

GRUPO DE ESTUDO DE LINHAS DE TRANSMISSÃO - GLT

USO DE MACHINE LEARNING PARA INSPEÇÃO DE LINHAS DE TRANSMISSÃO E REDES DE DISTRIBUIÇÃO

RENAN BARBOSA MARTINS DOS SANTOS(1); CRISTINA YURIKA KONATU OBATA ADORNI(1); GIOVANNI MOURA DE HOLANDA(1); MARCOS VANINE PORTILHO DE NADER(1); FERNANDO ANTONIO RAUTENBERG FINARDI(1); RONDINELE PINHEIRO SILVA(2); MARIO DAMIÃO CAPARROZ R JUNIOR(2); EMANUEL ANTONIO MOUTINHO(2); ILANA FRANÇA(2) FITEC(1); EQUATORIAL ENERGIA MARANHÃO(2)

RESUMO

Este artigo apresenta um projeto de P&D com o objetivo de introduzir o uso de machine learning para otimizar os processos de inspeção da Equatorial Energia, na detecção de defeitos nos elementos de rede das linhas de transmissão, por meio de imagens capturadas por drones. A solução proposta utiliza algoritmos de deep learning para a detecção dos elementos de rede e classificação entre não defeituosos e defeituosos, sendo que, no último caso, informa o tipo de defeito. O uso de drones no processo agiliza as atividades de campo, permitindo obter imagens de diferentes ângulos além de tornar o processo mais ágil e seguro.

PALAVRAS-CHAVE

Deep Learning, Classificação de defeitos, Distribuição de Energia Elétrica, Drone, *Machine Learning*.

1.0 INTRODUÇÃO

Na transmissão e distribuição de energia, os componentes da rede elétrica têm papel fundamental no desempenho e confiabilidade do serviço. Esses elementos estão sempre sujeitos a fatores externos, especialmente poluição e eventos climatológicos, que contribuem diretamente para a degradação de suas propriedades físico-elétricas (Domingues, 2012; Yang et al., 2019), levando-os a um comprometimento de seu desempenho operacional e mesmo a faltas que podem ocasionar a interrupção do serviço.

As consequências dessas faltas ou defeitos podem incluir perdas não apenas financeiras às distribuidoras, mas também comprometer a qualidade e confiabilidade do serviço prestado, contribuindo para o descontentamento do consumidor final. Para assegurar a excelência na entrega de energia elétrica ao consumidor final, tarefas como a inspeção das linhas de transmissão e distribuição são essenciais para a detecção precoce de defeitos em seus componentes e devem ser executadas periodicamente (Jalil et al., 2019). As empresas distribuidoras têm também como responsabilidade a tarefa que consiste do processo de inspeção e manutenção dos componentes das linhas de transmissão. Essa tarefa é de alto custo, quando há a necessidade de utilização de um helicóptero para as inspeções, e de alto risco, quando o inspetor precisa subir na torre para fazer uma inspeção visual minuciosa em seus componentes (Whitworth et al., 2001).

É importante enfatizar também que um dos maiores problemas dessa inspeção minuciosa se encontra no quão lenta ela pode ser e no fato de que especialistas em detecção de defeitos são enviados para áreas muitas vezes remotas para efetuá-la (Jalil et al., 2019). No caso de isoladores elétricos, alguns métodos avaliam sua degradação através de sensores de correntes de fuga (por exemplo, Mendonça et al., 2010) ou sensores ópticos coletando dados paramétricos em tempo real (por exemplo, Aragão et al., 2018) ou propriedades inerentes ao material do dispositivo, por exemplo, termocrômica (Martins, 2015) ou ultrassom aplicado a isoladores poliméricos (Silva et al., 2012).

O recente e expressivo crescimento da utilização de veículos aéreos não tripulados (VANTs) tem sido bastante difundido em diversas áreas da engenharia, auxiliando no monitoramento de estruturas de interesse na captura de imagens consideradas “pontos chave” em locais de difícil acesso e de grande risco, possibilitando a observação de objetos e eventos a partir de ângulos ainda não explorados por métodos tradicionais. Nas linhas de transmissão de energia, os VANTs, ou “drones” como ficaram mais conhecidos em geral, têm sido aplicados para inspecionar os elementos da rede (Homma et al., 2017).

Essas imagens, capturadas pelos drones em questão, podem ser tratadas para servir de base na extração de informações importantes e precisas sobre os objetos ou eventos observados de forma automática, a partir de métodos de visão computacional aliada com o aprendizado de máquinas (Homma et al., 2017). Asiegbu et al. (2012),

por exemplo, apresentam uma revisão da literatura referente à detecção de defeitos em equipamentos elétricos, usando a análise de imagens para detectar e classificar tais defeitos. Yang et al. (2019), por sua vez, utilizam imagens capturadas por drones para detectar rupturas em isoladores, usando para tanto a técnica *deep learning* com redes convolucionais, e obtendo uma taxa de identificação correta de mais de 98%.

Este trabalho explora o uso de drones para imageamento e de técnicas de reconhecimento de imagens baseadas em *deep learning*, implementando-as em uma aplicação prática: a inspeção de elementos que compõem as redes de transmissão e distribuição da empresa Equatorial Energia, com a finalidade de agilizar, aumentar a assertividade e diminuir os custos desse processo, quando comparado à inspeção convencional por equipe em solo e em cesta aérea. Dessa forma, objetiva-se abranger áreas de difícil acesso, melhorar a precisão das inspeções, evitar a exposição de inspetores a atividades perigosas e consequentemente reduzir os riscos de acidentes.

O uso de técnicas de Inteligência Artificial (IA), em especial de *machine learning* e *deep learning*, aplicadas ao imageamento por drone para a inspeção de LT (Linha de Transmissão) e RD (Rede de Distribuição) de concessionárias de distribuição de energia elétrica, representa uma nova abordagem de solução para apoiar decisões e melhorar o processo de inspeção. Inserida no projeto de P&D da ANEEL/Equatorial, a proposta de solução apresentada neste artigo reflete o estado da arte em tecnologia de visão computacional, e utiliza Redes Neurais Convolucionais (CNNs) para a análise e interpretação de imagens capturadas nas inspeções. Os primeiros resultados obtidos com essa abordagem apontam uma precisão média (mAP) de 0,9972 para detecção de isoladores nas imagens de torres, uma acurácia de teste de 99,47% para a classificação de isoladores e um mAP de 0,9340 para detecção de vazamento.

O presente artigo está estruturado da seguinte forma: Na Seção 2.0, é descrita a metodologia adotada para desenvolvimento da ferramenta computacional baseada em *machine learning*; na Seção 3.0, é apresentado o estudo de caso escolhido para aplicar a metodologia, tratando-se especificamente da detecção do defeito Isolador Vazado em Linha de Transmissão; e finalmente na Seção 4.0, são tecidas as principais conclusões obtidas até o momento com este trabalho, destacando-se o aprendizado da aplicação do método e da ferramenta, bem como a precisão dos resultados associados ao processo de detecção de defeitos de elementos de rede e os próximos passos para a evolução do tema.

2.0 METODOLOGIA DE DESENVOLVIMENTO

A Rede Neural Convolucional é uma arquitetura de aprendizado profundo (*deep learning*) inspirada no mecanismo de percepção visual dos seres vivos. Em 1990, LeCun et al. (1990) publicaram o artigo seminal que estabelece a estrutura moderna da CNN e, posteriormente, a melhorou em (1998). Eles desenvolveram uma rede neural artificial de múltiplas camadas chamada LeNet-5, que poderia classificar dígitos manuscritos. Como outras redes neurais profundas, o LeNet-5 possui várias camadas e pode ser treinado com o algoritmo de retropropagação (LeCun, 1989). Pode obter representações efetivas da imagem original, o que a torna possível reconhecer padrões visuais diretamente de *pixels* brutos com pouco a nenhum pré-processamento. Apesar de essas técnicas terem tido pouca atenção na década de 90 devido a limitações relacionadas à quantidade de dados disponíveis e poder computacional, atualmente, devido a grande evolução destes pontos, essas mostraram-se grandes aliadas na melhoria e inovação de processos já existentes.

Para o desenvolvimento do algoritmo de *deep learning*, centrado em CNNs, para análise e interpretação de imagens capturadas nas inspeções, adotou-se uma metodologia que tem como modelo de referência o CRISP (Cross Industry Standard Process for Data Mining) (Wirth&Hipp, 2000). Trata-se de um modelo padrão de processo, que é constituída numa sequência de cinco passos. A aplicação desses passos no desenvolvimento dos modelos deste projeto é descrita a seguir.

Passo 1: Definição do problema e dos dados

O primeiro passo do processo foi identificar o problema a ser resolvido e os dados que foram usados na solução do problema. A etapa de aprendizado ocorre por meio da identificação de padrões nas imagens. Logo, foi feito o possível para que as imagens capturadas para treinamento estivessem enquadradas no mesmo procedimento em que serão capturadas as imagens para a análise em produção.

Os principais dados usados no projeto foram as imagens que coletadas por drones. Outros dados tabulares também foram requeridos, tais como latitude e longitude. Esses dados possibilitam estabelecer um *link* entre o ativo capturado na imagem e a estrutura em que ele se encontra.

Passo 2: Obtenção dos dados e definição da Plataforma

Nessa fase, estabeleceu-se uma quantidade mínima de imagens para que o modelo pudesse abstrair corretamente as classes relevantes e/ou os formatos e características dos objetos a serem identificados. Outro fator importante estabelecido é o critério de avaliação (ou métricas) utilizado na fase de treinamento do modelo. O objetivo desta verificação é avaliar a melhoria no comportamento do modelo conforme a modificação de seus hiper-parâmetros de modo que se possa alcançar um resultado satisfatório quando implementado em produção.

É importante observar que, dependendo do problema em questão, a obtenção dessas imagens não ocorre de forma tão simples devido a motivos como a ausência de registros fotográficos das situações de interesse e, mesmo que hajam tais registros, os objetos de interesse nas imagens podem estar em uma localidade, angulação ou condição diferentes do procedimento/ferramenta de captura proposta na nova solução apresentada.

Essa fase também incluiu a definição da plataforma de desenvolvimento e implantação. Por se tratar de um problema de processamento intenso, foi importante definir na arquitetura quantas CPUs (unidades centrais de processamento) e GPUs (unidades de processamento gráfico) foram necessárias para cada fase.

Passo 3: Pré-processamento dos Dados

Dependendo do caso, o processamento direto dos dados brutos obtidos pode não ser a melhor abordagem. Por isso, foi necessária a implementação prévia de algumas técnicas para extrair o máximo de características referentes ao objeto ou classe de interesse, como o destaque de tons de cores, ênfase de bordas, etc. Algumas das técnicas são: a aplicação de filtros para suavizar os ruídos de uma imagem, aplicação de segmentação e filtros de frequência, aplicar a normalização dos *pixels* da imagem para que tenham a mesma escala (operações em matrizes), equalização de histogramas e redução de dimensionalidade da imagem.

Data augmentation

O aumento de dados de entrada é uma técnica bastante difundida que consiste na geração de novos dados de treinamento a partir dos dados existentes. Isso ajuda a diminuir o problema da disponibilidade de um número reduzido de imagens; no entanto um cuidado deve ser tomado para não se criar imagens que não correspondam à realidade. Além disso, a técnica deve ser utilizada com moderação, a fim de evitar a superespecialização do modelo (*overfitting*¹).

Passo 4: Treinamento e Avaliação do Modelo

Nessa fase foi construído o modelo e feita a avaliação desse modelo. Neste projeto, foram utilizadas as ferramentas do SAP Leonardo Machine Learning Foundation². O SAP Leonardo disponibiliza em seus serviços soluções baseadas em duas arquiteturas de redes neurais. Uma delas trata-se da arquitetura Inception-v3. A ferramenta utiliza a técnica Transfer Learning, que reaproveita o treinamento da etapa de extração de características das imagens de um modelo treinado para um volume extremamente alto de dados (ImageNet), com condições de classificar satisfatoriamente mais de 1.000 classes diferentes, na composição de uma solução final. Dessa forma, diminui-se a necessidade de processamento exagerado no treinamento, pois somente são modificados os parâmetros das camadas finais do modelo.

O Inception-v3 é um modelo de classificação e detecção de objetos em imagens, e um dos modelos estado da arte de redes neurais convolucionais (ver, por exemplo, Szegedy et al., 2016). Esse modelo consiste em duas etapas: a extração de características, efetuada através de camadas convolucionais e classificação, efetuada por camadas totalmente conectadas. Foi um marco no desenvolvimento de classificadores de CNN e continua em evolução.

A outra rede é utilizada a arquitetura YOLO (*You Only Look Once*), que fornece uma detecção baseada em regiões locais, utilizando uma única rede CNN para classificar e localizar objetos (Redmon et al., 2015). Essa rede conta com estratégias como a normalização de subgrupo, a remoção de camadas totalmente conectadas, *k-boxes*, entre outras. É importante mencionar que neste trabalho conseguiu-se combinar resultados satisfatórios com agilidade na inferência aos modelos e apresentação dos resultados no sistema desenvolvido, onde esses modelos estão integrados.

Para avaliar os modelos de detecção de objetos apresentados neste artigo, foi utilizada a métrica de precisão média (em inglês Average Precision - mAP), que leva em consideração a precisão de todas as classes de um conjunto de dados, conforme apresentado na Equação (1).

$$mAP = \frac{\sum_{k=1}^n P_{(k)} * rel_{(k)}}{R} \quad (1)$$

Onde n representa o número de resultados, $P_{(k)}$ é a precisão da classe k , $rel_{(k)}$ está relacionado com a relevância da classe e R é o número de classes relevantes do conjunto de dados.

Já para a avaliação dos modelos de classificação de imagens, foi utilizada a métrica de acurácia de validação combinada com a análise da função de perda de entropia cruzada do modelo, comumente usada para quantificar a diferença entre duas distribuições de probabilidade. A fórmula do cálculo da acurácia de um modelo é bem simples

¹ *Overfitting*: Problema enfrentado nos treinamentos de ML que ocorre quando um modelo se ajusta demais aos dados de treinamento e, assim, não consegue generalizar a previsão correta de novos dados de entrada

² Ver, por exemplo, <https://www.sap.com/products/machine-learning-foundation.html?infi=6c03ad17-5bd0-4fdf-a5a7-22fd00599a19>

e leva em consideração as predições corretas do modelo e as compara com o total de medições. Essa fórmula é apresentada na Equação (2).

$$Acurácia = \frac{Positivos\ Verdadeiros\ (TP) + Negativos\ Verdadeiros\ (TN)}{Total\ de\ Inferências} \quad (2)$$

A fórmula para cálculo da função de perda de entropia cruzada é dada pela Equação 3.

$$H_p(q) = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M y_{ij} \log p_{ij} \quad (3)$$

Onde N é o número de observações, M é o número de classes, y_{ij} indica se a classe j é a classe correta para a observação i , P_{ij} é a probabilidade dada pelo modelo de atribuir a classe j para a observação i .

Além da avaliação automática executada pelos serviços SAP descritos acima, também foi elaborado um *script* de teste em Python para avaliação fora da plataforma. Esse *script* é utilizado para testar os modelos de detecção de objetos e retorna a avaliação para um conjunto de imagens de teste. Com esse resultado, tem-se uma avaliação mais completa da solução. Como exemplos dessas métricas temos a acurácia para avaliar o número de acertos, a precisão para conhecer qual a porcentagem de predição de defeitos que são realmente defeitos e a pontuação F1 que é um indicador que avalia o balanceamento entre a precisão e o recall (porcentagem de defeitos que são detectados).

Passo 5: Inferência do modelo

Realizados o aprendizado e a otimização mencionados no item anterior, pôde-se então efetuar a inferência a partir do modelo e utilizar seus resultados de predição (classificação e detecção) para, no caso do projeto, fazer a identificação de defeitos de ativos nas imagens de inspeção.

Eventualmente o sistema apresentará erros nas inferências. Por isso, o sistema desenvolvido leva em consideração esses casos e tem uma tela de aprovação da predição do *machine learning*, conforme ilustrado na Figura 1.




FIGURA 1: Tela de aprovação – Erro na inferência
Fonte: Elaboração própria

Quando há um equívoco na inferência no modelo de *machine learning*, o operador pode recusar a previsão dada e apontar o defeito real do isolador (ou a ausência dele). Desse modo, cria-se uma base de dados para retreinamento de melhoria constante dos modelos, aproveitando os dados gerados em produção para aumentar cada vez mais a base de dados de treinamento dos modelos.

3.0 ESTUDO DE CASO: DETECÇÃO DO DEFEITO ISOLADOR VAZADO EM LT

O estudo de caso escolhido para aplicar a metodologia foi a detecção do defeito Isolador Vazado em LT.

Para a detecção desse tipo de defeito, foi elaborado primeiramente um processo para a detecção na imagem do isolador, ou seja, a partir da imagem de uma torre (ou parte dela), extraem-se todos os isoladores contidos. A segunda etapa consiste em classificar o tipo de cada isolador obtido na etapa anterior. Essa etapa é importante pois, mesmo

se tratando de um mesmo defeito em isoladores, como isolador vazado ou quebrado, há características significativamente distintas apresentadas em função do seu tipo. Apenas de posse da imagem dos isoladores extraídos e classificados por tipo, é possível iniciar as análises de presença de defeito de forma mais confiável e precisa. Resumindo, neste estudo de caso, a solução proposta faz o uso de três (3) modelos de *machine learning* diferentes.

1. Modelo de Object Detection para detecção de isoladores;
2. Modelo de Image classification para segregá-los por tipo;
3. Modelo de Object Detection para identificação de Vazamento - caso o isolador seja polimérico;

Como em todo e qualquer fluxo de modelos, o resultado do conjunto sempre é fortemente dependente do bom comportamento das primeiras etapas. Ou seja, para identificar os defeitos presentes nos isoladores é fundamental que o modelo de detecção e classificação de isoladores estejam funcionando da maneira mais assertiva possível. Isso porque pretende-se automatizar a extração e classificação de isoladores com todo e qualquer tipo de defeito, principalmente aqueles que possuem um número reduzido de imagens disponíveis, e dos defeitos de difícil obtenção e incremento de seu conjunto de dados. Foram então aplicados os cinco passos da metodologia.

Passo 1: Definição do problema e dos dados

O problema definido foi a detecção de defeito em isoladores de LT, em especial o defeito de isolador vazado, usando imagens obtidas tanto por meio de câmeras de mão convencionais, quanto por drones.

Passo 2: Obtenção dos dados e definição da Plataforma

Como a obtenção de imagens de defeitos com boa qualidade é extremamente difícil, foi definido um mínimo de 150 imagens para o início de um treinamento de detecção do defeito, com uso da plataforma de desenvolvimento e implantação SAP Leonardo Machine Learning Foundation, numa infraestrutura que opera em nuvem. Apesar de ter sido estabelecido esse número mínimo, quanto mais imagens representativas dos defeitos forem obtidas, melhor será o modelo..

O dispositivo de captura utilizado foi o drone Mavic Zoom 2. As imagens capturadas por ele têm resolução de 12MP, tecnologia full HD 4k (4000x3000) e foco automático. Os inspetores da Equatorial Energia foram treinados para manusear o drone com perícia de forma que possam, mesmo o drone sendo submetido a interferências eletromagnéticas causadas pelas linhas de alta tensão, capturar imagens das torres e isoladores de ângulos favoráveis, sem a necessidade de terem que subir na torre para tal tarefa. Esse processo, além de tornar as inspeções mais seguras para os inspetores, agilizam o tempo de inspeção de um trecho. Essa agilidade será depois convertida em tempo para que novas inspeções sejam incorporadas no planejamento periódico, tornando a rede de transmissão mais segura e confiável.

Passo 3: Pré-processamento dos Dados

Os principais aspectos do pré-processamento das imagens foram a correção do brilho e saturação das imagens e a redução no tamanho de seu arquivo para 1100x820. Essa mudança no tamanho da imagem é necessária, pois o serviço SAP tem uma limitação no tamanho das imagens de treino. Essa limitação não ocorre na etapa de inferência.

Passo 4: Treinamento e Avaliação do Modelo

Para treinamento dos modelos, foram utilizados dois serviços do SAP Leonardo Machine Learning Foundation: o serviço de detecção de objetos e o serviço de classificação de imagens. O primeiro consiste no retorno das coordenadas das *bounding boxes* que envolvem o objeto de interesse a partir da avaliação da imagem inserida. O segundo calcula e retorna a lista de classes previamente configuradas pelo usuário e suas respectivas probabilidades de certeza na previsão, para cada imagem individual. Cada imagem é atribuída para a classe cuja probabilidade é a maior. Esses serviços utilizam a técnica Transfer Learning para retreinamento de um modelo previamente treinado e otimizado baseado na arquitetura Inception-v3. Para treinar o modelo foram adotados os seguintes critérios:

- As métricas utilizadas foram mAP (mean Average Precision) para modelos de detecção de objetos e a acurácia para validação e a função de perda de entropia cruzada para modelos de classificação de imagens.
- Tratamento de Overfitting & Underfitting: as técnicas usadas foram Model Checkpoint, salvando o melhor modelo e Early Stopping com paciência de 15 épocas por se tratar de uma rede com uma arquitetura extremamente robusta.
- Hiperparâmetros: número de iterações máximo de 15.000.

Em resumo, o processo de análise automática na identificação de defeitos em um isolador começa na captura de imagens durante a inspeção por meio de um drone, seguido pelo carregamento dessas imagens no sistema para serem avaliadas pelos modelos de aprendizado de máquina. O primeiro modelo identifica todos os isoladores da imagem, seguido de uma etapa de recorte e extração dos isoladores identificados. O segundo modelo classifica o tipo dos isoladores extraídos. Finalmente, o terceiro modelo, específico para o defeito de vazamento do tipo de isolador (por

exemplo, polimérico), é criado a partir do serviço de detecção de objetos para identificar se o isolador apresenta ou não vazamentos. A Figura 2 apresenta o fluxo de modelos utilizados para melhor entendimento da solução.

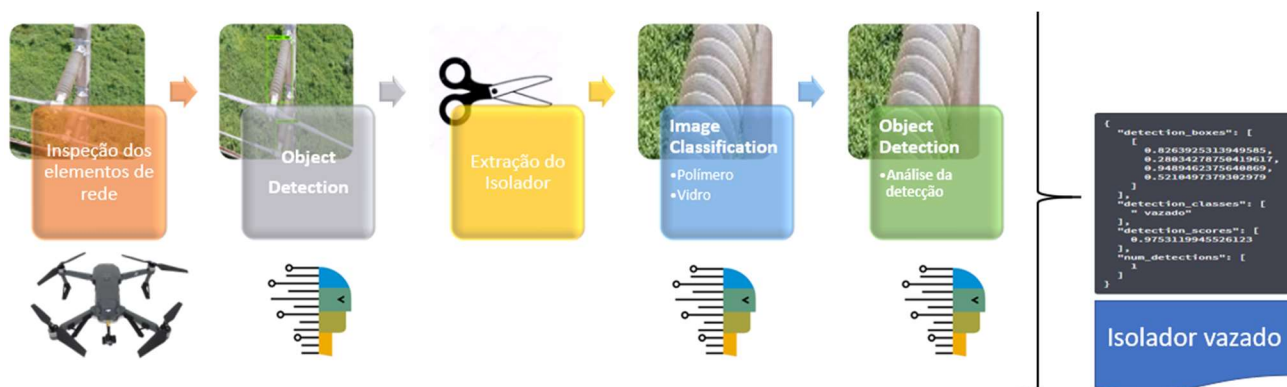


FIGURA 2: Fluxo de modelos para detecção de defeitos em isoladores. *Elaboração própria.*

Os resultados obtidos, tendo como base as métricas mAP e acurácia, encontram-se nas Tabelas 1 e 2.

TABELA 1: Resultado do modelo de detecção de isoladores

| Modelo | Melhor Iteração | mAP Treino | mAP Teste |
|-----------------------|-----------------|------------|-----------|
| Deteção de Isoladores | 13044 | 1 | 0,997218 |

TABELA 2: Resultado do modelo de classificação de isoladores

| Modelo | Melhor Iteração | Função de Perda - Validação | Acurácia de Validação | Acurácia de Teste |
|-----------------------------|-----------------|-----------------------------|-----------------------|-------------------|
| Classificação de Isoladores | 14 | 0,076474 | 98,17% | 97,53% |

A partir dessas tabelas, observa-se que os resultados foram bastante satisfatórios, combinando acurácia de testes elevada com o baixo valor nas funções de perda para a classificação e valor de mAP > 0,9 para os modelos de detecção de objetos. As análises desses resultados garantem a confiabilidade na execução automatizada de parte do processo de inspeção de linhas de transmissão. Resultados esses que também refletem o comportamento satisfatório na aplicação em produção, como mostrado nas figuras a seguir.

A Figura 3 ilustra dois casos de detecção de isoladores nas torres. Em ambos são identificados isoladores com probabilidade de 99%. Na Figura 4, é apresentada uma classificação de tipo de isoladores – o resultado indica que o isolador é polimérico com 99,7% de probabilidade. Por fim, a Figura 5 contém a detecção do defeito de vazamento para duas figuras. Também nesse exemplo, os objetos são detectados (defeitos) com probabilidade de 99%.




FIGURA 3: Exemplo da inferência no modelo de detecção de isoladores. Fotos: Equatorial



FIGURA 4: Exemplo da inferência no modelo de classificação de isoladores por tipo. Foto: Equatorial




FIGURA 5: Exemplo da inferência no modelo de detecção de vazamento em isoladores poliméricos. Fotos: Equatorial

4.0 CONCLUSÃO

Este artigo apresentou a motivação, a metodologia e o desenvolvimento de uma solução de detecção de defeitos em elementos de rede de energia elétrica a partir de imagens geradas por drones ou outros dispositivos. As imagens capturadas são submetidas a um pré-processamento e, em seguida, a um fluxo de modelos de *deep learning*. Um caso de uso é apresentado para o elemento de rede isolador polimérico quando o defeito é vazamento.

A solução proposta tem como base a utilização de serviços da plataforma SAP Leonardo, mais especificamente os serviços de detecção de objetos e classificação. A arquitetura da solução de *deep learning* proposta consiste de um pipeline em que inicialmente detecta-se os isoladores das imagens das torres. Como segundo passo, um programa em Python recorta cada isolador detectado, gerando um arquivo que é submetido para classificação do tipo de isolador. Uma vez obtido o tipo do isolador, efetua-se, como último estágio, a detecção de um defeito para um tipo de isolador.

O estágio atual do projeto é a construção do sistema que já usa a inferência dos modelos criado para identificar defeitos no isolador, sendo parte da solução para análise de inspeção de linhas de transmissão, usando imageamento por drones. Outros defeitos estão sendo identificados usando a mesma metodologia proposta.

Com continuidade ao trabalho atual, modelos para detecção de outros defeitos de isoladores – tais como a identificação de isoladores poluídos, quebrados e com componentes oxidados – serão treinados e colocados em operação. Também, serão desenvolvidas soluções para os outros tipos de isoladores identificados, como de vidro e de porcelana, englobando os isoladores utilizados em redes de distribuição com voltagem reduzida.

Os serviços SAP segmentam os arquivos de entrada para parametrizar os modelos em dados de treinamento e dados de teste. Os resultados apresentados computam as métricas pré-definidas nos serviços. Como um próximo trabalho do projeto, será desenvolvido um *script* para que o teste também seja efetuado através do uso das APIs de inferência.

As vantagens desse desenvolvimento são que esse último teste corresponde exatamente ao que está sendo implantado no sistema para a operação e a inclusão do cálculo de outras métricas que permitem ao usuário fazer uma avaliação mais completa da solução. Exemplos dessas métricas são: acurácia para avaliar o número de acertos; precisão para conhecer qual a porcentagem de predição de defeitos que são realmente defeitos e F1 que é um indicador que avalia o balanceamento entre a precisão e o recall (porcentagem de defeitos que são detectados).

A arquitetura descrita foi aplicada para o caso de uso estabelecido e apresentou um resultado bastante satisfatório que permite colocar esse serviço para a operação da concessionária. O sistema foi desenvolvido de forma que inicialmente, o usuário fornece *feedback* de cada diagnóstico que serve para validação do sistema e aumento da quantidade de dados para uso em retreinamento dos modelos, permitindo gerar versões futuras da aplicação com melhores acurácias.

AGRADECIMENTOS

Os autores agradecem a ANEEL (Agência Nacional de Energia Elétrica) cujo programa de Pesquisa & Desenvolvimento viabilizou a realização deste trabalho, bem como ao time de pesquisadores e técnicos envolvidos no projeto, especialmente Lucas P. A. Pinheiro.

REFERÊNCIAS BIBLIOGRÁFICAS

- ARAGÃO, B.L.C.; LIMA, L.L.; FIGUEIREDO, L.O.; PEREIRA, H.A. Sistema de transmissão óptico de dados de isoladores presentes em linhas de alta tensão. *Revista de Engenharia e Tecnologia*, 10 (2), 2018, pp. 71-80.
- ASIEGBU, G.O.; HAIDAR, A.M.A.; HAWARI, K. A Review of Defect Detection on Electrical Components Using Image Processing Technology. *Proc. Fourth International Conference on Signal and Image Processing*, 2012, pp 247-255.
- DOMINGUES, E.S. *Improved condition of composite insulator*. PhD Thesis, University of Manchester, 2012.
- FUKUSHIMA, K. NEOCOGNITRON: A self-organizing neural network model for a mechanism of visual pattern recognition. *Biol. Cybernetics* 36, 1980, pp. 193-202.
- HECHT-NIELSEN, R. Theory of the back propagation neural networks. *Proc. International Joint Conference on Neural Networks* 1, v. 1, 1989, pp. 593-611.
- HOMMA, R.F.; SOHN, O.; BOSE, R.C. Analysis of the recognition and localisation techniques of power transmission lines components in aerial images acquired by drones. *CIED, Open Access Proc. J.*, Vol. 2017, Iss. 1, 2017, pp. 29-32. Doi: 10.1049/oap-cired.2017.1193
- HUBEL, D.H.; WIESEL, T. N. Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, 1968, pp. 215-243.
- JALIL, B.; LEONE, G.R.; MARTINELLI, M.; MORONI, D.; PASCALI, M.A.; BERTON, A. Fault Detection in Power Equipment via an Unmanned Aerial System Using Multi Modal Data. *Sensors* 19 (13), 2019, p. 3014. Doi: 10.3390/s19133014
- LECUN, Y.; BOSER, B.; DENKER, J. S.; HENDERSON, D.; HOWARD, R. E; HUBBARD, W.; JACKEL, L. D. Handwritten digit recognition with a back-propagation network. In: *Advances in Neural Information Processing Systems*, 1990, pp. 396-404.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. *Proc. of IEEE* 86 (11) (1998) 2278-2324.
- LECUN, Y. Generalization and network design strategies. *Connectionism in perspective*, 1989, 143-155.
- MARTINS, R. *Desenvolvimento de isolador polimérico inteligente*. Tese de Doutorado, Universidade Federal do Paraná, 2015.
- MENDONÇA, P.L.; ANGELINI, J. M. G.; NALLIN, F.E.; COSTA, E. G.; FERREIRA, T.V.; GERMANO, A.D. Monitoramento de Isoladores Poliméricos em Linhas de Transmissão através de Sensor de Corrente de Fuga. *XIX Seminário Nacional de Distribuição de Energia Elétrica*, 2010.
- REDMON, J. et al. "You Only Look Once: Unified, Real-Time Object Detection". In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (2015), pp. 779-788.
- SILVA, A.A.P; SOUZA NETO, E.M.; BEZERRA, J.M.B.; BEZERRA, S.F.; SILVA, S.H.M.; EMERENCIANO, V.R.A.; LINS, Z.D. Linha de distribuição experimental para desenvolvimento de técnica de monitoração de isoladores poliméricos. *IV Simpósio Brasileiro de Sistemas Elétricos*, 2012
- SZEGEDY, C.; VANHOUCHE, V.; IOFFE, S; SHLENS, J.; WOJNA, Z. Rethinking the inception architecture for computer vision. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 2818-2826.
- WHITWORTH, C.C.; DULLER, A.W.G.; JONES, D.I.; EARP, G.K. Aerial video inspection of overhead power lines. *Power Engineering Journal* 15 (1), 2001, pp. 25-32. Doi: 10.1049/pe:20010103
- WIRTH, R., & HIPPEL, J. CRISP-DM: Towards a standard process model for data mining. *Proc 4th international conference on the practical applications of knowledge discovery and data mining*, 2000, pp. 29-39.
- YANG, Y.; WANG, L. WANG, Y.; MEI, X. Insulator self-shattering detection: a deep convolutional neural network approach. *Multimedia Tools and Applications*, 78(8), 2019, pp. 10097-10112. Doi: 10.1007/s11042-018-6610-4

DADOS BIOGRÁFICOS



Possui graduação em Engenharia Mecânica pela Universidade Federal do Pará (2017). Mestre na UNICAMP em Engenharia Mecânica, ênfase em mecânica computacional. Tem experiência na área de inteligência artificial e aprendizado de máquinas e monitoramento de saúde estrutural, mais especificamente em monitoramento da saúde estrutural utilizando técnicas de visão computacional e aprendizado profundo. Atualmente é Cientista de Dados na Kumulus Cloud & Data. À época da realização deste trabalho, ele estava na FITec - Fundação para Inovações Tecnológicas. CONTATO: eng.santosrenan@gmail.com

(2) CRISTINA YURIKA KONATU OBATA ADORNI

Possui graduação em Análise de Sistemas pela Pontifícia Universidade Católica de Campinas (1987). Atualmente é pesquisadora da FITec – Fundação para Inovações Tecnológicas, na área de Engenharia de Sistemas com ênfase em Inteligência Artificial e gerenciamento de projetos P&D ANEEL. Tem experiência na área de Ciência da Computação, Análise de Sistemas, Validação de Sistemas e Análise de Dados. Também tem experiência em pesquisa e desenvolvimento e na coordenação de atividades de gestão e planejamento. É membra do Conselho Técnico-Científico da FITec. CONTATO: cadorni@fitec.org.br

(3) GIOVANNI MOURA DE HOLANDA

Mestre em Engenharia Elétrica (eletrônica e comunicações) pela UNICAMP e graduado em Engenharia Elétrica pela UFPB. Há mais de 30 anos vem atuando em pesquisas e consultorias na área de tecnologias digitais e projetos de inovação. Atualmente é Pesquisador Sênior e Cientista de Dados na FITec - Fundação para Inovações Tecnológicas, em Campinas - SP, engajado em atividades sistêmicas e multidisciplinares, incluindo inteligência artificial, gestão de ativos, visão computacional, transformação digital, manutenção preditiva, controle de processos, metodologias de análises e apoio a decisão. É membro do Conselho Técnico-Científico da FITec. Atualmente é também pesquisador associado do BIOS– Brazilian Institute of Data Science. CONTATO: gholanda@fitec.org.br

(4) MARCOS VANINE PORTILHO DE NADER

Possui mestrado em Engenharia Elétrica pela Universidade Estadual de Campinas (2006). Tem experiência na área de Ciência da Computação, atuando principalmente nos seguintes temas: desenvolvimento de sistemas, concepção de projetos, elaboração de propostas técnicas e gerenciamento de equipes de desenvolvimento de software. Atualmente é Consultor de Negócios e Cientista de Dados na FITec – Fundação para Inovações Tecnológicas, atuando no desenvolvimento de novos negócios, com base em projetos de pesquisa e desenvolvimento que envolvem soluções de inteligência artificial (aprendizado de máquina), Internet das coisas, big data e analytics. É também pesquisador associado do BIOS– Brazilian Institute of Data Science. CONTATO: mvanine@fitec.org.br

(5) FERNANDO ANTONIO RAUTENBERG FINARDI

Possui graduação em Engenharia de Computação pela Pontifícia Universidade Católica de Campinas (2017). Tem experiência na área de Ciência da Computação, com ênfase em Sistemas de Computação, atuando no desenvolvimento de software full-stack (Front-end e Back-end), ciência de dados e desenvolvimento de soluções de Machine Learning. Atualmente é Especialista em Desenvolvimento de Software na FITec – Fundação para Inovações Tecnológicas. Tem como linhas de desenvolvimento: Arquitetura de Sistemas, Desenvolvimento de Software e Inteligência Artificial. CONTATO: ffinardi@fitec.org.br

(6) RONDINELE PINHEIRO SILVA

Engenheiro Eletricista formado pela Universidade Federal do Maranhão, Especialização em Gestão de Alta Tensão. Atualmente como engenheiro de distribuição, na Gerência Corporativa de Manutenção e Automação do grupo Equatorial Energia, atuando no planejamento e controle em linhas de transmissão (69KV a 138KV) e subestações. Atuando também na criação e monitoramento de indicadores de confiabilidade, utilização do módulo PM do software do SAP e criação de procedimentos e diretrizes. E, propondo soluções e melhorias para o segmento de alta tensão. E, gestão de custos, OPEX e CAPEX.

(7) MARIO DAMIÃO CAPARROZ R JUNIOR

Possui graduação em Sistemas de Informação pela UNDB (2018). Pós-graduação em Gestão de Projetos e Gestão de Processos pela UNIASSSELVI (2021). Atualmente atua no Planejamento e Controle de Manutenção em Alta Tensão, no desenvolvimento de soluções para automação de processos, na gestão de projetos e no processo de prospecção de novas tecnologias para a área de manutenção.

(8) EMANUEL ANTONIO MOUTINHO

Engenheiro Eletricista formado pela Universidade Federal do Maranhão, Engenheiro de Segurança do Trabalho pela Faculdade Atenas Maranhense e Pós-graduado em Gestão de Alta Tensão. Atualmente atua no Planejamento e Controle de Manutenção em Alta Tensão, gerenciando projetos de pesquisa e desenvolvimento e adquirindo novas tecnologias para a área de manutenção.

(9) ILANA FRANÇA

Graduação em Engenharia Elétrica pela Universidade Federal do Maranhão (2020) e Pós-Graduada em Gestão de Projetos pelo INEX – Instituto Nacional de Educação e Extensão. Atualmente é Analista de Projetos do NEPEN -

Núcleo de Estudos e Pesquisas do Norte e Nordeste / Grupo Equatorial Energia (MA), tendo como função o gerenciamento técnico de projetos de Pesquisa e Desenvolvimento (P&D) / ANEEL, coordenando cronogramas e entregas dos produtos neles desenvolvidos).