

Capítulo VII

Inteligência artificial em subestações

O processo de implantação de automação das subestações de energia elétrica buscou, em um primeiro momento, a melhoria operacional, por meio da introdução da telesupervisão e do telecomando, permitindo, assim, a otimização de recursos humanos, que ficavam alocados em operações nas subestações, para serviços nas redes ou nas linhas.

Ocorre que, com a retirada do elemento humano das subestações, os operadores nos centros de operação devem executar comandos, a distância, confiando apenas nas informações disponíveis no momento, recebidas das chaves e demais dispositivos, através de sensores, unidades remotas etc. Dependendo do porte e por segurança, a manobra - seja programada, corretiva ou mesmo de emergência - acaba, algumas vezes, sendo precedida de uma inspeção em campo pelo electricista, que precisa se deslocar às pressas para o local para garantir ou verificar a correta operação.

Para diminuir o risco, observa-se cada vez mais a instalação de câmeras nos pátios das subestações. Essa é uma excelente ideia, pois permite aos operadores uma visão, em tempo real, dos equipamentos das subestações. Com a redução no custo de câmeras térmicas, até o custeio das inspeções periódicas com termovisores pode ser minimizado. Porém, há de se considerar que, com a adoção de câmeras em todas as subestações, o custo com links de comunicação de banda larga para o tráfego das imagens é bastante aumentado. Ademais, links de banda larga muitas vezes não estão disponíveis para subestações remotamente localizadas, exigindo a adoção de conexões via satélite, o que encarece mais ainda o processo.

Mesmo com a adoção de câmeras, ainda se faz necessário

um “observador” experiente no Centro de Operação, que deve comandar o posicionamento de cada câmera apontando para cada chave, analisar cada uma das imagens e concluir sobre o estado das chaves.

É nesse ponto que o conceito de Inteligência Artificial (IA) passa a ser interessante. Um dos ramos da IA, denominado “visão computacional”, compreende o processamento de imagens com o objetivo de, computacionalmente, obter informações de alto nível a respeito do que está sendo observado.

Um problema que representa oportunidade para uso de técnicas de visão computacional em subestações é o monitoramento do estado (aberto ou fechado) de chaves seccionadoras. Atualmente, no caso de chaves operadas manualmente, mais comuns em subestações de distribuição, existe a possibilidade de erros operacionais, em especial se a ação foi realizada em caráter emergencial e/ou sob condições atmosféricas adversas. A informação do estado das chaves é relatada ao Centro de Operação por um ser humano, que pode cometer erros devido à falta de atenção, condições que dificultam a visualização ou outras razões.

As chaves operadas por telecomando também não estão isentas de problemas operacionais. Normalmente, chaves seccionadoras permanecem no mesmo estado por meses ou até anos, estando sujeitas à deterioração dos mecanismos de movimentação. Ao executar a operação da chave, o mecanismo pode falhar, deixando-a em um estado não conforme. Por isso, mesmo para chaves automatizadas, a concessionária ainda necessita de uma confirmação visual para garantir que estão no estado correto, o que é fundamental para evitar acidentes, danos a equipamentos da subestação e interrupções no serviço.

Nesse contexto, a visão computacional entra com o objetivo de determinar, automaticamente e a qualquer momento, se as chaves estão abertas ou fechadas, por meio de câmeras do tipo PTZ (pan/tilt/zoom) instaladas na subestação. Com a adoção do conceito de IA Embarcada, as imagens capturadas pelas câmeras não mais precisam ser transmitidas para os centros de operação, pois os algoritmos de IA são executados na própria subestação e apenas as conclusões são transmitidas, reduzindo enormemente os gastos com telecomunicação. Periodicamente, o computador monitora e analisa todas as chaves da subestação de forma cíclica.

Este relato descreve dois projetos executados pelo Lactec, em parceria com a Copel Distribuição e Copel Geração e Transmissão, no âmbito do Programa de P&D da Agência Nacional de Energia Elétrica (Aneel).

APLICAÇÃO EM SUBESTAÇÃO DE DISTRIBUIÇÃO

O objeto de estudo da aplicação em subestações de distribuição [1][2][3] foram chaves seccionadoras do tipo “faca”, presentes no setor de 13,8 kV da Subestação Copel Parolin, na cidade de Curitiba (PR). A Figura 1 mostra seis exemplares de chaves desse tipo, sendo que as três inferiores estão fechadas e as três superiores abertas.



Figura 1 – Chaves seccionadoras do tipo “faca”.

A geometria desse tipo de chave é relativamente simples, consistindo em um objeto com formato aproximadamente retangular que rotaciona em torno de um único eixo. Para viabilizar o desenvolvimento dos algoritmos de reconhecimento, foram instaladas quatro câmeras em pontos diferentes da subestação, as quais passaram a capturar fotos a serem utilizadas no processo de treinamento dos modelos de IA. Para cada câmera, foram definidos



Suportes Fixos de Solo & Trackers para Painéis Fotovoltaicos

Acompanhamos as tendências do **mercado de geração de energia solar fotovoltaica** para oferecer sempre os melhores produtos e serviços.

A Brametal trabalha com um robusto **Sistema de Gestão da Qualidade de Ponta a Ponta**, focada no produto final.



Saiba mais:



diversos presets (configurações de angulação e zoom da câmera PTZ) para capturar imagens de todos os conjuntos trifásicos de chaves.

Para poder treinar o reconhecimento automático do estado de cada chave, sob diversas condições atmosféricas, milhares de imagens tiveram de ser capturadas durante diversos meses. Também foi necessário o desenvolvimento de algoritmo eliminador de gotas de chuva e alinhamento a uma imagem de referência baseado em correlação de fase [4], a fim de minimizar as variações provocadas pela imprecisão dos motores da câmera PTZ, conforme ilustrado na Figura 2.



Figura 2 – Comparação entre uma única captura (esquerda) e a média de 100 capturas (direita).

RECONHECIMENTO DO ESTADO DAS CHAVES

Para o reconhecimento automático, é necessário o Aprendizado de Máquina (Machine Learning). A primeira técnica considerada foi uma rede neural convolucional (CNN) [5], baseada em operações de convolução bidimensional, que considera a relação espacial entre os pixels da imagem. A entrada na CNN é uma amostra de 256x256 pixels contendo uma chave, e a saída é a classe reconhecida para a imagem de entrada.

A segunda técnica envolve a extração de descritor com posterior classificação. No cálculo do descritor, foram testados dois algoritmos: Scale-invariant Feature Transform (SIFT) [6] e Histogram of Oriented Gradients (HOG) [7], resultando em um conjunto de 1152 e 1568 valores que descrevem a orientação e a magnitude do contraste em diferentes regiões da imagem. Para a classificação, usou-se o algoritmo Support Vector Machine (SVM) [8], cuja saída indica a classificação obtida para a amostra.

Os diferentes modelos foram treinados sobre uma base de dados contendo 6.813 e 15.384 amostras de chaves abertas e fechadas, respectivamente, capturadas ao longo de 5 dias e noites. No conjunto de teste com 13.391 e 27.210 amostras de

chaves abertas e fechadas capturadas em períodos diferentes, o modelo que obteve o melhor resultado foi o SIFT com SVM, que acertou o estado da chave em 99,83% dos casos.

Buscando melhorar o resultado e tornar o sistema mais robusto a diferentes situações, empregou-se a técnica de votação de algoritmos, uma forma de ensemble. Na votação de algoritmos, um modelo que gerou uma saída com valor alto de confiança possui maior peso que um modelo que gerou uma saída com valor baixo. Agregando as respostas dos variados modelos, gera-se uma única decisão sobre o estado da chave. Usando essa estratégia, a taxa de acerto no conjunto de teste aumentou para 99,99%.

A Figura 3 ilustra a execução do algoritmo de reconhecimento sobre duas imagens contendo chaves seccionadoras, identificando corretamente o estado aberto e fechado das chaves.



Figura 3 – Resultados obtidos pelo sistema sobre imagens de um conjunto de chaves reais, as quais tiveram seu estado alterado.

A conectividade entre o resultado do reconhecimento processado localmente e o Centro de Operação pode ser realizada em banda estreita via protocolo DNP3.

Dificuldades

O maior problema é o aprendizado de máquina, pois como reconhecimento é baseado em modelos estatísticos, são necessárias amostras reais de imagens de todas as chaves abertas e fechadas sob quaisquer condições atmosféricas encontradas na prática. Porém, as chaves seccionadoras não podem ter seu estado alterado sem o devido planejamento de manobra na rede.



APLICAÇÃO EM SUBESTAÇÃO DE TRANSMISSÃO

Em subestações de transmissão, há uma maior variabilidade de tipos de chaves seccionadoras, com movimentos mais complexos que as chaves “faca” utilizadas na distribuição. Duas subestações da Copel fazem parte do estudo: o setor de 230 kV da Subestação Campo Comprido, em Curitiba, e o setor de 525 kV da Subestação Bateias, em Campo Largo, na região metropolitana. A Figura 4 exemplifica dois dos modelos de chaves estudados: “abertura central” e “dupla abertura”.




Figura 4 – Chaves seccionadoras do tipo “abertura central” (esquerda) e “dupla abertura” (direita).

Devido à dificuldade enfrentada no projeto anterior na fase de aprendizado de máquina, buscou-se no conceito inovador de Realidade Virtual um método de gerar “fake photos” representando chaves no modo aberto que na realidade não poderiam ser abertas, sem prejuízo à operação normal da subestação.

Modelagem 3D

Para criar as imagens artificiais de chaves em posições diversas, o primeiro passo foi o levantamento a laser do ambiente. Para isso, usa-se um scanner LIDAR estacionário, que dispara feixes laser para todas as direções, detecta os raios refletidos e marca pontos no espaço cartesiano (XYZ), gerando uma “nuvem de pontos”. A Figura 5 representa o levantamento a laser da Subestação Bateias.



Figura 5 – Nuvem de pontos completa da Subestação Bateias.

Em seguida, a nuvem de pontos é usada como referência para a tarefa de modelagem manual das estruturas da subestação. São identificados itens como chaves seccionadoras, isoladores, disjuntores, transformadores, cabos, torres e pórticos, que são recortados da nuvem de pontos completa e recriados individualmente em softwares de modelagem 3D, conforme ilustrado na Figura 6. Depois disso, utiliza-se novamente a nuvem de pontos completa para fazer a montagem da cena virtual, posicionando todos os elementos nas devidas posições.



Figura 6 – Comparação entre objetos na nuvem de pontos (esquerda) e o objeto modelado (direita).

Com o modelo 3D completo, foi possível definir o posicionamento de câmeras para o sistema de reconhecimento. No caso de subestações de transmissão, as chaves seccionadoras ficam distribuídas no pátio em meio a outras estruturas, de forma que uma câmera mal posicionada pode ter o ponto de vista para uma chave bloqueado por outro objeto. Por isso, usou-se o ambiente virtual para escolher bons posicionamentos de câmera, maximizando a capacidade de monitoramento de cada câmera PTZ.

Aplicação do conceito de realidade virtual para aprendizado de máquina

Para fins de treinamento dos modelos de IA, não basta ter apenas os objetos modelados e posicionados no ambiente virtual. É preciso que a imagem gerada por computador seja similar à capturada por uma câmera real. Para isso, outras propriedades da cena virtual precisam ser ajustadas:

- Ajuste de parâmetros dos “materiais” virtuais. Isso determina a cor dos objetos, a forma com que interagem com a luz (opacidade, refletividade etc.), a textura, entre outros fatores;
- Calibração da iluminação. Isso inclui a intensidade e direção da luz, a formação de sombras etc.;
- Ajuste fino da modelagem (formato) dos objetos.

O ajuste do modelo 3D é uma tarefa em que melhoramentos são repetidamente realizados durante o projeto. O objetivo é reproduzir o aspecto de uma fotografia real, e não criar um ambiente perfeito e surreal. Por isso, realizou-se a instalação das câmeras e iniciou-se a captura automática de imagens, a fim de alimentar tanto a tarefa de ajuste do modelo 3D quanto o desenvolvimento dos algoritmos de visão computacional.

Como o aprendizado de máquina exige grandes quantidades de dados, a geração de imagens por computador foi automatizada, por meio de um script executado no programa de modelagem 3D. Presets virtuais foram definidos, reproduzindo os presets das câmeras reais na subestação, e centenas de milhares de imagens foram geradas variando-se aleatoriamente as propriedades do ambiente. A Figura 7 mostra uma imagem gerada a partir do modelo 3D com aspecto de fotografia.



Figura 7 – Imagem gerada por computador da subestação virtual.

CABOS PARA SISTEMAS FOTOVOLTAICOS



Cabo SolarMax Flex

0,6/1kV (1,8kV)

Suporta

- Grandes oscilações de energia
- Radiação UV
- Intempéries
- Alta e baixa temperatura
- Soluções ácidas e alcalinas



Outros cabos utilizados no SISTEMA FOTOVOLTAICO



Maxlink R AL



SafetyMax AL UV

LIGUE E SOLICITE UM
ATENDIMENTO TÉCNICO
0800 701 3701
www.condumax.com.br

Condumax
FIOS E CABOS ELÉTRICOS

Incesa
COMPONENTES ELÉTRICOS

CONDUMAX, INCESA E GRUPO CONDUMAX, INCESA

Com relação à visão computacional, neste projeto selecionou-se apenas a técnica de CNN, devido às dificuldades advindas da geometria das chaves e seus padrões de abertura. Atualmente, os modelos estão sendo desenvolvidos e seus resultados serão apresentados em breve.

Monitoramento térmico das chaves

Além do monitoramento por visão computacional, este projeto também inclui o monitoramento térmico de chaves, visando detectar anomalias de aquecimento. No setor elétrico, frequentemente são usados termovisores para inspeção termográfica [9], mas neste projeto buscou-se uma alternativa voltada à automação. Para isso, foram instaladas câmeras termográficas na subestação, cujos posicionamentos também foram escolhidos virtualmente no modelo 3D.

O objetivo desse processo é alertar caso a temperatura ultrapasse o limite de funcionamento normal do equipamento. Para isso, foram determinadas regiões de interesse no enquadramento da câmera térmica, focando nos contatos das chaves seccionadoras. O software verifica periodicamente a temperatura máxima nas regiões delimitadas e dispara um alerta, caso exceda o limite. Dessa forma, o monitoramento térmico é realizado continuamente, permitindo que a necessidade de ação corretiva seja identificada com antecedência. A Figura 8 mostra uma imagem capturada por uma câmera termográfica na Subestação Campo Comprido.



Figura 8 – Imagem capturada por uma câmera termográfica instalada na subestação com as áreas de interesse delimitadas.

CONCLUSÕES

Foi desenvolvida uma nova metodologia para reconhecimento automático do estado de chaves em subestação de forma não invasiva utilizando técnicas de visão computacional, inteligência

artificial e aprendizado de máquina em eletrônica embarcada. Os resultados, utilizando imagens reais capturadas por câmeras instaladas em subestação, obtiveram taxas de acerto superiores a 99%.

AGRADECIMENTOS

Os projetos PD 02866-0342/2012 e PD 06491-0455/2017, para a Copel Distribuição e Copel Geração e Transmissão, respectivamente, foram viabilizados dentro do Programa de Pesquisa e Desenvolvimento regulado pela Agência Nacional de Energia Elétrica (ANEEL).

REFERÊNCIAS

- [1] L. Lippmann Junior et al. “Videomonitoramento com reconhecimento automático de imagens para suporte à operação de dispositivos em subestações”, *Anais do XXIV SNPTEE*, 2017;
- [2] R. Wagner et al. “Visão robótica com integração ao COD, detecção automatizada de estado de chaves em subestações de distribuição”, *Anais do XXIII SENDI*, 2018;
- [3] L. Lippmann Junior et al. “Monitoramento on-line de chaves seccionadoras por sistema não invasivo”, *Anais do XXV SNPTEE*, 2019;
- [4] H. Stone, “A Fast Direct Fourier-Based Algorithm for Subpixel Registration of Images”, *IEEE Transactions on Geoscience and Remote Sensing*, V. 39, No. 10, Oct. 2001, pp.2235-2242;
- [5] I. Goodfellow, Y. Bengio, and A. Courville, “Deep Learning”. MIT Press, 2016;
- [6] D. G. Lowe, “Distinctive image features from scale-invariant keypoints”, *International Journal of Computer Vision*, vol. 60, no. 2, pp. 91-110, November 2004;
- [7] N. Dalal and B. Triggs, “Histograms of oriented gradients for human detection”, in *IEEE Conference on Computer Vision and Pattern Recognition*, 2005, pp. 886-893;
- [8] C. Cortes and V. Vapnik, “Support-vector networks”, *Machine Learning*, vol. 20, no. 3, pp. 273-297, September 1995;
- [9] C. Huais, “Desafios da manutenção em sistemas MT e AT”, O Setor Elétrico, 2021.

*Lourival Lippmann Junior é pesquisador no Lactec, graduado em Engenharia Eletrônica pelo ITA e mestrado em Automação Industrial pela UTFPR;

Victor Barpp Gomes é pesquisador no Lactec, graduado em Engenharia de Computação pela UTFPR e mestrando em Visão Computacional pela UTFPR;

Bruno Marchesi é pesquisador no Lactec, graduado em Engenharia Elétrica e mestrado em Informática Industrial pela UTFPR.