



Grupo de Estudo de Transformadores, Reatores, Materiais e Tecnologias Emergentes-GTM

Classificador de Nível de Poluição em Isoladores de Vidro, aplicação em Rede Neural

**YURI DOS REIS OLIVEIRA(1); JOSÉ ANTONIO DAFFONSECA SANTIAGO CARDOSO(2); JORGE LUIS DE OLIVEIRA(2);
CEPEL / PUC-Rio(1);CEPEL(2);**

RESUMO

Frequentemente os isoladores são retirados do sistema elétrico e então inspecionados para a verificação do nível de poluição o qual estão submetidos. Para facilitar tal verificação foi proposto neste trabalho o treinamento de uma rede neural convolutiva destinada a classificar o nível de poluição em um isolador de vidro ainda instalado no sistema elétrico, utilizando apenas as imagens obtidas com a câmera de detecção de corona ultravioleta (UV). O trabalho também relata a metodologia utilizada para obter o banco de dados através de ensaios de alta tensão executados com isoladores poluídos artificialmente com camada solida salina e nevoa limpa.

PALAVRAS-CHAVE

Efeito Corona, Corona UV, Isolador, Poluição Artificial, Inteligência Artificial.

1.0 - INTRODUÇÃO

A suportabilidade dielétrica da superfície de um isolador tipo disco é reduzida substancialmente quando submetida a determinadas condições climáticas, como chuva, alta umidade, nevoa e etc. Tal efeito pode se tornar mais acentuada quando o isolador está exposto a uma atmosfera poluída e se torna ainda mais agravante no primeiro isolador da cadeia, o isolador mais próximo ao condutor.

Entende-se como atmosfera poluída, do ponto de vista elétrico, um ambiente que, num período de tempo, propicia a formação de uma camada condutiva quando a superfície esta exposta a umidade.

Desta forma, sem as condições atmosféricas propicias, a variação no comportamento dielétrico da superfície do isolador não está totalmente correlacionada com a poluição do isolador, pois sua superfície se mantém seca. Entretanto, se ocorrer um processo de umidificação que dissolva parcialmente mas não remova os sais contidos na camada de poluição, desenvolvendo bandas secas e bandas molhadas, proporcionando pequenas descargas superficiais e assim correntes de alta frequência, podendo estas serem direcionadas ao longo do sistema de transmissão, vindo a provocar os seguintes fenômenos [1].

- Ruído audível, que podem atingir até 65 dB (medido a 30 metros da fonte)
- Perturbações radioelétricas, afeta transmissões AM e FM
- Perda corona, através do efeito corona.

Devido a provável correlação entre as descargas superficiais proporcionadas pela ruptura da rigidez dielétrica da superfície do isolador e o efeito corona advindo, este trabalho tem como objetivo treinar uma rede neural

convolucional (CNN) [2] com imagens do efeito corona ultravioleta (UV) obtidas durante ensaios de alta tensão, com isoladores poluídos artificialmente com camada sólida e submetidos a nevoa de água limpa, visando classificar a intensidade da poluição em 3 classes, "Muito Fraco", "Fraco" e "Moderado".

2.0 - DESCARGAS EM ISOLADORES POLUIDOS

A sequência de eventos a seguir mostra a influência da poluição na formação de descargas/arcs na superfície de isoladores [1]:

- I. O isolador está coberto com uma camada de poluição seca, contendo sais solúveis ou ácidos diluídos ou alcalis. Conforme mostra a Figura 1 a camada de sal decorrente da poluição artificial em isoladores



FIGURA 1 - Isolador poluído artificialmente, detalhe da camada de sal em sua superfície.

- II. A superfície do isolador poluído é umidificada, completamente ou parcialmente, por névoa, chuva fina ou nevoeiro, fazendo com que a camada de poluição se torne condutora.
- III. Assim que a camada poluente que cobre o isolador energizado se torna condutora, as correntes de fuga superficiais aparecem e o aquecimento por elas provocado começa a secar parte da camada poluente.
- IV. A secagem da camada poluente é sempre não uniforme, fazendo com que a camada poluente úmida seja cortada por bandas secas que interrompem o fluxo da corrente de fuga.
- V. A tensão aplicada nas bandas secas, as quais podem ter somente poucos centímetros de largura, causa uma descarga no ar e a banda seca é ultrapassada por arcs que estão, eletricamente, em série com a resistência da parte não seca da camada de poluição.
- VI. Se a resistência da parte seca da camada de poluição for muito baixa, os arcs que ultrapassam as bandas secas não se extinguem e, pelo contrário, aumentam sua extensão ao longo da superfície do isolador. Este fato, por sua vez, diminui a resistência elétrica em série com os arcs, aumentando a corrente e permitindo aumentar, ainda mais sua extensão até que toda a superfície do isolador esteja coberta ocasionando, assim, uma descarga disruptiva.

3.0 - AQUISIÇÃO DE IMAGENS DE CORONA UV

Baseados nas etapas descritas anteriormente, foram realizados ensaios de alta tensão, com isoladores poluídos artificialmente com camada sólida salina respectiva ao nível de poluição desejado, e névoa limpa, seguindo o procedimento A da norma NBR 10621 [3], por questões de segurança.

Para aquisição de imagens de corona UV para o dataset de treinamento e teste da rede CNN.

Para representar os isoladores com os níveis de poluição (muito fraco, fraco e moderado) que deseja-se classificar, foram realizados 3 ensaios, com diferentes níveis de densidade superficial de depósito de sal (DDS), parâmetro estabelecido pela IEC/TS 60815-1 [4], que indica a relação entre quantidade de sal depositado na superfície do isolador, por centímetro quadrado, indicando a severidade da poluição no isolador de vidro. Na Tabela 1 pode ser visualizado os níveis de severidade de poluição segundo [4], e em azul os níveis de poluição que foram considerados para o dataset.

10 a 13 de novembro de 2019
Belo Horizonte - MG

Tabela 1 – Nivel de severidade de poluição

Nivel de poluição	DDS (mg/cm ²)
Insignificante	<0,015
Muito fraco	0,015 a 0,03
Fraco	0,03 a 0,06
Moderado	0,06 a 0,12
Forte	0,12 a 0,24
Muito forte	0,24 a 0,48
Excepcional	>>0,48

3.1 - Arranjo de ensaio

Para a realização do ensaio é necessário criar uma atmosfera com elevada umidade relativa do ar, sendo necessário uma câmara em forma de cubo (1 metro), com as faces de plástico transparente, conforme visualizado na Figura 2.

Também foi utilizado um dispersor de névoa (residencial) para criar a atmosfera desejada e assim simular condições que os isoladores ficam submetidos quando estão na linha de transmissão. Na Figura 3 pode ser visualizado o dispersor de nevoa e a atmosfera criada pela câmara e humidificador.



FIGURA 2 - Câmara de ensaio

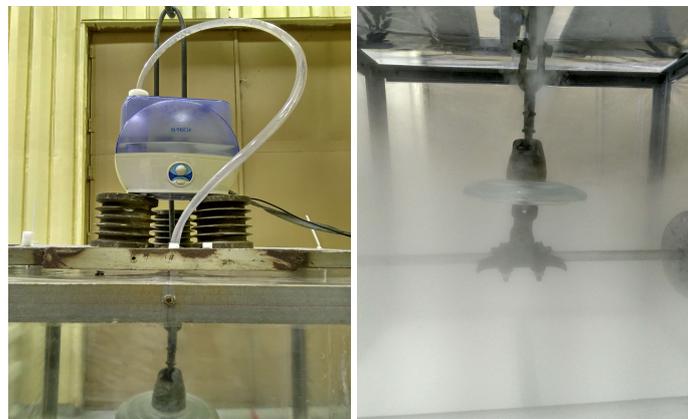


FIGURA 3 - Dispersor de nevoa (esqued) Atmosfera com elevada umidade relativa do ar (direita)

Com o objetivo de analisar apenas o primeiro isolador da cadeia, os ensaios foram realizados com um isolador poluído, devido ao tamanho da câmara e o nível de tensão que seria aplicado. Este arranjo de ensaio foi alimentado por um transformador monofásico de 150 kV.

3.2.-Aquisição das imagens de corona ultravioleta (UV)

O efeito corona é proveniente do elevado gradiente de campo elétrico em dada região, pois ioniza ar resultando em uma avalanche de elétrons acarretando descargas elétricas [5].

Estas descargas emitem radiação eletromagnética com comprimento de onda na faixa de 230 a 405 nm. Radiações dessa magnitude situam-se no espectro ultravioleta UV, entretanto nessa faixa de comprimento de onda também é encontrado as radiações solares. Assim a câmera de detecção de corona UV, mostrado na Figura 4, utilizada para a detecção de corona capta as radiações emitidas entre os valores de 240 a 280 nm, já que a radiação UV proveniente do sol nessa faixa de comprimento de onda é filtrada pela camada de ozônio. Possibilitando a detecção da descarga corona em ambientes diurnos também em laboratórios iluminados [5].



FIGURA 4 - Camera de detecção de corona UV utilizado nos ensaios

A câmera UV é composta internamente por um detector UV e uma câmera que conforme visualizado na Figura 5, através de um arranjo de espelhos a imagem registrada gera dois sinais de vídeo, correspondentes a imagem propriamente dita e a irradiação de UV. Logo estes sinais são sobrepostos de modo que possa identificar a localização das descargas corona [6].

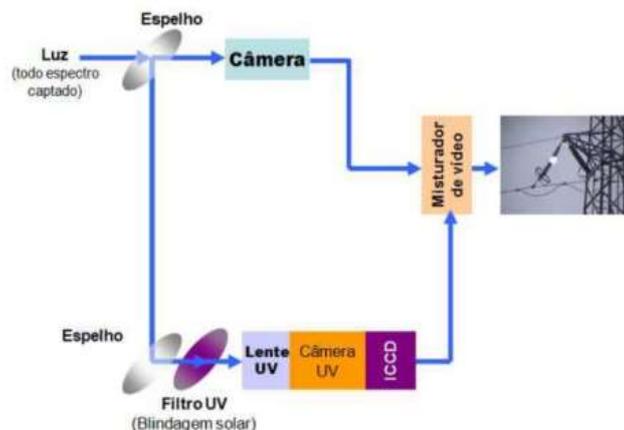


FIGURA 5 - Modelo básico de aquisição da camera de detecção de corona UV

A câmera possui o artifício de variação de ganho entre as faixas de 0 a 250, embora o ganho intensifique a detecção da irradiação UV, de mesmo modo será a ampliação do ruído ambiente. Portanto, segundo [7] a faixa de ganho deve ser mantida entre 120 a 150, já que nestes valores a detecção de descargas apresenta um comportamento linear e relação de sinal-ruído aceitável [7]. Durante os ensaios o ganho da câmera foi mantido em 150.

A imagem de corona UV, ou seja, o frame do vídeo registrado por uma câmera de detecção de corona UV pode ser visualizado na Figura 6.



FIGURA 6 - Frame registrado pela câmera UV

3.3 - Poluição artificial

A poluição artificial em camada sólida tem como objetivo, criar uma camada de sal sobre a superfície do isolador que ao ser dissolvida em decorrência da elevada umidade relativa do ar, permitindo o fluxo de corrente sobre a superfície do isolador. Além de uma camada de sal, é necessário que um material insolúvel e inerte, Caulim, também esteja presente nessa camada sólida, deste modo a solução de poluição deve conter o valor normalizado de Caulim de 40g por litro de água destilada.

Infelizmente não existe um método numérico que relaciona a quantidade de sal e o valor do DDS, deste modo a solução de preparação para os níveis de poluição especificados devem ser retroativamente ajustados até que tenha encontrado o valor de DDS, ver Tabela 1.

3.4 - Procedimento de ensaio.

No Metodologia utilizada não ensaios, se baseia no procedimento A da norma NBR 10621, o qual simula a energização de uma linha que possui isoladores poluídos, pois solicita que a umidificação do ambiente antes e durante a energização.

Entretanto, como o objetivo deste ensaio é obter as imagens de corona UV correspondentes aos níveis de severidade de poluição apenas na faixa de tensão (20 a 24 kV), é necessário que somente seja energizado o circuito de ensaio, quando o isolador e a umidade relativa do ar dentro da câmara esteja propícia a formação de descargas superficiais e assim ao corona. Desta forma, a execução dos ensaios seguiu as seguintes etapas:

- 1) Com o arranjo de ensaio devidamente aterrado e montado incluindo o isolador poluído no circuito e a câmara totalmente fechada, o dispersor de nevoa é ligado mantido durante 10 minutos, antes da energização.
- 2) Após os 10 minutos, a janela de aquisição da câmara é aberta e o circuito é energizado, entretanto, o dispersor de nevoa é mantido ligado durante todo este processo e até o final do ensaio.

3) A tensão é elevada até que o efeito corona esteja mantido no isolador. Nos isoladores utilizados, o nível de tensão o qual encontramos corona está na faixa de 20 a 24 kV conforme o nível da severidade da poluição.

4) Elevado a tensão até o nível desejado, inicia-se a filmagem do corona UV. Neste trabalho foram adquiridas em média 15 minutos de vídeo em cada ensaio.

5) Após filmagem, o circuito é desenergizado e devidamente aterrado e ao final o dispersor de nevoa é desligado.

4.0 - CONJUNTO DE DADOS - DATA SET

O dataset é formado pelos frames dos vídeos dos ensaios realizados, do qual cada imagem recebeu uma marcação, "label", indicando a qual classe pertence, 0=Muito fraco, 1=Fraco e 2=Moderado. Os frames foram tratados em apenas uma banda, ou seja, apenas em níveis de cinza.

Ao todo foram obtidas aproximadamente 86000 imagens com resolução 320x240 e 24 bits, significando um elevado custo computacional, levando em consideração que as regiões mais externas da imagem de corona UV têm contribuições pequenas quanto a informações relevantes.

A elevada resolução e o desbalanceamento da quantidade de imagens entre as classes demonstrado na Tabela 2, foram solucionadas durante o pré-processamento. As imagens foram comprimidas até a resolução de 64x64 pixels, e para balancear o dataset, as imagens comprimidas foram separadas em 3 conjuntos igualmente distribuídas em cada conjunto.

a. Conjunto de treinamento

Dados disponibilizados para treinamento e convergência da rede, necessitando de uma grande massa de dados, deste modo este conjunto possui 74977 frames do qual cada classe possui 24990 frames aproximadamente.

b. Conjunto de validação

Dados utilizados para avaliação da generalização da rede durante o treinamento, neste conjunto foram utilizados ao todo 6000 frames, 2000 correspondente a cada classe.

c. Conjunto de teste

Dados utilizados para avaliação da exatidão e generalização a posteriori ao treinamento, ao todo foram utilizados 1050 frames, 350 correspondentes a cada classe.

Tabela 2 – Frames totais adquiridos e distribuição dos conjuntos

Classes	Frames
Muito Fraco	30195
Fraco	29241
Moderado	27364
Total	86800

Tabela 3 – Distribuição de dados nos conjuntos

Conjuntos	Classes	Frames
Treinamento	Muito Fraco	24992
	Fraco	24992
	Moderado	24993
Validação	Muito Fraco	2000
	Fraco	2000
	Moderado	2000

Teste	Muito Fraco	350
	Fraco	350
	Moderado	350

5.0 - REDE CNN

As redes neurais de múltiplas camadas, Deep Neural Networks (DNN) são modelos de aprendizado supervisionado. Dentre estas redes profundas, a chamada Convolutional Neural Networks (CNN) são modelos projetos para trabalhar com classificação de imagens. Elas são baseadas no córtex visual de um gato [8]. E teve seu primeiro modelo desenvolvido por Lecun [9], para o reconhecimento de caracteres escritos.

Tendo como grande diferencial da rede CNN as camadas convolutivas, que conseguem extrair as características com base em um sub-região da imagem e sua vizinhança ao invés da extração de característica baseada em todos os pixels da imagem conforme as DNN comuns [2], como mostra a Figura 7.

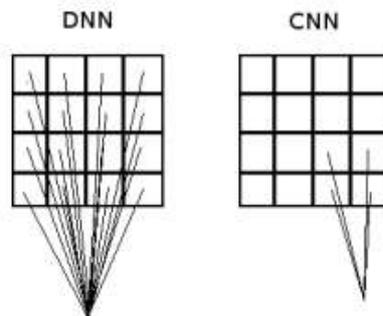


FIGURA 7 – Modelo de extração de características de redes DNNs e CNNs

Após o desenvolvimento de Lecun, outras redes foram desenvolvidas utilizando as camadas de convolução, como mostra a Figura 8, de modo que a medida que fosse elevado a profundidade (número de camadas) da rede o nível de abstração das características extraídas aumentavam, obtendo assim melhores resultados [10]. Atualmente existem redes com mais de 100 camadas como a rede “Resnet” que comprovam a relação inversamente proporcional entre número de camadas e o erro de classificação [11].

Para o desenvolvimento do classificador de nível de severidade de poluição baseado em CNN, foi utilizado a rede VGG16 [12] como inspiração, do qual apenas suas camadas fully connected foram modificadas, alterando-se o número de neurônios e adicionando uma camada de dropout, como mostra a Figura 8.

5.1 - Arquitetura da rede

A arquitetura utilizada neste trabalho baseou-se na rede VGG-16, e mais explicitamente, em todos os blocos convolutivos utilizados para extração de features. Do qual, cada bloco é formado por duas ou três camadas de convolução em sequência, cada uma com as seguintes configurações, kernel (3,3), stride (2,2) e padding “same”, após as camadas de convolução uma camada de maxpooling com kernel (2,2) e stride (2,2) formando deste modo um bloco.

Foram utilizadas imagens com dimensões reduzidas em (1x64x64) sendo imagens monocromáticas, ao invés de dimensões (224x224x3), valor original das imagens de entrada da rede VGG-16 [12].

Após os blocos de camadas convolucionais (conv) e maxpooling (pool), os features foram vetorizados (flatten) e então submetidos as camadas fully connected (fc) com 4096 neurônios, dropout(0,4), fully connected com 1024 neurônios e softmax(3). Com esta arquitetura chegou-se a 27.304.643 parâmetros treináveis como visualizado na Figura 9

Em todas as camadas que possuem função de ativação, foi utilizado a função de ativação Relu.

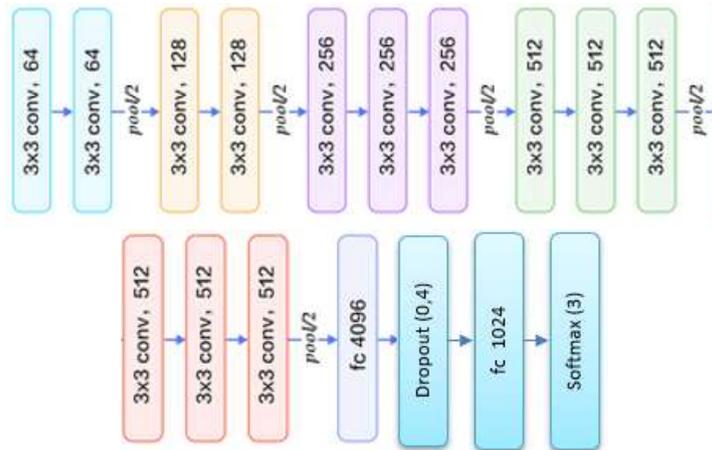


FIGURA 8– Arquitetura utilizado no classificador

Layer (type)	Output Shape	Param #
block1_conv1 (Conv2D)	(None, 64, 64, 64)	640
block1_conv2 (Conv2D)	(None, 64, 64, 64)	36928
block1_pool (MaxPooling2D)	(None, 64, 32, 32)	0
block2_conv1 (Conv2D)	(None, 128, 32, 32)	73856
block2_conv2 (Conv2D)	(None, 128, 32, 32)	147584
block2_pool (MaxPooling2D)	(None, 128, 16, 16)	0
block3_conv1 (Conv2D)	(None, 256, 16, 16)	295168
block3_conv2 (Conv2D)	(None, 256, 16, 16)	590080
block3_conv3 (Conv2D)	(None, 256, 16, 16)	590080
block3_pool (MaxPooling2D)	(None, 256, 8, 8)	0
block4_conv1 (Conv2D)	(None, 512, 8, 8)	1180160
block4_conv2 (Conv2D)	(None, 512, 8, 8)	2359808
block4_conv3 (Conv2D)	(None, 512, 8, 8)	2359808
block4_pool (MaxPooling2D)	(None, 512, 4, 4)	0
block5_conv1 (Conv2D)	(None, 512, 4, 4)	2359808
block5_conv2 (Conv2D)	(None, 512, 4, 4)	2359808
block5_conv3 (Conv2D)	(None, 512, 4, 4)	2359808
block5_pool (MaxPooling2D)	(None, 512, 2, 2)	0
Flatten (Flatten)	(None, 2048)	0
fc1 (Dense)	(None, 4096)	8392704
dropout_2 (Dropout)	(None, 4096)	0
fc2 (Dense)	(None, 1024)	4195328
predictions (Dense)	(None, 3)	3075

Total params: 27,304,643
Trainable params: 27,304,643
Non-trainable params: 0

Train on 74977 samples, validate on 6000 samples

FIGURA 9 - Detalhamento da arquitetura utilizada

5.2 - Ajuste de hiperparâmetros

Após determinar a arquitetura, buscou-se ajustar os hiperparâmetros de maneira a obter bons resultados quanto à convergência e generalização da rede. Foi utilizado apenas o otimizador SGD (Stochastic gradient descent) devido ao seu menor custo computacional. As configurações testadas podem ser visualizadas na Tabela 4.

Tabela 4 – Hiperparâmetros testados

ID	LR	Épocas	Batch size	Loss	ACC (%)
Model 1	0,0001	10	64	1,0973	43,20
Model 2	0,001	10	64	0,1686	94,52
Model 3	0,001	20	64	0,0677	98,08
Model 4	0,0005	30	64	0,0857	97,57
Model 5	0,001	25	64	0,0594	97,82
Model 6	0,0009	25	64	0,0633	97,95
Model 7	0,0007	25	64	0,0642	98,07

Devido ao modelo 5 apresentar exatidão (ACC) aceitável em 97,82 % e a menor perda (Loss) entre os demais, o mesmo foi considerado adequado para uso na classificação do nível de severidade do nível de poluição. Na Figura 10 pode ser visualizado os resultados adquiridos.

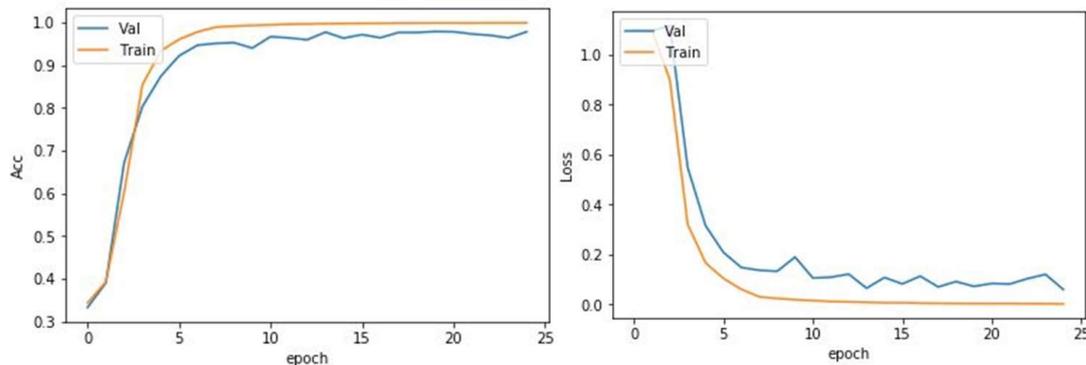


FIGURA 10 - Resultados do treinamento do modelo 5

O comportamento razoavelmente suave apresentado pelo modelo durante o treinamento indica que a taxa de aprendizado da ordem de 10^{-3} , proporcionou a convergência e generalização do modelo sem apresentar comportamento de overfitting. Deste modo este modelo foi novamente testado realizando a predição sobre os frames do conjunto de teste, obtendo 98,57 % de acurácia, entre 1050 frames, indicando elevado poder de generalização do modelo.

6.0 - CONCLUSÃO

Embora as imagens de corona UV sejam representativamente muito abstratas, não indicando desta forma, nenhum padrão aos humanos, as técnicas de redes CNN proporcionaram resultados muito promissores para classificá-las. Desta forma, um modelo CNN treinado com um dataset vasto e diversificado, tem potencial para auxiliar no diagnóstico de isoladores poluídos instalados no campo.

Quanto ao modelo, após a avaliação da arquitetura com diferentes valores de hiperparâmetros, observou-se que a quinta configuração apresentou o melhor resultado, devido ao seu comportamento suave, embora a utilização do algoritmo de aprendizado SGD tenha proporcionado um resultado ruidoso, aumentando o parâmetro "loss".

A utilização de imagens com apenas níveis de cinza não apresentou nenhum dano aos resultados, indicando que a característica "cor" não possui influência notável no aprendizado e na generalização do modelo, necessitando apenas das características de forma e posição.

7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) D. R. DE MELLO, R. T. D. C. JUNIOR, J. T. BATISTA, M. E. MELO. Avaliação do grau de poluição em instalações de transmissão, subestação e distribuição. Brasil
- (2) R. H. S. ROCHA, Reconhecimento de objetos por redes neurais convolucionais. Dissertação de Mestrado. PUC-Rio, Brasil, 2015.
- (3) ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. High-voltage insulators to be used on a.c. systems - Artificial pollution tests - NBR 10621, Brasil.
- (4) INTERNATIONAL ELECTROTECHNICAL COMMISSION, "Selection and dimensioning of high-voltage insulators intended for use in polluted conditions - Part 1: Definitions, information and general principles - IEC/TS 60815-12008.
- (5) K. B. BRITO, ET AL., Attribute extraction and sensitivity analysis for classification of polymeric insulators ultraviolet images, 20th International Symposium on High Voltage Engineering (ISH), Buenos Aires, Argentina, 2017.
- (6) M. LINDNER, Daylight corona discharge imager: High Voltage Engineering Eleventh International Symposium, Vol. 4, pp. 349 – 352, 1999.
- (7) W. P. P. BARROS. Análise do Efeito Corona para Diagnóstico de Isoladores Poliméricos. Dissertação de Mestrado. Universidade Federal de Campina Grande (UFCG), Brasil, 2011.
- (8) D. HUBEL, H. WIESEL, T. N. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. The Journal of physiology, 160:106–154, Jan. 1962. 1.
- (9) Y. LECUN, L. BOTTOU, Y. BENGIO, P. HAFFNER. Gradient-based learning applied to document recognition. In: Haykin, S.; Kosko, B., editors, intelligent signal processing, p. 306–351. IEEE Press, 2001. 1, 3, 4.2.
- (10) KRIZHEVSKY, A., SUTSKEVER, I., AND HINTON, G. E. ImageNet classification with deep convolutional neural networks. In NIPS, pp. 1106–1114, 2012
- (11) HE, K., ZHANG, X., REN, S. AND SUN, J. Deep Residual learning for image recognition. 2015.
- (12) SIMONYAN, K. AND ZISSERMAN, A. Very Deep convolutional networks for large-scale image recognition.

8.0 - DADOS BIOGRÁFICOS



Yuri dos Reis Oliveira

Graduado em engenharia elétrica pela Unifoa em 2014 e pós-graduado em metrologia pela Puc-Rio obtendo grau mestre em 2016. O autor possui experiências em ensaios de alta tensão com tensões impulsivas e em



XXV SNPTEE
SEMINÁRIO NACIONAL DE PRODUÇÃO E
TRANSMISSÃO DE ENERGIA ELÉTRICA

4720
GTM/09

10 a 13 de novembro de 2019
Belo Horizonte - MG

frequência industrial e calibração de sistemas medição aprovados e de referência. Atualmente tem trabalhado com processamento digital de imagens e inteligência artificial especificamente redes neurais, buscando aplicações nas áreas de ensaios e diagnósticos de equipamentos de alta tensão.