultados obtidos com a aplicação da metodologia proposta à base de dados de vídeos UV. Primeiramente, discute-se o desempenho dos algoritmos de PDI e VC desenvolvidos e aplicados. Em seguida, apresenta-se os resultados da classificação.

### 5.1. EXTRAÇÃO DE FÁCULAS

Na Figura 22 constam quatro exemplos de extração de fâculas. Analisando as imagens, fica claro o bom desempenho do limiar de cor proposto na segmentação das fâculas. Para todos os casos testados, não houve nenhum registro de erro na segmentação das fâculas, há apenas a perda de alguns *pixels* nas bordas das fâculas. Esse comportamento é previsto, visto que os esses *pixels* possuem uma coloração intermediária entre o magenta e a cor do fundo da imagem.

Figura 22. Exemplos de extração de fâculas. (a) Quadro original – CH. (b) Fâculas segmentadas – CH. (c) Quadro original – DI. (d) Fâculas segmentadas – DI. (e) Quadro original – IS. (f) Fâculas segmentadas – IS. (e) Quadro original – IP. (f) Fâculas segmentadas – IP.





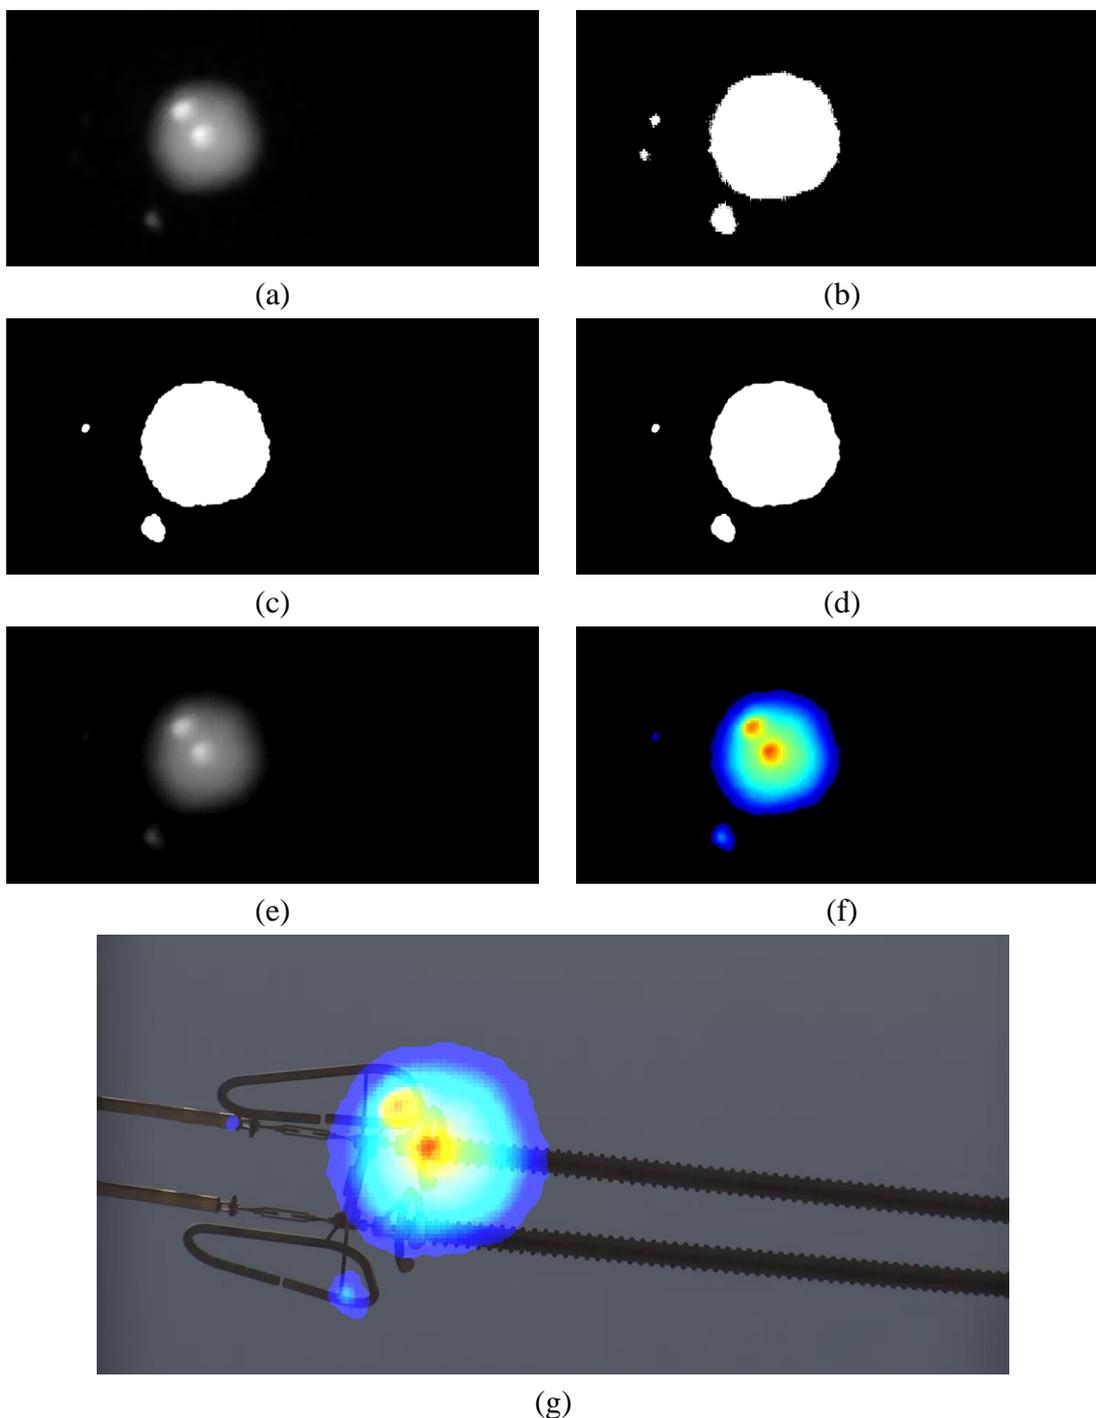
Fonte: autoria própria.

## 5.2. MAPAS DE PERSISTÊNCIA

Na Figura 23 constam os resultados de cada etapa da construção do mapa de persistência. Na primeira etapa, o somatório dos quadros produz uma imagem em tons de cinza com diversas regiões mal delimitadas e com tonalidades indistinguíveis entre si. A segunda etapa binariza a imagem e elimina, no processo, as regiões com persistência menor que 2%. As operações morfológicas de abertura e fechamento, respectivamente Figura 23c e Figura 23d, cumprem a função de eliminar regiões muito pequenas e dão um contorno consistente a cada origem de fâcula. Por fim, ao multiplicar o resultado dessas operações pelo resultado do somatório dos quadros, obtém-se o mapa de persistência em tons de cinza e em seguida o mapa de persistência colorido, respectivamente Figura 23e e Figura 23f.

Figura 23. Etapas da elaboração do mapa de persistência.

- (a) Resultado do somatório dos quadros. (b) Binarização e eliminação das regiões de baixa persistência. (c) Operação de abertura. (d) Operação de fechamento. (e) Mapa de persistência em tons de cinza. (f) Mapa de persistência colorido. (g) Mapa de persistência combinado com ao quadro de referência.



Fonte: autoria própria.

A combinação do quadro de referência com o mapa de persistência colorido, conforme ilustrado Figura 23g, deixa claro quais são as origens de fâculas. Nesse caso, há 3 origens distintas, a maior delas muito próxima ao isolador polimérico e as outras duas nas ferragens, com menor relevância. Essa percepção refinada do fenômeno

difficilmente é atingida apenas assistindo o vídeo, mesmo que por um profissional experiente.

Na Figura 24 observam-se duas comparações entre o resultado do somatório dos quadros com o mapa de persistência final. Nota-se que o método elimina regiões de baixa persistência e destaca aquelas que são mais relevantes. No primeiro caso, Figura 24b, fica claro que há duas origens de fâcula, ambas provenientes da abertura dos anéis equalizadores. No segundo caso, Figura 24d, a origem de fâculas é o cabo, verifica-se que essa origem apresenta um comportamento mais difuso, com formato menos arredondo.

Figura 24. Comparação entre o resultado do somatório dos quadros e o mapa de persistência final.

- (a) Resultado do somatório - IS. (b) Mapa de persistência final - IS.  
(c) Resultado do somatório - IP. (d) Mapa de persistência final - IP.



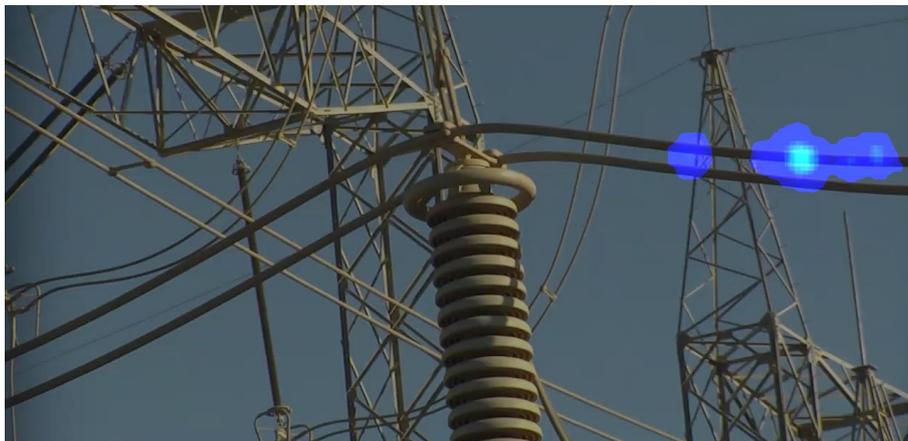
(a)



(b)



(c)



(d)

Fonte: autoria própria.

### 5.3. DETECÇÃO DOS ISOLAMENTOS

O modelo de RNA-C foi configurado para um treinamento de 300 épocas com a base expandida de 48.800 imagens. O treinamento, contudo, foi interrompido automaticamente na época 160, após o algoritmo constar 100 épocas sem melhoria nos resultados. Dessa forma, o melhor resultado foi obtido na época 60, após aproximadamente 6 horas do início do treinamento.

Na Tabela 3 constam os resultados de validação da RNA-C, composta por 8730 instâncias (isolamentos). A rede foi capaz de detectar 85,5% dos positivos verdadeiros e 81,7% das suas previsões foram corretas. Para um IoU de 0,5 a *mAP* foi de 88,8%, já para o IoU variando de 0,5 a 0,95 a *mAP* foi de 55,6%, o que indica que a rede além de

detectar corretamente, também posiciona as BBox de maneira muito semelhante a rotulação.

Tabela 3. Resultados do treinamento da RNA-C.

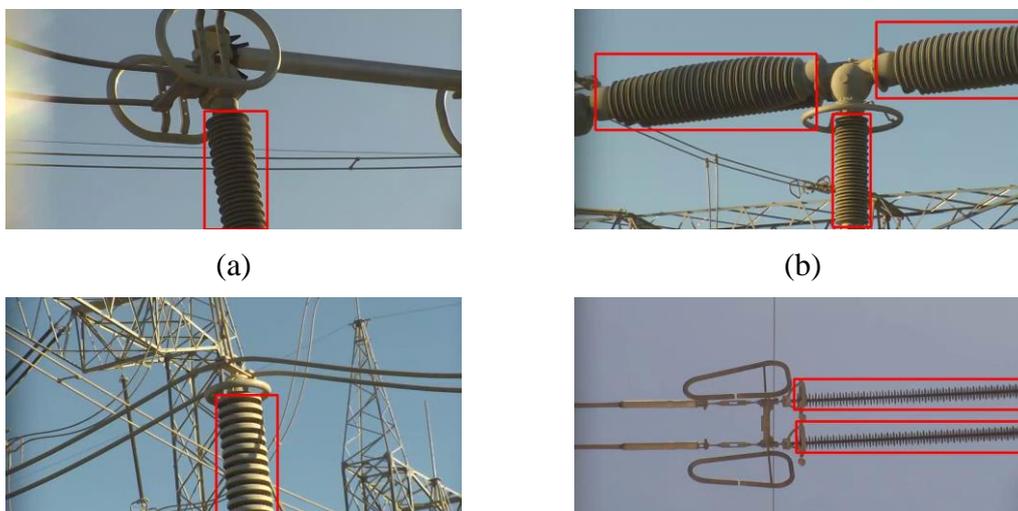
Imagens	Instância	$p$	$r$	mAP50	mAP50-95
1985	8730	0,855	0,817	0,888	0,556

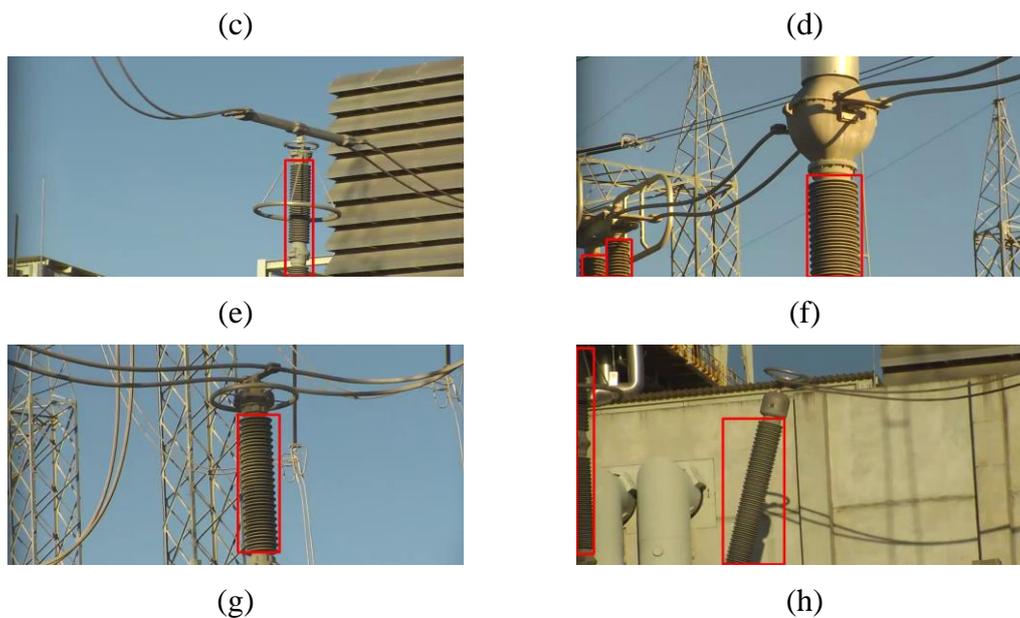
Fonte: autoria própria.

Destaca-se que a base de validação, além de grande (1985 imagens e 8730 instâncias), também é bastante heterogênea, com imagens de todos os equipamentos da SE captadas com dispositivos diferentes (smartphones, termovisor e câmera UV) e com condições de iluminação diversas. Seria possível chegar a resultados de detecção superiores usando uma base mais homogênea, contudo, é mais vantajoso que o modelo seja generalista. Em outras palavras, aumentar a base de validação pode piorar numericamente os resultados e ao mesmo tempo melhorar a detecção em condições práticas.

Na Figura 25 podem ser vistos alguns exemplos de detecção com o modelo de RNA-C aplicado. Fica claro que a rede foi capaz de generalizar os diferentes tipos de isolamento e detectar corretamente. Na Figura 25f, além da coluna do TC também foram detectadas duas colunas do contato móvel de uma CH ao fundo da imagem. Já na Figura 25h, além da bucha do TR também foi detectada a coluna isolante de um PR.

Figura 25. Exemplos de detecção de isolamento.  
(a) CH. (b) DI. (c) IP. (d) IS. (e) PR. (f) TC. (g) TP. (h) TR.

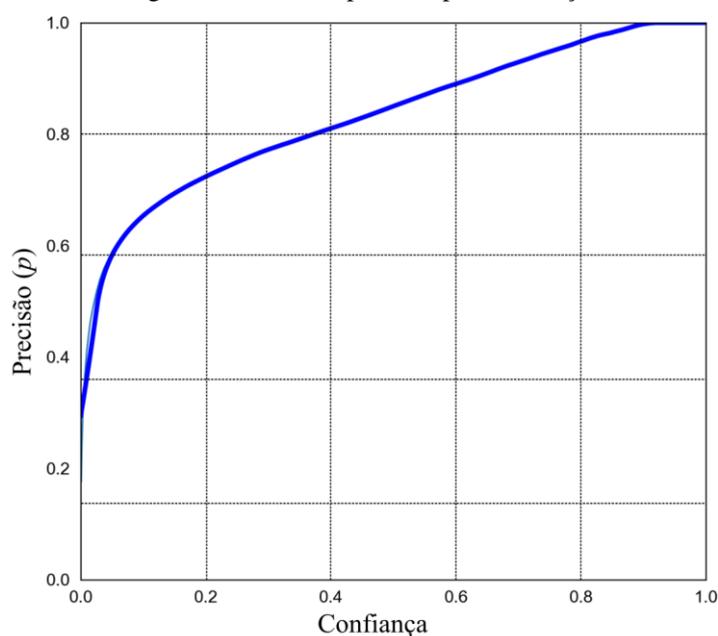




Fonte: autoria própria.

Na Figura 26, observa-se a curva obtida de precisão por confiança do modelo treinado. Conforme a confiança aumenta, a precisão aumenta rapidamente. Para um valor de confiança em torno de 0,4, a precisão já ultrapassa os 80% e, conforme a confiança se aproxima de 1 a precisão também tende a 1. Esse comportamento é o esperado para um bom modelo de detecção de objetos.

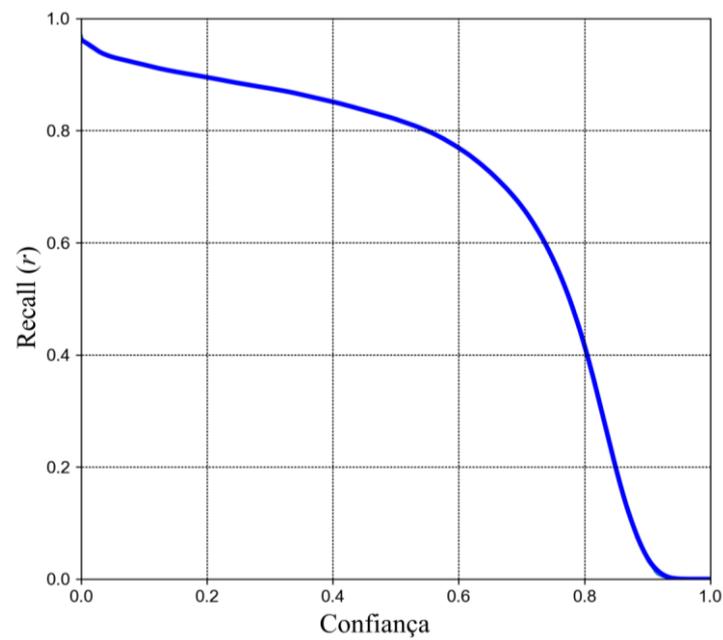
Figura 26. Curva de precisão por confiança.



Fonte: autoria própria.

No gráfico apresentado na Figura 27 o formato da curva de *recall* (proporção de positivos encontrados) por confiança é típico de um bom modelo de detecção de objetos. No Apêndice A estão apresentados mais alguns gráficos do modelo, como por exemplo a curva *p versus r*, a matriz de confusão, entre outros.

Figura 27. Curva de *recall* por confiança.



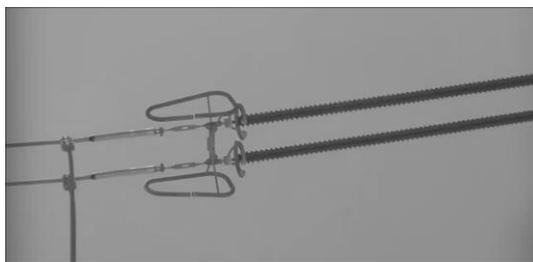
Fonte: autoria própria.

## 5.4. SEGMENTAÇÃO DOS ISOLAMENTOS

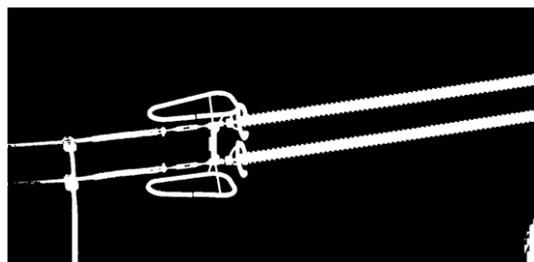
Na Figura 28 apresenta-se o resultado de cada etapa da segmentação de um isolador polimérico. A segmentação adaptativa da média apresenta bom desempenho em separar o fundo dos objetos, conforme ilustrado na Figura 28b. Já nas Figura 28c e Figura 28d, observa-se, respectivamente, a detecção da componente polimérica e sua binarização. Nota-se, que o algoritmo proposto utilizou a detecção em que o polímero estava na horizontal, de forma que a área ocupada pela BBox foi minimizada. Na Figura 28e, tem-se o isolamento segmentado, que é resultado da multiplicação da Figura 28b pela Figura 28d. Esta última deve ser rotacionada à posição original antes de realizar a multiplicação.

Figura 28. Etapas da segmentação do isolamento.

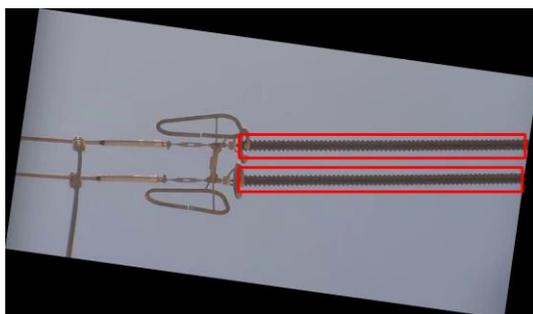
(a)  $I_{m_{ref}}$  em tons de cinza. (b) Resultado da limiarização adaptativa da média. (c) Detecção com a RNA-C escolhida. (d) Detecção binarizada (e) Isolamento segmentado. (f) Resultado da operação de deletar regiões pequenas. (g) Isolamento destacado no quadro de referência.



(a)



(b)



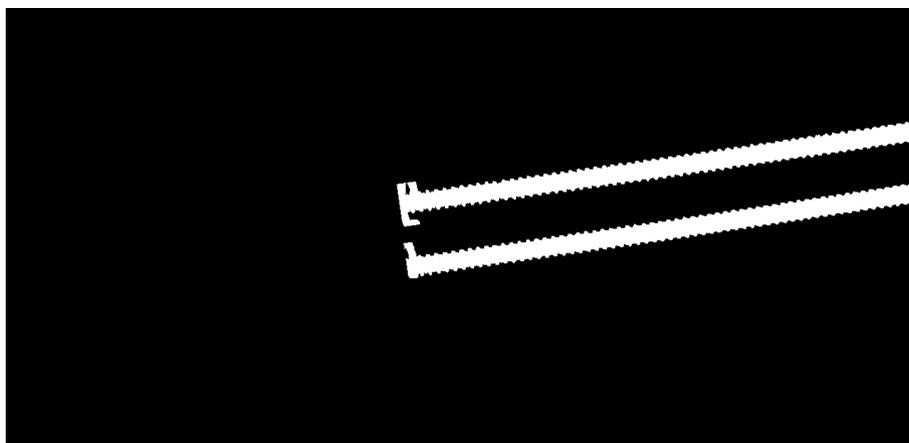
(c)



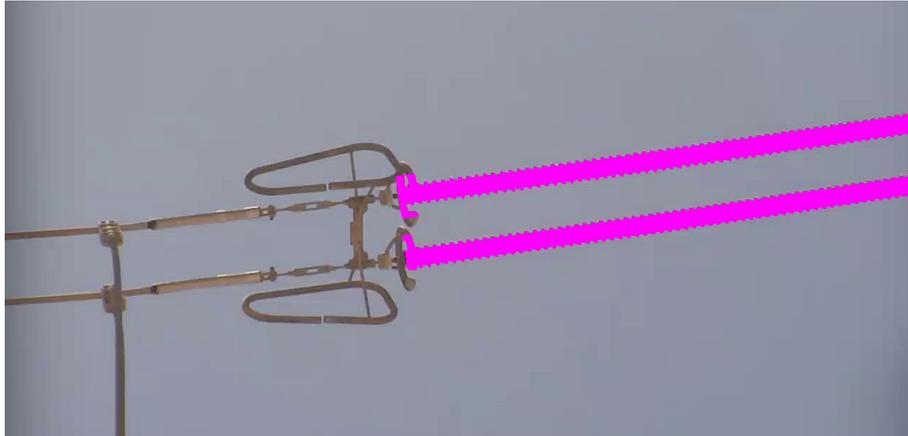
(d)



(e)



(f)



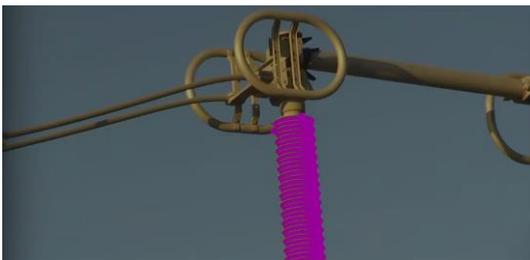
(g)

Fonte: autoria própria.

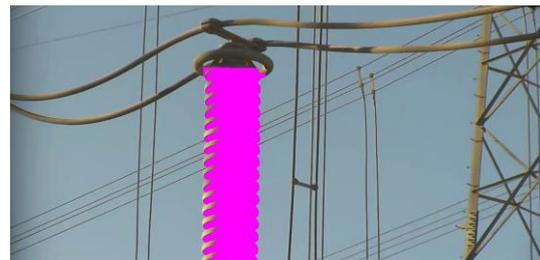
Na Figura 28f é apresentado o resultado da última etapa da segmentação, que é a eliminação de regiões muito pequenas. Nesse caso específico, havia poucos *pixels* a serem eliminados por esse critério. Analisando o resultado da segmentação destacado no quadro de referência, conforme a Figura 28g, fica claro que o algoritmo foi capaz de detectar e segmentar os isolamentos com excelente desempenho.

Na Figura 29 ilustra-se mais 6 exemplos de segmentação. Nota-se que em alguns casos *pixels* do isolamento não foram segmentados corretamente, por exemplo no para-raios da Figura 29c. Contudo, esses erros não são capazes de interferir significativamente no cálculo de  $d_{\min}$ , visto que o formato da coluna isolante foi preservado.

Figura 29. Exemplos de segmentação. (a) CH. (b) IP. (c) PR. (d) TC. (e) IS. (f) IS.



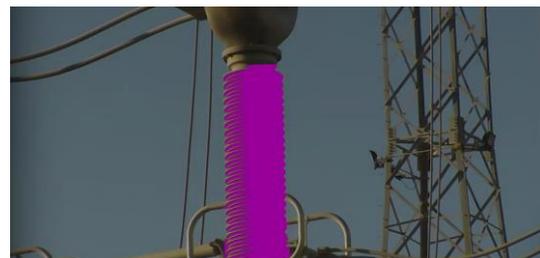
(a)



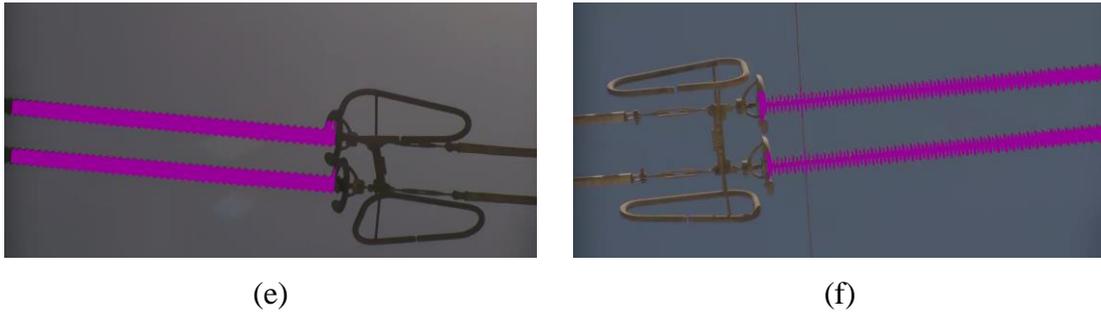
(b)



(c)



(d)



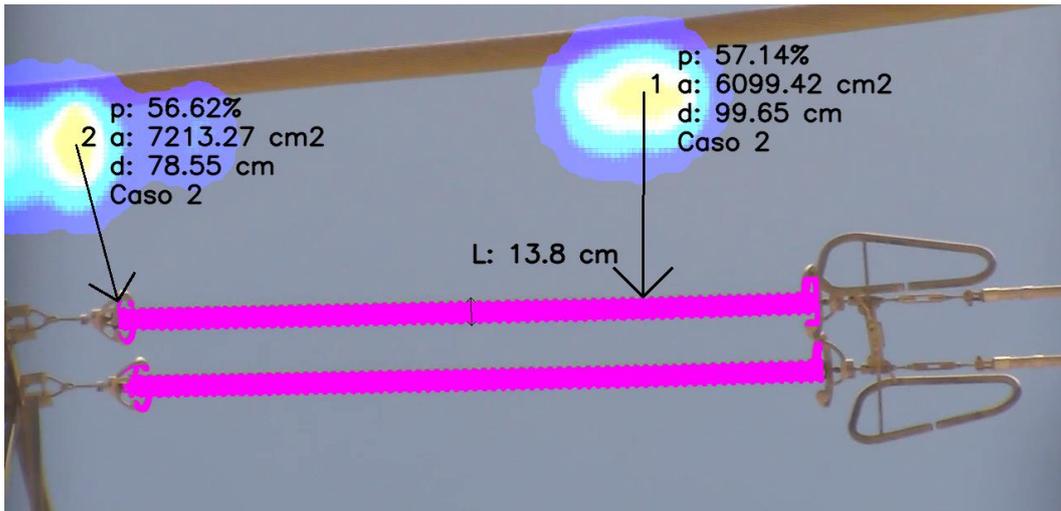
Fonte: autoria própria.

Na segmentação dos isoladores de suspensão, o método proposto acaba, inevitavelmente, segmentando parte do anel equalizador. Isso acontece, pois o anel anti-corona se sobrepõe fisicamente ao polímero. Contudo, a estratégia de detectar o isolamento na imagem rotacionada minimiza significativamente esse problema, resultando em pouca ou nenhuma interferência no cálculo de  $d_{\min}$ .

## 5.5. CLASSIFICAÇÃO

Nesta seção, estão apresentados os resultados da aplicação do algoritmo desenvolvido aos 96 vídeos de equipamentos de alta tensão gravados em uma SE de 500 kV. Na Figura 30 apresenta-se o primeiro exemplo de um IS. Nesse caso, há duas origens de fâcula com intensidade de UV significativa, originadas por descargas corona em um cabo. A persistência e a área de ambas as origens foram quantificadas dentro da faixa de maior criticidade ( $A$  e  $P$  iguais a 2). Contudo, o método classificou corretamente as descargas como **Caso 2**, visto que a origem está significativamente distante do isolador polimérico.

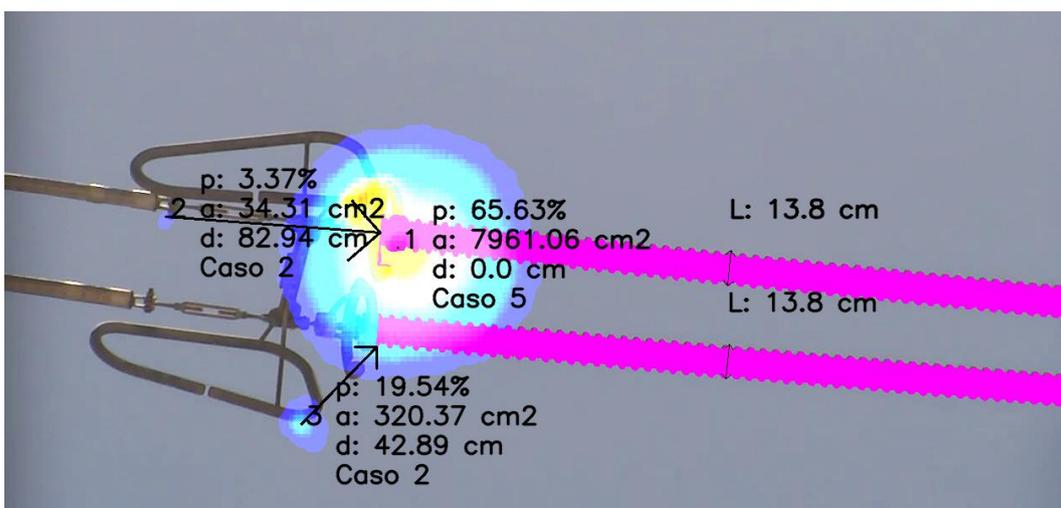
Figura 30. Exemplo 1 de aplicação do algoritmo.



Fonte: autoria própria.

Na imagem, é possível ver a marcação da largura do polímero considerada, representada pela letra  $L$ . Este é um dos casos em que os valores numéricos de  $d_{min}$  estão muito longe dos valores reais, visto que o cabo que origina as descargas está muito mais próximo da câmera que o isolador. Contudo, como esses casos acontecem exatamente quando a descarga está longe do isolador, a classificação é dada como **Caso 2** mesmo com o valor de  $d_{min}$  equivocado. Por outro lado, na Figura 31 está apresentado um caso em que as origens de fâcula estão aproximadamente no mesmo plano do isolador polimérico.

Figura 31. Exemplo 2 de aplicação do algoritmo.



Fonte: autoria própria.

Em uma situação como essa, é importante que os valores de  $d_{min}$  sejam mais próximos da realidade. Nesse exemplo, há 3 origens de fâculas, duas suficientemente distantes do polímero para serem classificadas como **Caso 2** e uma localizada exatamente no polímero e com alta persistência e área, sendo assim classificada como **Caso 5**. Um exemplo com características semelhantes está na Figura 32. Nesse caso há uma origem classificada como **Caso 3** e a distância calculada de 22,33 cm está próxima ao limiar que tornaria esse um **Caso 2**.

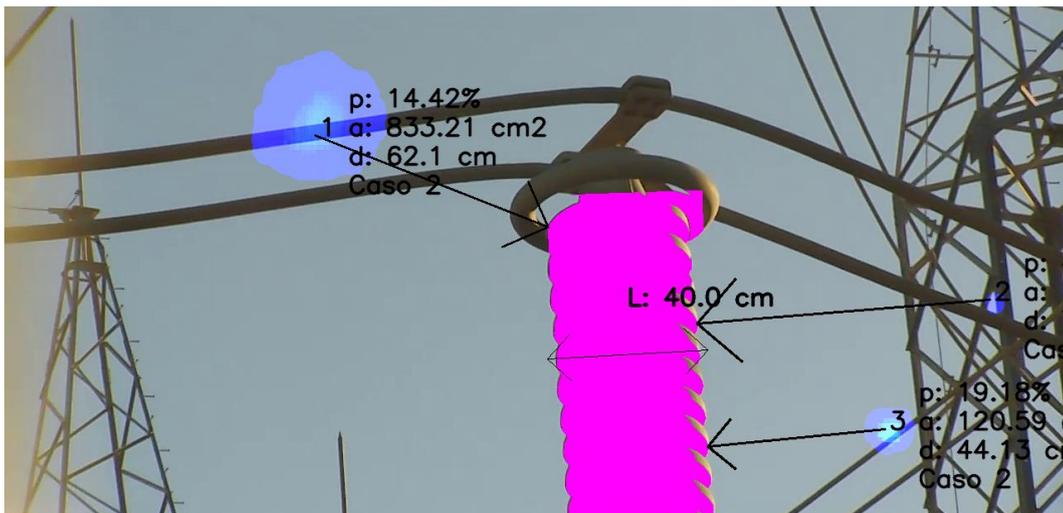
Figura 32. Exemplo 3 de aplicação do algoritmo.



Fonte: autoria própria.

Na Figura 33 observa-se um exemplo de um IP. Foram detectadas 3 origens distintas de fâcula. Na origem número 1, o UV está sendo emitido por descargas vindas do cabo e distantes do equipamento, dessa forma, o algoritmo classificou como **Caso 2**. A origem de fâcula 3 parece ser originada em cabos que estão muito distantes do IP. Um fato que corrobora com essa hipótese é seu alto valor de  $p_{máx}$  (19,18%) associado a um baixo valor de  $a_f$  (120,59 cm<sup>2</sup>). Isso acontece, pois a radiação UV é atenuada significativamente devido à distância, o que tende a reduzir  $a_f$ , já  $p_{máx}$  é menos afetada por esse fator e tende a preservar a intermitência do fenômeno. Essa observação está em acordo com os ensaios em laboratório realizados por Florentino (2019).

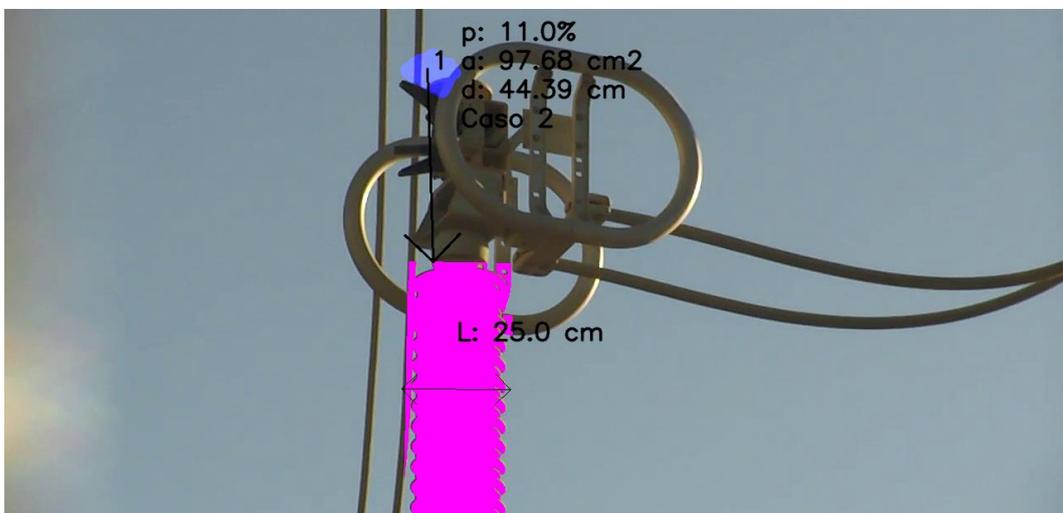
Figura 33. Exemplo 4 de aplicação do algoritmo.



Fonte: autoria própria.

Na Figura 34 consta um exemplo de uma CH. A origem de fâcula aparenta partir do contato fixo da chave e é justificado pelo próprio formato da peça, que cria uma região de campo elétrico intenso e não uniforme. Para confirmar esse tipo de hipótese é necessário que o equipamento seja monitorado a partir de ângulos distintos.

Figura 34. Exemplo 5 de aplicação do algoritmo.

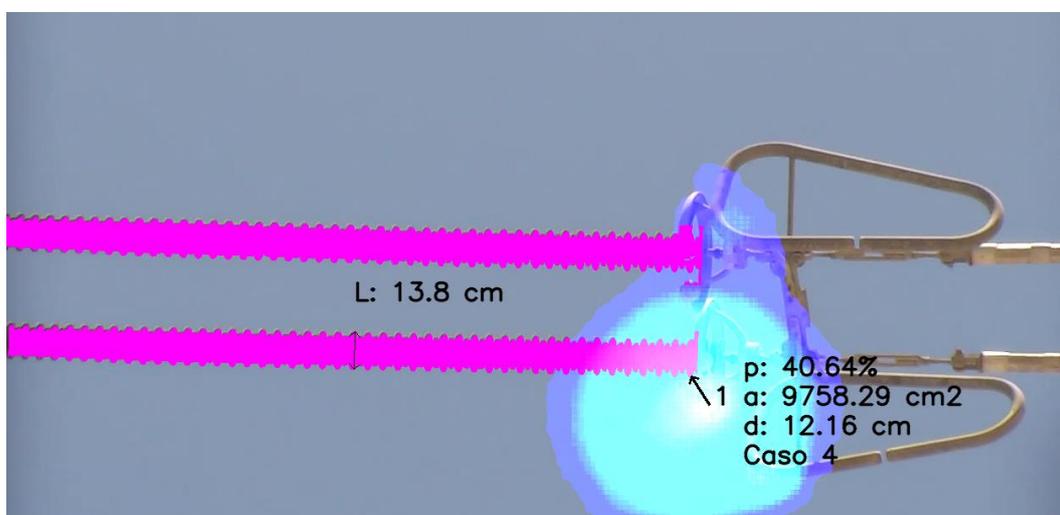


Fonte: autoria própria.

Nota-se nesse exemplo que parte de um cabo que passa atrás da CH foi segmentado junto a coluna isolante, mas isso não resultou em erros no cálculo de  $d_{mim}$ , visto que a seta aponta exatamente para o ponto mais próximo da coluna. Apenas a normalização da distância para centímetros foi afetada suavemente, mas sem comprometer a classificação.

No exemplo de vídeo UV de um IS, ilustrado na Figura 35, há uma origem de fâcula de alta persistência e área, mas que foi classificada como Caso 4, pois o valor de  $d_{mim}$  foi superior a 10 cm, conforme a equação (36). Nesse caso, a radiação UV foi emitida por descargas aparentemente originadas no anel equalizador. Sendo assim, trata-se de um caso preocupante, mas não o suficiente para ser classificado como Caso 5. Nessa situação, é vital que mais vídeos sejam feitos do mesmo equipamento a partir de ângulos diferentes. Dessa forma, seria possível confirmar se de fato a descarga parte do anel equalizador e não do isolamento em si.

Figura 35. Exemplo 6 de aplicação do algoritmo.

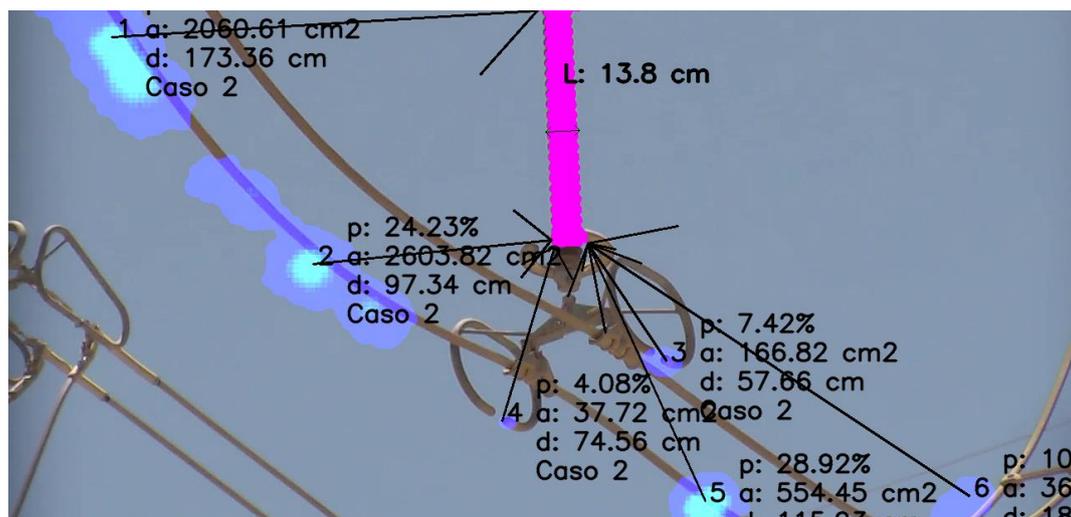


Fonte: autoria própria.

Novamente no exemplo da Figura 35, há uma outra origem de fâcula não destacada, que surge no outro anel equalizador. Devido à grande intensidade das descargas, as duas origens acabaram misturadas e consideradas como uma só. Em trabalhos futuros pode ser desenvolvida uma maneira mais eficiente de manter essas origens separadas. Do ponto de vista prático, repetir essa filmagem de um outro ângulo pode ser suficiente para que as origens sejam diferenciadas e o algoritmo possa classificá-las de maneira independente.

No 7º e último exemplo de aplicação do algoritmo, ilustrado na Figura 36, há 6 origens distintas de fâculas, todas elas classificadas como **Caso 2**. Destaca-se, que conforme as origens se aproximam do polímero, mais relevante é o parâmetro  $d_{mim}$  e, ao mesmo tempo, mais preciso é o seu cálculo em centímetros.

Figura 36. Exemplo 7 de aplicação do algoritmo.



Fonte: Autoria própria.

Alguns autores, como Britto (2021), propuseram o fator de forma como parâmetro relevante na análise de vídeos UV. Neste exemplo há evidências que descargas originadas em cabos tendem a ser mais difusas e, conseqüentemente, menos arredondas. Contudo, não há uma vantagem clara em usar o fator de forma para classificar essas fâculas como originadas em cabos, visto que o parâmetro  $d_{mím}$  já indica que elas não são preocupantes devido à distância do isolamento.

Na Tabela 4 estão elencados os resultados para cada dia de inspeção. Os **Casos 1** e **2** foram os mais comuns, o que indica que, na maior parte dos vídeos gravados, não foram detectadas descargas preocupantes.

Tabela 4. Resultado geral da classificação.

Dia	RH (%)	Nº Vídeos	Nº Origens de fâcula	Classificação				
				Caso 1	Caso 2	Caso 3	Caso 4	Caso 5
1	66,8	25	46	6	<b>37</b>	5	3	1
2	70,9	38	39	16	<b>23</b>	8	7	1
3	69,1	24	11	<b>16</b>	10	0	1	0
4	61,2	9	3	<b>7</b>	2	0	0	1

Fonte: autoria própria.

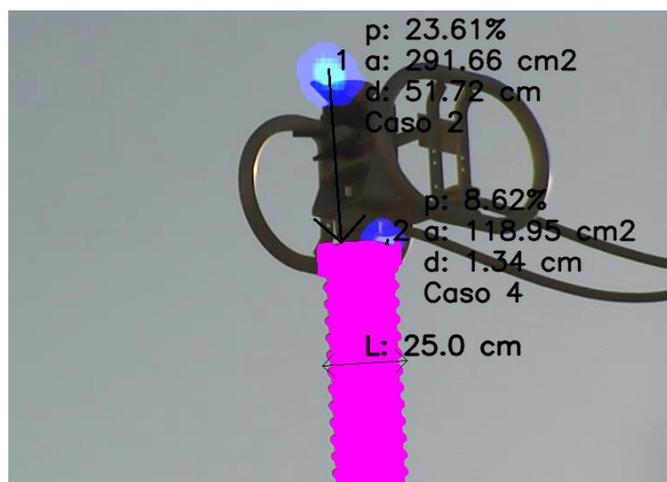
Todas as origens de fâculas classificadas como **Caso 5**, e 10 dos 11 casos classificados como **Caso 4**, foram registrados em vídeos de IS. Isso demonstra que esse modelo de equipamento tende a apresentar mais efeito corona que os demais. As causas para esse comportamento podem ser diversas. Destaca-se a possibilidade de equalização

inadequada, visto que há grande registro de descargas originadas em anéis equalizadores, e o maior acúmulo de poluição salina, visto que os IS estão instalados aproximadamente a 30 metros de altura. Essa última hipótese está associada ao fato da SE em que as inspeções ocorreram localizar-se a pouco mais de 1 km da praia.

Nos dias 1 e 2 de inspeção, foram monitorados apenas IS e o **Caso 2** foi o de maior prevalência. Na maioria dos vídeos, as origens de fâcula partiam dos anéis equalizadores do isolador. Sendo assim, são casos em que não há prejuízo significativo aos isolamentos. Contudo, em algumas inspeções a origem de fâcula esteve suficientemente próxima ao componente polimérico. Nesses casos a presença de corona pode, no longo prazo, danificar os isoladores e levar a problemas mais sérios, como um *flashover* ou desconexão mecânica.

Nos dias 3 e 4 foi priorizados o monitoramento dos outros equipamentos da SE. Observou-se que, depois dos IS, os equipamentos com maior registro de corona são as CH e os IP. Nos seccionadores, as descargas surgem principalmente no encaixe do contato fixo e com maior intensidade quando o equipamento está aberto. Contudo, houve ao menos um caso em que a origem de fâculas estava significativamente próxima à coluna isolante ( $D = 2$ ), conforme a equação (36) e como ilustrado na Figura 37. Essa origem foi classificada pelo algoritmo como Caso 4, pois tanto a persistência quanto a área não foram significativas ( $P = 1$  e  $A = 0$ ), conforme equações (34) e (35).

Figura 37. Origem de descarga próxima a coluna isolante de uma CH.



Fonte: autoria própria.

Tomando os dias 1 e 2 como preferíveis para uma análise estatística da classificação, na Tabela 5 estão apresentados os resultados da classificação dos vídeos

feitos nesses dias em porcentagem. Observa-se que 70,6% das origens de fâculas foram classificadas como **Caso 2** ( $D = 0$ ). Isso indica a importância do parâmetro  $d_{mim}$  no processo de classificação. Na prática, é um parâmetro de corte, e caso seu valor seja baixo o suficiente, não é relevante analisar a persistência e a área da fâcula. Evidentemente, isso aplica-se no contexto em que o interesse está voltado às descargas muito próximas aos isolamentos.

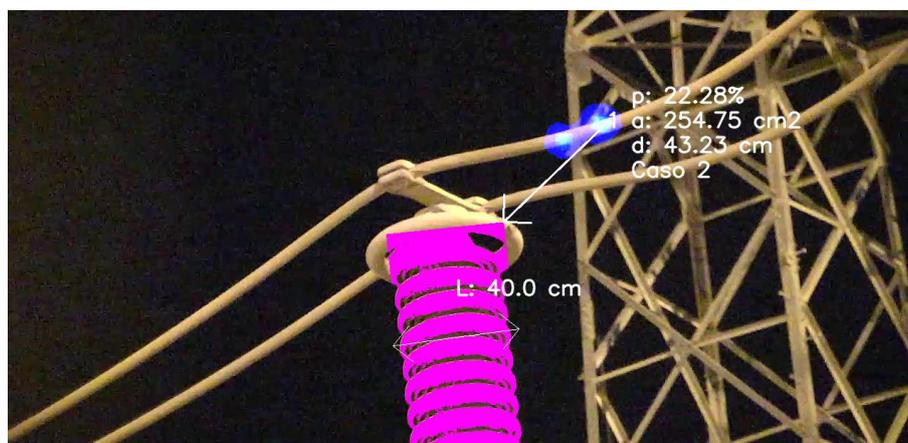
Tabela 5. Resultado geral da classificação dos dias 1 e 2 em termos percentuais.

Dia	Nº Vídeos	Nº Origens de fâcula	Classificação				
			Caso 1	Caso 2	Caso 3	Caso 4	Caso 5
1	25	46	24,0%	<b>80,4%</b>	10,9%	6,5%	2,2%
2	38	39	42,1%	<b>59,0%</b>	20,5%	17,9%	2,6%
Total	63	85	34,9%	<b>70,6%</b>	15,3%	11,8%	2,4%

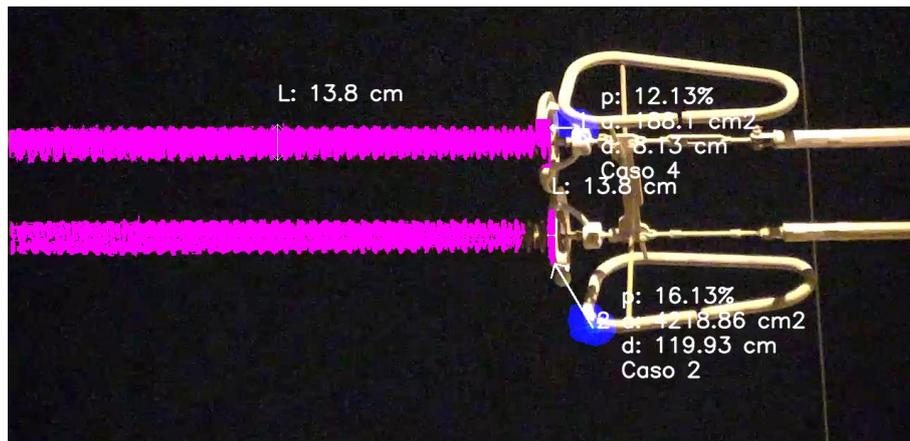
Fonte: autoria própria.

A possibilidade de realizar inspeções pela noite também foi investigada durante a pesquisa. De maneira geral, os vídeos UV gravados à noite perdem nitidez devido à baixa luminosidade do ambiente. Nessas condições, o ISO da câmera acaba adicionando ruído significativo na imagem, o que pode prejudicar a aplicação do algoritmo de segmentação proposto. Além disso, o foco automático da câmera não opera tão bem à noite quanto à luz do dia. Para fins ilustrativos, alguns exemplos de aplicação do algoritmo em inspeções noturnas estão elencados na Figura 38.

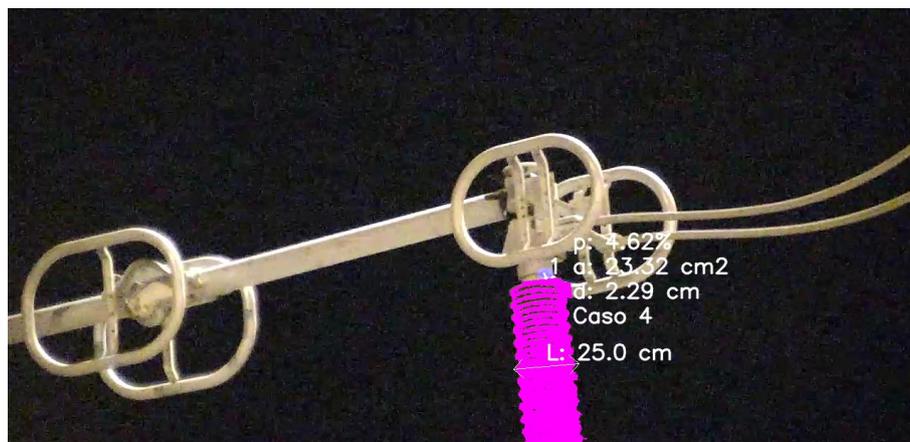
Figura 38. Exemplos de aplicação do método em vídeos gravados a noite.



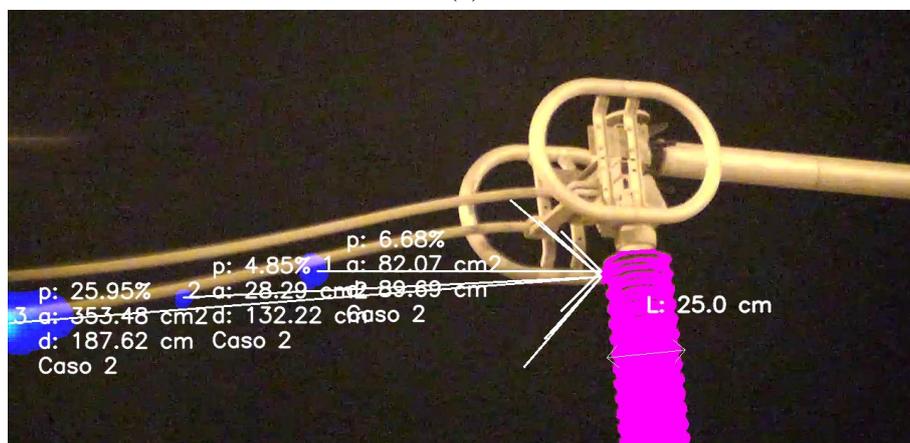
(a)



(b)



(c)



(d)

Fonte: autoria própria.

Nestes exemplos fica claro que o desempenho da segmentação em vídeos feitos à noite é inferior, contudo, a presença de “buracos” no isolamento segmentado não implica diretamente em erros no cálculo de  $d_{min}$  caso o formato do isolamento seja preservado. No caso da Figura 38c houve prejuízo na extração de atributos e, conseqüentemente, na classificação pois há uma parte importante do polímero não segmentada. Isso é justificado

pela baixa luminosidade ambiente, que provocou a falha da limiarização adaptativa. Por outro lado, nesses 4 exemplos a detecção com a RNA-C foi satisfatória.

## 6. CONCLUSÃO

Nesta dissertação foi apresentada uma metodologia automatizada e inovadora de processamento de imagens de câmera UV aplicado ao monitoramento de descargas corona. Os parâmetros para classificação foram  $p_{m\acute{a}x}$ ,  $a_f$ ,  $d_{m\acute{i}n}$  e, que quantificam, respectivamente, a persistência no tempo da radiação UV captada, a sua intensidade e a distância entre sua origem e o isolamento mais próximo. Esses parâmetros foram usados para classificar cada origem de descarga entre 5 categorias. Duas delas referentes a casos em que as descargas não oferecem risco aos isolamentos e três que diferenciam o nível de risco que os equipamentos estão submetidos.

O algoritmo de construção do mapa de persistência agrega toda a informação do vídeo em uma única imagem e fornece informações relevantes do UV detectado, permitindo a sumarização das características dispersas no vídeo em um só resultado visual. O mapa é composto por regiões que representam a detecção de UV ao longo do vídeo. Cada região representa uma origem de fâcula independente, que são quantificadas em termos de  $p_{m\acute{a}x}$  e  $a_f$  para posterior classificação.

O algoritmo proposto utiliza um modelo do YOLOv5 para detectar o componente isolante de equipamentos elétricos (isolador polimérico, coluna isolante ou bucha). Aliado a isso, o método de limiarização adaptativa usado permite realizar uma segmentação fina destes isolamentos. Uma base de dados com imagens de equipamentos elétricos de alta tensão foi construída para o treinamento desse modelo. O YOLOv5 foi treinado com uma base de 6.620 imagens, expandidas artificialmente para 48.800. Na validação, com 8730 instâncias, o modelo foi capaz de detectar 85,5% dos positivos verdadeiros e 81,7% das previsões feitas foram corretas. Além disso a mAP50-95 foi de 55,6% o que indica que, mesmo para um critério rigoroso, o modelo foi capaz de posicional satisfatoriamente as BBox.

Os resultados demonstraram que o método de segmentação proposto é adequado e produz resultados confiáveis. A estratégia de rotacionar o quadro de referência de  $-45^\circ$  a  $45^\circ$  e escolher a detecção com BBox com maior razão entre lados foi capaz de melhorar significativamente a segmentação. Além disso, o método de limiarização adaptativa da média demonstrou-se eficiente na binarização das imagens.

O algoritmo de classificação foi aplicado a 96 vídeos gravados com DayCor Luminar HD em uma SE de 500 kV. Os resultados demonstraram que a metodologia proposta é capaz de diferenciar origens de fâcula e classificar corretamente sua relevância. Ficou claro que, em inspeções em campo, o parâmetro  $d_{min}$  apresenta grande importância, visto que introduz um contexto a descarga registrada e permite diferenciar descargas cuja origem é um isolamento, daquelas que se originam em cabos, anéis equalizadores, entre outras estruturas. Conforme a Tabela 5, nas inspeções de IS feitas nos Dias 1 e 2, 70,6% das origens de fâculas detectadas estavam suficientemente distantes do isolamento para serem relevantes.

## 6.1. PERSPECTIVAS

A seguir, estão elencadas algumas sugestões de melhorias no algoritmo desenvolvido, a fim de torná-lo ainda mais robusto e ampliar suas aplicações.

- Para melhorar e simplificar o processo de segmentação do isolamento, pode-se desenvolver uma RNA-C especializada nessa tarefa. O modelo precisa ser resiliente no reconhecimento de diferentes peças de isolamento e precisa oferecer uma segmentação *pixel a pixel* com alta precisão.
- O algoritmo de processamento do mapa de persistência pode ser aprimorado de maneira a tornar possível a diferenciação de origens de fâculas muito próximas e que se misturam.
- Ensaios em laboratório podem ser aplicados a fim de refinar o método de classificação de forma que seja possível diagnosticar especificamente qual o defeito no equipamento monitorado.
- Realização de um estudo comparativo entre simulações de campo elétrico e o monitoramento com a câmera UV. O princípio está em relacionar a distribuição de campo elétrico ao longo de um isolador (ou cadeia de isoladores) com a detecção de descargas corona. Dessa forma, seria possível verificar distorções no campo causadas por defeitos.

- Aprimorar o cálculo de  $d_{min}$  a partir de ferramentas de calibração de câmera, tornando esse cálculo menos impreciso quando a origem de fâcula se distância do isolamento.

## 6.2. PRODUÇÕES CIENTÍFICAS E TECNOLÓGICAS

Ao longo dessa pesquisa alguns artigos científicos foram publicados, em diferentes áreas de pesquisa.

### 6.2.1. ARTIGOS CIENTÍFICOS PUBLICADOS

Durante o período do mestrado, foram publicados 5 artigos científicos, sendo dois deles como autor e três como coautor. Destacam-se os dois artigos relacionados ao monitoramento de equipamentos elétricos por imageamento UV, o primeiro publicado no *Congreso Iberoamericano en Alta Tensión y Aislamiento Eléctrico (ALTAE)* e o segundo no *2023 IEEE Electrical Insulation Conference (EIC)*. A seguir, estão listadas os artigos publicados:

1. ARAUJO, B. V. S; RODRIGUES, G. A; ANDRADE, F. A; FERREIRA, T. V; Análise e Otimização de Campo Elétrico Aplicado ao Projeto de um Divisor Resistivo de Alta Tensão, Congreso Iberoamericano en Alta Tensión y Aislamiento Eléctrico, San José, Costa Rica, 2021.
2. RODRIGUES, G. A; ARAUJO, B. V. S; FLORENTINO, M. T. B; FERREIRA, T. V; COSTA, E. G. Detecção, Localização e Quantificação de Descargas Corona em Isoladores de Vidro por Meio de Imageamento Ultravioleta, Congreso Iberoamericano en Alta Tensión y Aislamiento Eléctrico, San José, Costa Rica, 2021.
3. RODRIGUES, L. A; SANTOS, M. A; RODRIGUES, G. A; FERREIRA, T. V. Monitoramento de Transformador de Baixa Potência Baseado em Internet das Coisas e Gêmeos Digitais. XXIV Congresso Brasileiro de Automática, Fortaleza/CE, Brasil, 2022.

4. ARAUJO, Bruno Vinicius Silveira et al. Lâmpadas LED e distorção harmônica: uma amostra do mercado brasileiro. *Revista Principia - Divulgação Científica e Tecnológica do IFPB*, João Pessoa, jul. 2022.
5. RODRIGUES, G. A; CORDEIRO, C. A; ARAUJO, B. V. S; FREIRE, E. O; XAVIER, G. V. R; e FERREIRA, T. V; *Digital Image Processing Applied to the Reduction of Subjectivity on Ultraviolet Imaging Diagnosis of Insulators, 2023 IEEE Electrical Insulation Conference (EIC)*, Quebec City, QC, Canada, 2023, pp. 1-4, 2023.
6. NASCIMENTO, J. P. S; RODRIGUES, G. A; ARAUJO, B. V. S; XAVIER, G. V. R; FREIRE, E. O; SALES, G; FERREIRA, T. V; *Detection of Electrical Equipment Using an Artificial Neural Network with Visual Spectrum Images and Thermal Images, 23rd International Symposium on High Voltage Engineering (ISH)*, Glasgow, Scotland, UK, 2023.

## **6.2.2. PATENTES**

Durante o período do mestrado foram registradas duas patentes, ambas relacionadas a invenções para aplicação no SEP.

1. ARAUJO, B. V. S; RODRIGUES, G.A, FERREIRA, T. V. Dispositivo de desligamento multifásico de rede de distribuição acionado pela ejeção de cartucho em chaves fusíveis. BR 10 2021 014283 9. 20 de julho de 2021.
2. ARAUJO, B. V. S; RODRIGUES, G. A, FERREIRA, T. V. Dispositivo de coleta de energia em linhas de alta tensão com sistema optoeletrônico de conversão de energia. BR 10 2022 014787 6. 27 de julho de 2022.

## **6.2.3. REGISTRO DE SOFTWARE**

Durante o período do mestrado foi realizado um registro de software.

1. MACÊDO, M. S; FERREIRA, T. V.; OLIVEIRA, J. H. P; SANTOS, Carlos D. B; ARAÚJO, B. V. S; RODRIGUES, G. A; XAVIER, G. V. R. *Hydrophobicity Cam. 512023001842-2*. 27 de junho de 2023.

# REFERÊNCIAS

BHUTADA *et al*; 3D Electric Field Modelling of UHV Class AC Composite Transmission Line Insulators. 1-6, 2020.

BRITTO, K; COSTA, E; DIAS, B; FLORENTINO, M; e LIRA, G; Development of DIP-based algorithm for extraction of UV video attributes from corona discharges on polymeric insulators. **International Journal of Electrical Power and Energy Systems**, 2021.

DAVARI, N; AKBARIZADEH, G; e MASHHOUR E; Intelligent Diagnosis of Incipient Fault in Power Distribution Lines Based on Corona Detection in UV-Visible Videos, in **IEEE Transactions on Power Delivery**, vol. 36, no. 6, pp. 3640-3648, 2021.

FAN, S; YU, Y; XU, M. e ZHAO, L; High-Precision External Parameter Calibration Method for Camera and Lidar Based on a Calibration Device, in **IEEE Access**, vol. 11, pp. 18750-18760, 2023.

FARADAY, M; Experimental Research in Electricity – thirteenth series, **Philosophical Transactions of the Royal Society of London**, 1838.

FERREIRA, T. V.; GERMANO, A. D.; COSTA, E. G. Ultrasound and Artificial Intelligence Applied to the Pollution Estimation in Insulations. **IEEE Transactions on Power Delivery**, v. 27, n. 2, 2012.

FLORENTINO, M. T. B; **Caracterização das Condições Operacionais de Isoladores Poliméricos Usando os Atributos da Descarga Corona**. [Tese de Doutorado]. Universidade Federal de Campina Grande, 2019.

GUEDES, C. P. G. **Classificação das Condições de Degradação de Isoladores Poliméricos pelos Níveis de Radiação UV e a Lógica Fuzzy** [Dissertação de Mestrado]. Universidade Federal de Campina Grande, 2015.

GUBANSKI, S. M; DERNFALK, A; ANDERSSON, J e HILLBORG, H; Diagnostic Methods for Outdoor Polymeric Insulators, in **IEEE Transactions on Dielectrics and Electrical Insulation**, vol. 14, no. 5, 2007.

GONZALEZ, R. C., Deep Convolutional Neural Networks [Lecture Notes], in **IEEE Signal Processing Magazine**, vol. 35, no. 6, pp. 79-87, Nov. 2018.

GONZALEZ, R. C., **Digital Image Processing**, 4<sup>o</sup> ed; Person, Londres, 2018.

GRUM, F, COSTA, L. F; **Spectral emission of corona discharges**. Appl opt; Jan. 1, 1976.

HERZBERG, G; Molecular Spectra and Molecular Structure I, **Spectra of Diatomic Molecules**, D. Van Nostrand, New York, 1950.

IEEE Std 430-2017. IEEE Standard Procedures for the Measurement of Radio Noise from Overhead Power Lines and Substations; Revision.

JIN, L; AI, J; TIAN, Z; e ZHANG, Y; Detection of polluted insulators using the information fusion of multispectral images, in **IEEE Transactions on Dielectrics and Electrical Insulation**, vol. 24, no. 6, pp. 3530-3538, Dez. 2017.

KUFFEL, E; ZAENGL, W. S; KUFFEL, J; **High Voltage Engineering**, 2<sup>o</sup> ed; Newnes, Oxford, 2000.

LECUN, Y. *et al*; Backpropagation Applied to Handwritten Zip Code Recognition, in **Neural Computation**, vol. 1, no. 4, pp. 541-551, Dez. 1989.

LINDNER, M. ELSTEIN, S; LINDNER, P; TOPAZ, J. M. e PHILLIPS, A. J; **Daylight corona discharge imager**, 1999 Eleventh International Symposium on High Voltage Engineering, London, UK, 1999, pp. 349-352 vol.4.

LI, M. *et al.*, **Insulator Defect Detection Based on Ultraviolet Imaging and Acoustic Emission Signal**, 2020 IEEE 3rd Student Conference on Electrical Machines and Systems (SCEMS), pp. 472-475, 2020.

LIN, Tsung-Yi *et al*; **Microsoft coco: Common objects in context**. Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, Set. 6-12, 2014, Proceedings, Part V 13. Springer International Publishing, 2014. p. 740-755.

LIU, Y. *et al*. **Influence of Pollution Degree and Humidity on Surface Discharge Characteristics of Insulators**, 2021 3rd Asia Energy and Electrical Engineering Symposium (AEEES), pp. 175-178. 2021

LOEB, L. B. e MEEK J. M; **The Mechanism of Electric Spark**. Stanford University Press, 1940.

MIKOLAJCZYK, A. e GROCHOWSKI, M; **Data augmentation for improving deep learning in image classification problem**, in Proc. Int. Interdiscipl. PhD Workshop (IIPhDW), Maio 2018, pp. 117–122.

OTSU, N; A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, ed. 1, p. 62-66, 1979.

RAETHER, H; Die Entwicklung der Elektronenlawine in den Funkenkanal, **Zeitschrift für Physik**; pp. 375, 524, 1939.

REDMON, J; DIVVALA, S; GIRSHICK, R. e FARHADI, A; **You Only Look Once: Unified, Real-Time Object Detection**, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016.

REZATOFIGHI, H; TSOI, N; GWAK, J; SADEGHIAN, A; REID, I. e SAVARESE, S. **Generalized intersection over union: A metric and a loss for bounding box regression**. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 658-666), 2019.

RIBEIRO, G. L; **Aprimoramento da Classificação de Isoladores Poliméricos por Medições Termográficas e Radiação UV Usando Processamento de Imagens e RNA** [Dissertação de Mestrado]. Universidade Federal de Campina Grande, 2017.

SMITH, A. R; Dr Alvy Ray Smith Curriculum Vitae. Disponível em:  
<<http://alvyray.com/Bio/BioCV.htm#Software>>. Acesso em: 12 ago. 2023.

SZELISKI, R; **Computer Vision: Algorithms and Applications**. 1. ed. Springer, 2010.

TALBOT, H., e NAJMAN, L. **Mathematical Morphology: From Theory to Applications**. Wiley & Sons, Incorporated, John, 2013.

TOWNSEND, J. S; **Electricity in Gases**, Oxford, Clarendon Press, 1915.

TRICHEL, G. W; The Mechanism of the Positive Point-to-Plane Corona in Air at Atmospheric Pressure. **Physical Review Journals Archive**, p. 382, 1939.

VOSLO, W. L; STOLPER, G. R. e BAKER, P; **Daylight Corona Discharge Observation and Recording system**. The 10<sup>th</sup> International Symposium on HV Engineering, 1977.

WANG, S; LV, F; e LIU, Y. Estimation of discharge magnitude of composite insulator surface corona discharge based on ultraviolet imaging method, **IEEE Transactions on Dielectrics and Electrical Insulation**, vol. 21, no. 4, 2014.

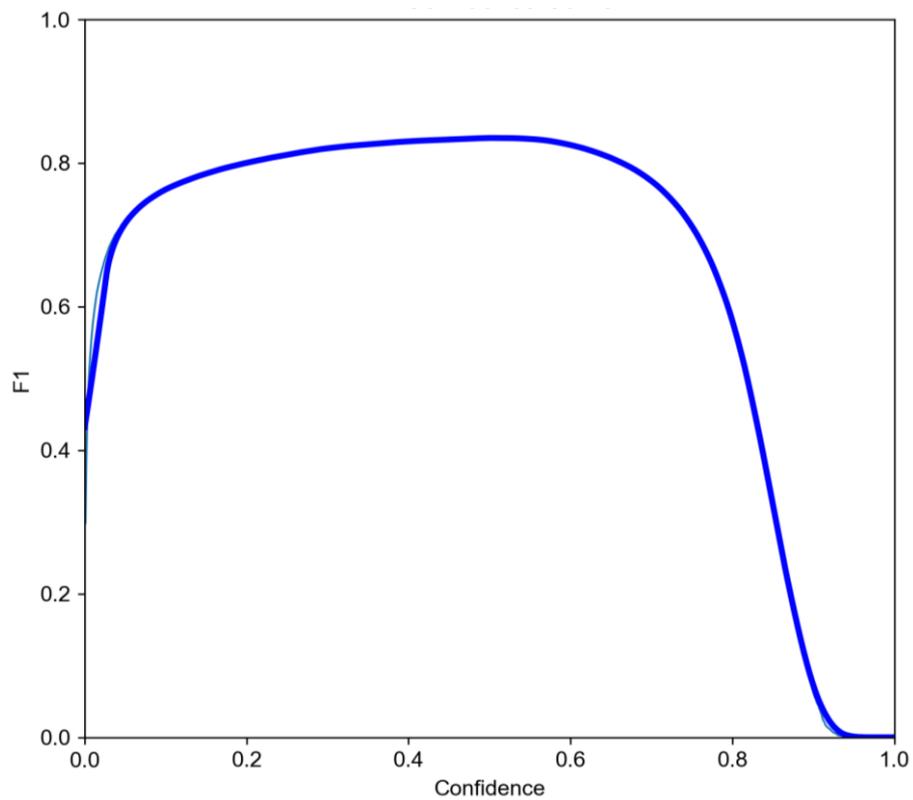
YARNELL, R; BRIGNAC, D; FU, Y. e DeMARA, R. F; Utilization of Data Augmentation Techniques to Enhance Learning with Sparse Datasets, **2022 5th International Conference on Artificial Intelligence for Industries (AI4I)**, Laguna Hills, CA, USA, 2022, pp. 73-73, 2022.

ZHANG, Z; et al, Comparison of different characteristic parameters acquired by UV imager in detecting corona discharge, **IEEE Transactions on Dielectrics and Electrical Insulation**, 2016.

## APÊNDICE A – RESULTADOS DO TREINAMENTO DA RNA-C

Neste apêndice estão elencados alguns gráficos com resultados do treinamento da RNA-C aplicada nessa dissertação. Na Figura 39 observa-se a curva de F1 por confiança.

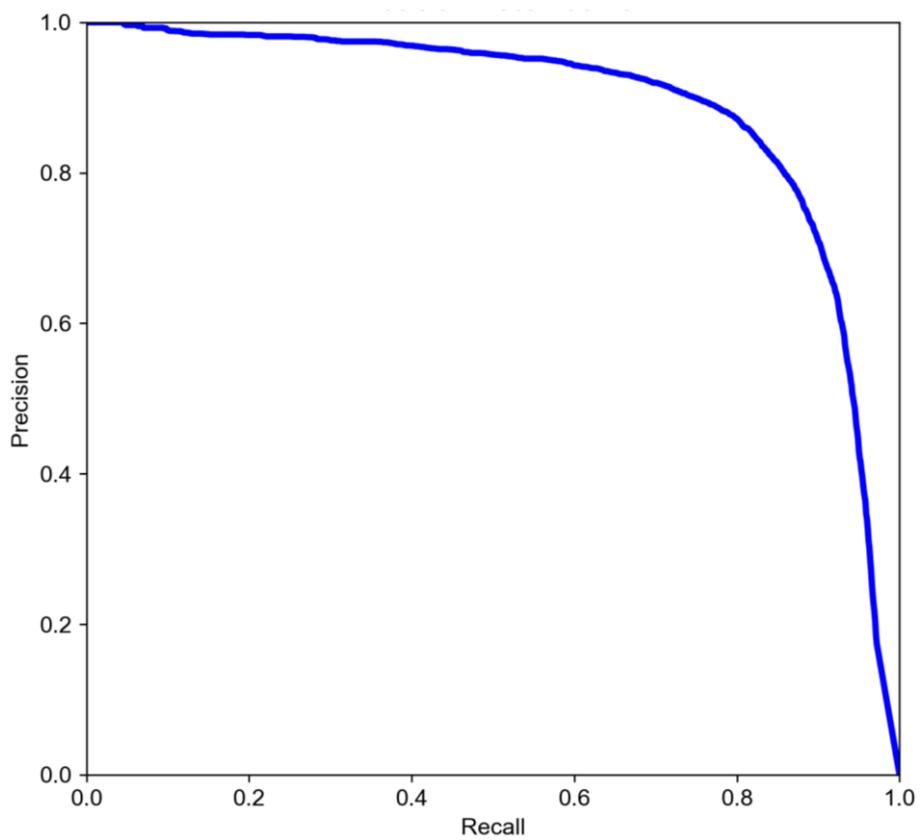
Figura 39. Curva de F1 por confiança.



Fonte: autoria própria.

Na Figura 40 consta a curva de precisão por recall, com formato típico de um modelo de bom desempenho na detecção de objetos.

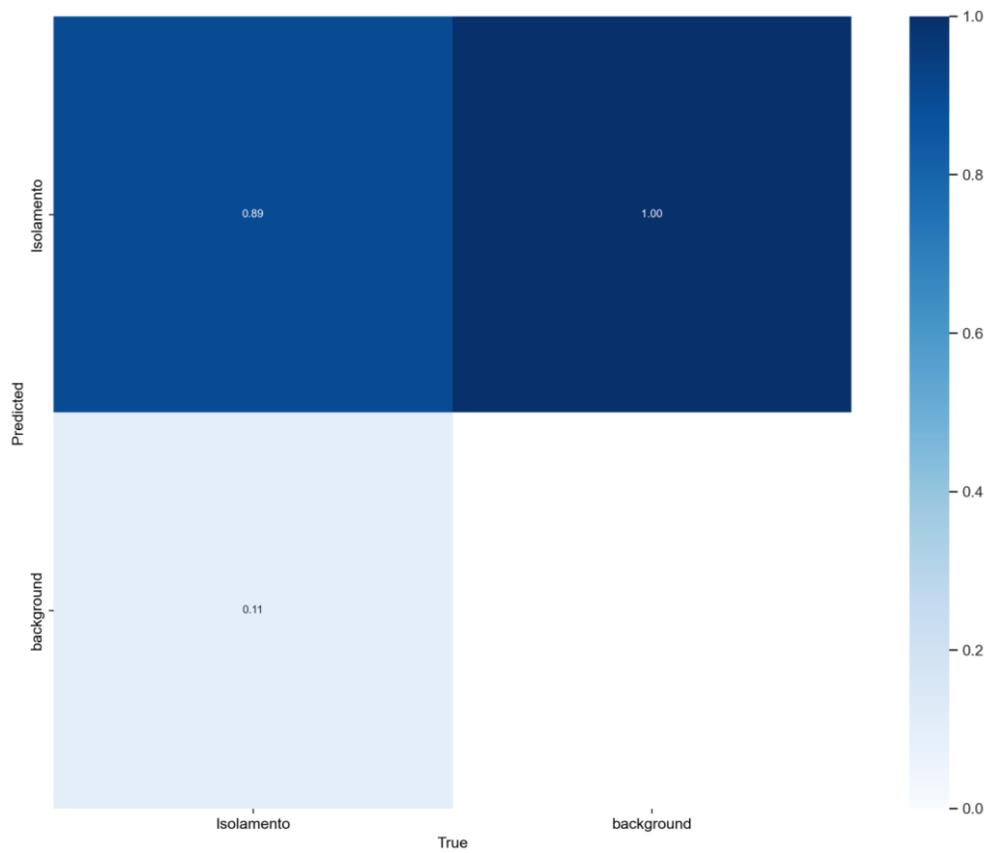
Figura 40. Curva de precisão por recall.



Fonte: autoria própria.

Na Figura 41 está ilustrada a matriz de confusão.

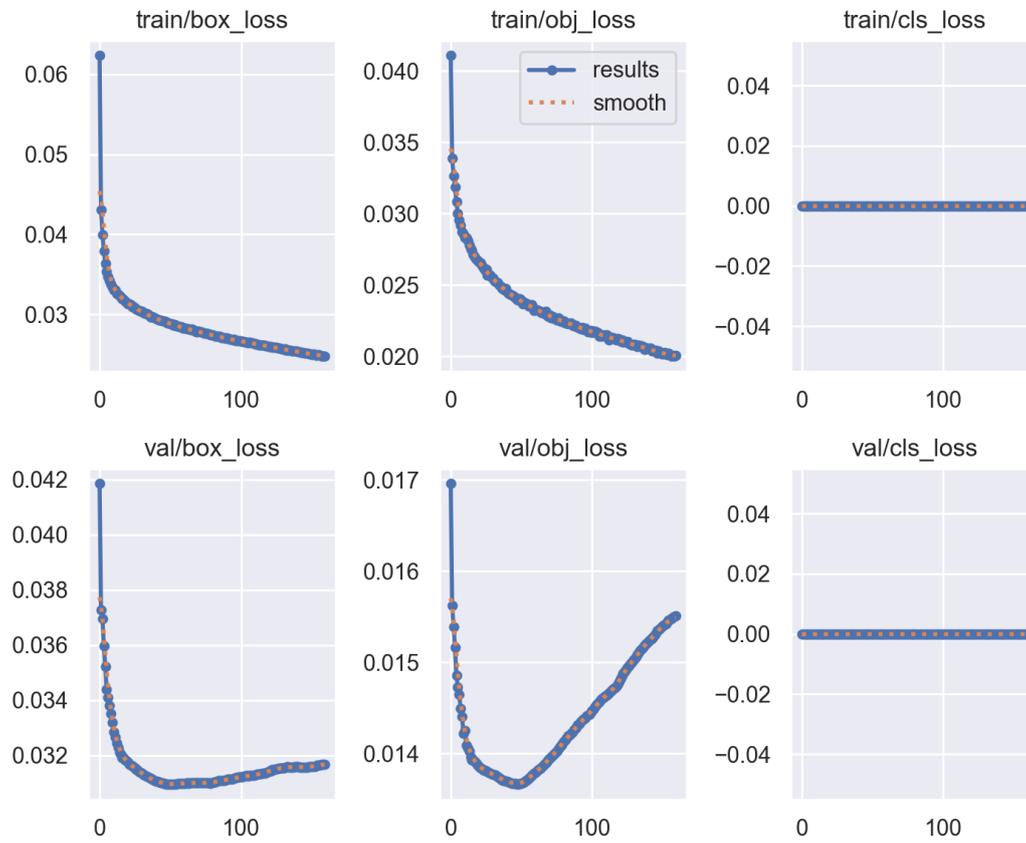
Figura 41. Matriz de Confusão.



Fonte: Autoria própria.

Na Figura 42 observa-se 10 gráficos com os resultados compilados do treinamento da RNA-C.

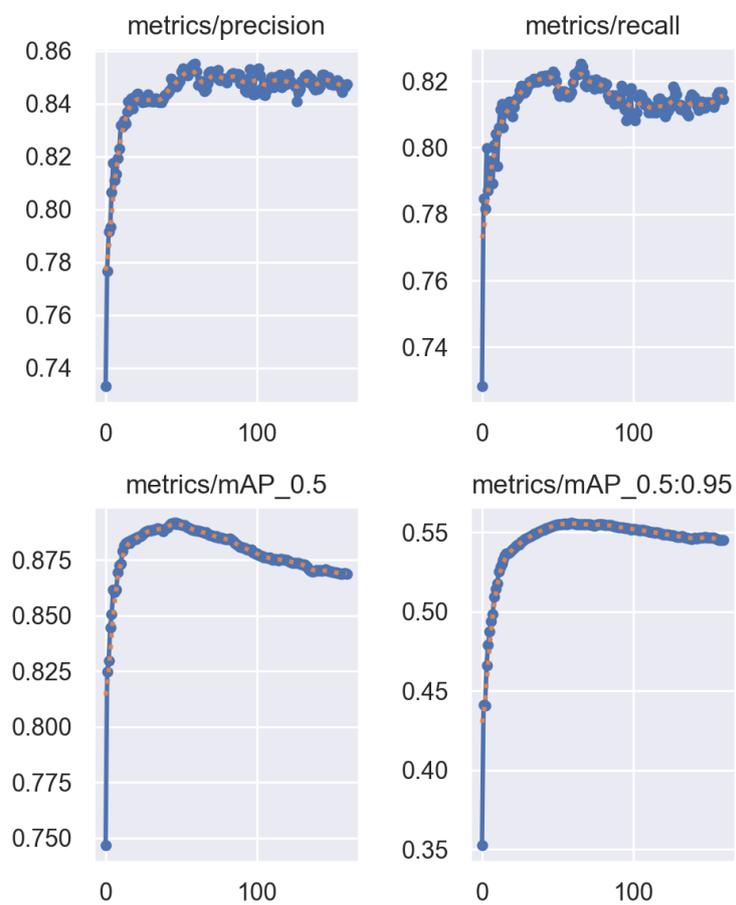
Figura 42. Resultados do treinamento da RNA-C.



Fonte: autoria própria.

Na Figura 43 constam as curvas de  $p$ ,  $r$ ,  $mAP50$  e  $mAP50: 95$  por época.

Figura 43. Resultados do treinamento da RNA-C.



Fonte: autoria própria.