



## **Grupo de Estudo de Subestações e Equipamentos de Alta Tensão-GSE**

### **Monitoramento on-line de chaves seccionadoras por sistema não invasivo**

**LOURIVAL LIPPMANN JUNIOR(1); BRUNO MARCHESI(2); RAFAEL WAGNER(3); AMANDA CANESTRARO(4);  
BOGDAN TOMOYUKI NASSU(5); MARCOS SCREMIN(6); VANDERLEI ZARNICINSKI(6); VICTOR BARPP  
GOMES(7);  
LACTEC(1);LACTEC(2);LACTEC(3);LACTEC(4);UTFPR(5);COPEL(6);LACTEC(7);**

## **RESUMO**

Este trabalho apresenta os resultados obtidos na implementação de um sistema on-line de identificação automática do estado de chaves em subestações, através de técnica de visão computacional, desenvolvido pelo LACTEC e COPEL, dentro de um projeto de pesquisa e desenvolvimento. São apresentados os algoritmos que compuseram o sistema e o desempenho de reconhecimento com imagens capturadas por câmeras instaladas em uma subestação de distribuição.

## **PALAVRAS-CHAVE**

Aprendizado de Máquina, Automação, Equipamentos de Subestação, Qualidade do Serviço, Visão Computacional

### **1.0 - INTRODUÇÃO**

A principal motivação para a execução deste projeto foi a dificuldade que se apresenta aos operadores de Centro de Operação na determinação correta do estado de chaves em subestações. Muitas chaves, apesar de serem automatizadas, podem apresentar falhas no mecanismo de movimentação. Além disso, as chaves de operação exclusivamente manual estão sujeitas à falha humana na sua operação.

Portanto, o objetivo deste projeto foi criar um sistema totalmente automatizado, não invasivo, para realizar a captura e o processamento das imagens e, através de algoritmos de visão computacional, detectar o estado da chave, aberta ou fechada. O resultado é o envio apenas da informação do estado lógico das chaves para a concessionária, sem a necessidade do envio das imagens, reduzindo custos de banda de comunicação. Dessa forma, com a instalação deste sistema, não é necessária nenhuma interferência humana nem deslocamento para determinar com exatidão o estado atual da chave.

### **2.0 - DESENVOLVIMENTO DO PROJETO**

Para o desenvolvimento, instalação e validação do sistema, foi selecionada a subestação COPEL Parolin, em Curitiba/PR.

O projeto foi subdividido nas etapas de: projeto de infraestrutura para a captura e processamento de imagens em tempo real incluindo câmeras, iluminadores e computador de alto desempenho; etapa de desenvolvimento de software incluindo rotulagem, definição de abordagens de visão computacional, aprendizado de máquina e implementação de algoritmos de reconhecimento; testes de integração ao Centro de Operação da concessionária.

A Figura 1 ilustra uma das tarefas de instalação da infraestrutura do projeto desenvolvido, na subestação.



FIGURA 1 – Instalação de equipamento do projeto, poste, câmera e iluminador, na subestação.

## 2.1 Rotulagem

Um dos desafios encontrados neste projeto foi a localização e a identificação de cada chave nas imagens, sem adicionar marcadores ou alterar o ambiente para facilitar essa tarefa. A solução encontrada para esse problema foi realizar uma etapa inicial de rotulagem.

Durante a etapa de rotulagem, é definido um conjunto de enquadramentos, os quais são, em essência, pontos de vista que são armazenados como presets para os motores das câmeras PTZ. O conjunto de enquadramentos definido deve garantir que todas as chaves a serem monitoradas apareçam com boa visibilidade em pelo menos um enquadramento, de um ponto de vista aproximadamente lateral. Isso possibilita que uma mudança de estado de uma chave possa ser aproximada como uma rotação do “corpo” da chave.

A rotulagem propriamente dita consiste no fornecimento de dados para a localização e identificação das chaves nos enquadramentos. A Figura 2 representa um dos casos de uso do software de rotulagem. À esquerda, mostra-se a tela de demarcação manual da chave. Os pontos de (1) a (4) representam os vértices da chave, e podem ser movimentados pelo usuário. Os segmentos de reta, traçados entre os pontos de (1) a (4), mostram a região selecionada para a chave. O ponto (5) representa o centro de rotação da chave, e também pode ser movimentado pelo usuário. À direita, mostra-se uma previsão da imagem da chave na horizontal, que é atualizada conforme o usuário movimenta os pontos na tela de demarcação, evidenciando o centro de rotação da chave (6).



FIGURA 2 – Demarcação de uma chave seccionadora no software de rotulagem.

A rotulagem precisa ser feita apenas uma vez, antes do treinamento dos modelos.

## 2.2 Modelos de aprendizado de máquina

Neste projeto, foram desenvolvidas variadas abordagens de modelos de aprendizado de máquina. Testou-se um total de quinze modelos distintos, gerados por meio de diferentes combinações de algoritmos de visão computacional e técnicas de aprendizado de máquina.

Os modelos desenvolvidos podem ser classificados, em um primeiro momento, de acordo com a estratégia de reconhecimento do estado das chaves, o que os divide em três grupos. O primeiro grupo, composto por modelos chamados “aberto/fechado”, buscam distinguir se a chave está na posição aberta ou fechada, dado um recorte de uma região da imagem que contém uma chave seccionadora. O segundo grupo, que é representado pelos modelos “horizontais”, estimam o ângulo do corpo da chave na imagem por meio da identificação da chave na horizontal. O terceiro grupo é composto por detectores de outliers (anomalias), ou seja, sua função é perceber alterações no posicionamento das chaves observado na etapa de treinamento.

Ademais, os modelos podem também ser agrupados de acordo com os classificadores utilizados. Nesta versão do sistema, foram utilizadas três abordagens de classificação. A primeira é a CNN (Convolutional Neural Network), rede neural que recebe como entrada a própria imagem da chave. As outras duas abordagens, SVM (Support Vector Machine) e modelo gaussiano multidimensional, utilizam descritores como entrada, os quais são computados por dois algoritmos: uma versão modificada do SIFT (Scale-Invariant Feature Transform) e HOG (Histogram of Oriented Gradients).

Em resumo, para cada grupo (“aberto/fechado”, “horizontal”, detector de outliers), foram desenvolvidos cinco tipos de modelos, utilizando as seguintes tecnologias: descritores SIFT com classificador SVM; descritores SIFT com modelo gaussiano; descritores HOG com classificador SVM; descritores HOG com modelo gaussiano; rede neural convolucional.

### 2.2.1 Modelos “aberto/fechado”

Os modelos “aberto/fechado” são treinados com amostras retiradas de imagens capturadas pelas câmeras da subestação. Nesses modelos, para cada chave seccionadora de uma imagem, obtém-se, a partir dos dados de rotulagem, um recorte quadrado que contém a chave. Os recortes são feitos de forma que o ponto base da chave fique localizado no quadrante inferior direito, fazendo com que a chave apareça verticalmente no lado direito da imagem, caso esteja fechada, ou horizontalmente na parte inferior da imagem, caso esteja aberta. Para evitar que o fundo da imagem (chão, estruturas, entre outros) introduza viés no treinamento dos modelos, é aplicada uma máscara em formato de “L invertido”, que escurece as regiões da amostra nas quais não se espera encontrar a chave. A Figura 3-(a) representa um exemplo de amostra utilizada por esses modelos.



FIGURA 3 – (a) exemplo para modelo “aberto/fechado”, (b) exemplo para modelo de outliers.

Dessa forma, na operação do sistema, os modelos “aberto/fechado” determinam o estado da chave com base na semelhança da imagem de teste com as amostras utilizadas no treinamento. Se a chave aparecer na vertical, do lado direito, o algoritmo responderá mais fortemente para o estado “fechado”, e se aparecer na horizontal, na parte inferior, o algoritmo responderá mais fortemente para o estado “aberto”.

### 2.2.2 Modelos detectores de outliers

A função dos modelos detectores de outliers é perceber alterações na região da imagem que contém uma chave. Esses modelos são computados de forma independente para cada chave, ou seja, cada modelo é treinado apenas com imagens da mesma chave, sob diferentes condições de iluminação. As amostras utilizadas para o treinamento são semelhantes às amostras dos modelos “horizontais”, com a chave na horizontal, mas as regiões afastadas da chave (fundo da imagem) são escurecidas, delimitando estritamente a região da chave. Dessa maneira, os modelos são treinados com o intuito de reagir positivamente apenas a situações de normalidade, ou seja, semelhantes às observadas durante o treinamento.

A Figura 3-(b) acima exemplifica amostra para estes modelos.

Assim, o princípio do algoritmo que utiliza os modelos detectores de outliers é supor que, se houve alguma alteração significativa na região da imagem em que a chave estava durante o treinamento, ocorreu uma mudança de estado. Esses modelos são dimensionados para serem estritos, ou seja, uma ligeira alteração será apontada como um outlier, já que a intenção desses modelos na operação do sistema é servir como uma etapa de filtragem inicial de imagens muito semelhantes às observadas durante o treinamento.

### 2.2.3 Modelos “horizontais”

As amostras de treinamento para os modelos “horizontais” são classificadas em amostras positivas e amostras negativas. Amostras positivas são recortes da imagem que contêm a chave na horizontal, com o ponto base à esquerda e a alça de manobra acima, obtidas por meio de transformações na imagem (rotação, escala, espelhamento) com base nas informações fornecidas na etapa de rotulagem. Amostras negativas, obtidas de regiões aleatórias da imagem ou da posição estimada em que a chave estaria caso estivesse no outro estado, não contêm a chave na horizontal.

Os modelos “horizontais”, idealmente, respondem com altos valores a entradas que possuem a chave na horizontal. Assim, o princípio de funcionamento do algoritmo que utiliza os modelos “horizontais” é testar vários ângulos de rotação, rotacionando e espelhando a imagem de entrada várias vezes. São testados alguns ângulos em torno do ângulo informado para a chave na rotulagem, e alguns ângulos em torno do ângulo estimado que a chave teria se estivesse no outro estado, gerando duas saídas. De acordo com a discrepância entre as saídas, determina-se se a chave está no mesmo estado observado durante o treinamento ou não.

### 2.2.4 Sistema de votação com base nos resultados dos algoritmos

Como cada tipo de modelo tem uma abordagem diferente, o resultado de tipos de modelos diferentes pode ser melhor em condições variadas. Tendo isso em vista, buscou-se melhorar a robustez do sistema por meio da combinação do resultado de modelos diferentes, criando uma espécie de “votação” entre algoritmos.

Para cada modelo, ao invés de obter apenas a saída discreta (que seria o “rótulo” binário, o estado aberto/fechado), obtém-se uma saída contínua, o valor numérico bruto gerado na saída do modelo. Frente as imagens de treinamento, calcula-se, para ambas as classes (estados), o valor médio e o desvio padrão da saída bruta do algoritmo. Esses dados estatísticos são utilizados para dar um grau de confiabilidade à resposta do modelo: ao executar o algoritmo sobre uma amostra qualquer, pode-se dizer se o resultado é de “alta confiança”, “baixa confiança” ou “desconhecido”, com base no número de desvios padrões entre o valor obtido e a média.

Inicialmente, define-se um conjunto de algoritmos que serão executados. Se houver algum modelo detector de outliers nesse conjunto, esse modelo é testado primeiro. Caso o resultado seja diferente do observado durante o treinamento (um outlier), executam-se os outros algoritmos configurados. Dessa forma, implementa-se um filtro de inliers: se a imagem for muito semelhante às do treinamento, os algoritmos seguintes não são executados, economizando tempo de processamento.

Para implementar a votação entre modelos diferentes, atribui-se uma pontuação a cada resposta, sendo: 1 para aberto com alta confiança; 0,25 para aberto com baixa confiança; 0 para desconhecido; -0,25 para fechado com baixa confiança; -1 para fechado com alta confiança. Faz-se, então, a média aritmética das respostas dos algoritmos envolvidos: se o valor resultante for positivo, considera-se que a chave está aberta, e se for negativo, considera-se que a chave está fechada. Quando uma chave for visível em mais de um enquadramento, a média da pontuação contabiliza as respostas dos algoritmos para todos os enquadramentos.

Para exemplificar o funcionamento do sistema de votação entre algoritmos, apresentam-se três exemplos, nos quais os algoritmos configurados eram: detector de outliers com SVM e descritores HOG (sw\_hog), modelo “aberto/fechado” com SVM e descritores SIFT (oc\_sift) e modelo “horizontal” com CNN (hor\_cnn).

A Figura 4 mostra o reconhecimento do estado de chaves para uma imagem noturna. Na porção inferior da Figura 4, o texto indica os modelos que foram executados para cada chave, e seus respectivos votos. Para as quatro chaves da imagem, o algoritmo sw\_hog atribuiu a pontuação -0,25 (fechado com baixa confiança). Como o estado das quatro chaves observado durante o treinamento era “fechado”, os algoritmos seguintes não foram executados, e o estado reconhecido pelo algoritmo foi “fechado”.






FIGURA 4 – Reconhecimento de estado de chaves em uma imagem noturna.

A Figura 5-(a) e a Figura 5-(b) mostram o reconhecimento de estado de chaves para o mesmo conjunto de chaves, porém em dias diferentes. Além disso, na Figura 5-(a), as chaves estão fechadas, enquanto que na Figura 5-(b) as chaves haviam sido manobradas, ficando no estado aberto. Na Figura 5-(a), o algoritmo sw\_hog atribuiu a pontuação -1 (fechado com alta confiança) para as três chaves. Como as chaves também estavam no estado fechado durante o treinamento, os algoritmos seguintes não foram executados, e o estado reconhecido pelo algoritmo foi “fechado”. Na Figura 5-(b), o algoritmo sw\_hog votou 1 (aberto com alta confiança) para as três chaves. Como as chaves estavam fechadas durante o treinamento, isso foi considerado um outlier, e os algoritmos seguintes foram executados. Para a chave 25C, ambos os modelos hor\_cnn e oc\_sift votaram 1, resultando em uma pontuação média igual a 1. Para ambas as chaves 25B e 25A, o algoritmo oc\_sift votou 1, mas o algoritmo hor\_cnn votou 0 (estado desconhecido), resultando em uma pontuação média de 0,6666. Como, para as três chaves, a votação resultou em valores positivos, o estado reconhecido pelo algoritmo foi “aberto”.



FIGURA 5 – (a) reconhecimento de estado de chaves, (b) reconhecimento de chaves manobradas.

### 2.3 Treinamento dos modelos

O treinamento dos modelos envolve principalmente o processamento das imagens de entrada, o cálculo dos descritores SIFT e HOG e a geração dos modelos de aprendizagem de máquina. O software para treinamento dos modelos foi desenvolvido com uma combinação de Python e C++, utilizando as bibliotecas OpenCV, TensorFlow e TFLearn. O treinamento foi realizado em um computador com processador Intel Core i7, 32 GB de RAM e placa de vídeo NVIDIA TITAN Xp.

O conjunto de imagens de treinamento foi obtido por meio da infraestrutura de câmeras e iluminadores instalada na subestação COPEL Parolin. Utilizou-se um total de 4508 imagens para o treinamento, capturadas ao decorrer de cinco dias e noites, a maioria sob condições de tempo limpo. Desse conjunto de treinamento, extraiu-se um total de 6813 amostras de chaves abertas do barramento transferência e 15384 amostras de chaves fechadas dos barramentos entrada e saída.

### 2.4 Captura das imagens e processamento embarcado na subestação

Após a geração dos modelos de aprendizado de máquina, os softwares foram gravados no equipamento final, uma unidade de CPU baseada no padrão Tegra K1 SoC da NVIDIA. Esse equipamento, instalado na subestação, é

responsável pelo controle das câmeras, pelo processamento dos algoritmos de reconhecimento de estado de chaves e pela integração com o Centro de Operação da concessionária de energia elétrica.

A operação do sistema começa com a aquisição das imagens. Periodicamente, as câmeras, comandadas pelo dispositivo NVIDIA, movem-se para cada enquadramento e fazem a captura de imagens. Na subestação Parolin, da COPEL, monitora-se um total de 102 chaves seccionadoras. Faz-se um pré-processamento, que consiste em fazer a média de várias capturas da câmera, para reduzir o ruído e remover pingos de chuva, e também o alinhamento com uma imagem de referência, por meio de um algoritmo de correlação de fase modificado para situações de variação de luminosidade.

As imagens geradas são, então, submetidas aos algoritmos de reconhecimento de estado de chaves. Primeiramente, são geradas as amostras (recortes) utilizados pelos algoritmos. Em seguida, executa-se o algoritmo de classificação: para os modelos SIFT e HOG, antes são calculados os descritores, enquanto para os modelos CNN, utiliza-se a imagem diretamente. Por fim, os resultados da aplicação de diferentes modelos são combinados e produzem uma saída que informa o estado e o grau de confiança das chaves.

Vale lembrar que o reconhecimento do estado das chaves é realizado na própria subestação, ou seja, não há streaming de vídeo nem transmissão de imagens via rede. O sistema é integrado ao Centro de Operação da concessionária via protocolo DNP3, transmitindo apenas a informação de pontos binários contendo o status das chaves monitoradas.

## 2.5 Integração com o Centro de Operação

A integração ao Centro de Operação da concessionária se deu mediante a conexão do sistema à rede Ethernet dedicada às Operações. O protocolo de comunicação implementado foi o padrão DNP3, sendo que este sistema de monitoramento opera como Unidade Terminal Remota (UTR), respondendo às requisições periódicas de consistência de dados que são requisitadas pelo software Supervisório (SCADA – Supervisory Control and Data Acquisition). Este sistema de monitoramento também possui a capacidade de gerar mensagens espontâneas (não solicitadas), no caso de detecção de alteração de estado de alguma chave, para transmitir a informação relevante ao Centro. O tipo de dados utilizado para cada chave é o BINARY INPUT WITH STATUS, ponto binário com informação da posição da chave (0-zero para chave aberta e 1-um para chave fechada), e de estado (qualidade) do ponto (0-zero para fora de serviço (offline) ou 1-um para online).

A subestação SE-Parolin (PRO) da COPEL possui onze alimentadores. Cada alimentador possui três chaves de entrada e três chaves de saída. Há ainda seis chaves de dois circuitos gerais. Portanto, o número total mapeado de chaves seccionadoras foi de setenta e duas chaves, sendo cada chave mapeada individualmente como um ponto binário para o SCADA.

A Figura 6 apresenta o mapeamento das chaves para os alimentadores da subestação.

DNP3_ID	Alimentador_ID	Alimentador_Nome	Circuito_ID	Chave_Posição	Chave_Fase	Chave_ID
0	1	ALIM1 DOM ÁTICO	1=primário	1	A	1
1	1		1	2	B	2
2	1		1	3	C	3
3	1		2=secundário	1	A	4
4	1		2	2	B	5
5	1		2	3	C	6
...	...	...	...	...	...	...
60	11	ALIM11 PAULO SETÚBAL	1=primário	1	A	61
61	11		1	2	B	62
62	11		1	3	C	63
63	11		2=secundário	1	A	64
64	11		2	2	B	65
65	11		2	3	C	66
66	12	GERAL1	0=não se aplica	1	A	67
67	12		0	2	B	68
68	12		0	3	C	69
69	13	GERAL2	0=não se aplica	1	A	70
70	13		0	2	B	71
71	13		0	3	C	72

FIGURA 6 – Mapeamento das chaves da subestação COPEL-Parolin.

Na Figura 6, a coluna DNP3\_ID representa o índice do ponto binário DNP3 ao qual a chave se refere. A coluna Alimentador\_ID é o índice interno de representação do alimentador, assim como também a coluna Chave\_ID é o

índice interno para cada chave, individualmente. A coluna Alimentador\_Nome é um campo de texto que melhor representa o alimentador em questão, para referência, seja um bairro, uma avenida ou região específica da cidade. A coluna Circuito\_ID indica se a chave se refere ao circuito primário ou secundário da chave, sendo o primário antes da chave e o secundário depois da chave e ligado às cargas. As colunas Chave\_Posição e Chave\_Fase se referenciam à fase da linha à qual a chave está conectada.

A Tabela 1 apresenta a definição dos possíveis valores do ponto binário com status, para cada chave.

TABELA 1 – Especificação dos valores do ponto binário com status	
Ponto binário com estado (DNP3 BINARY INPUT WITH STATUS)	Situação
01 (online)	Chave aberta
11 (online)	Chave fechada
00 (offline)	Chave em posição não-conforme
10 (offline)	Estado indeterminado

Os valores com informação relevante às Operações são aqueles que estão em estado online, transmitindo a informação real ao SCADA da posição atual da chave, se aberta ou fechada. Os valores que estão em estado offline são aqueles na margem da indefinição da posição real da chave naquele momento, devido a estar entreaberta ou ao sistema de monitoramento não ter conseguido determinar por situação limítrofe, seja por falha de comunicação entre a unidade de processamento e a unidade de aquisição, falha no sistema de iluminação, falha no enquadramento ou foco, ou alto fator de incerteza do algoritmo de determinação do estado da chave.

Foram realizados testes de integração do sistema de monitoramento à Rede de Operações da COPEL, conforme mostrado na Figura 7. Se referiram à compatibilidade do tipo de dados, às respostas às requisições periódicas para consistência de dados e às mensagens espontâneas geradas no caso da detecção de mudança do estado.



FIGURA 7 – Testes de integração do sistema de monitoramento das chaves ao Centro de Operação.

## 2.6 Resultados

Os modelos foram testados individualmente em um universo de 7974 fotografias, por dias e noites. As imagens contemplam condições de tempo como chuva e neblina, e também incluem capturas de chaves manobradas (que tiveram seu estado alterado na subestação). Desse conjunto de teste, extraiu-se um total de 13391 amostras de chaves abertas e 27210 amostras de chaves fechadas. A Tabela 2 mostra os resultados percentuais obtidos.

TABELA 2 – Percentuais de classificações corretas e incorretas de cada modelo

Tipo de modelo	Correto, alta conf.	Correto, baixa conf.	Desconhecido	Incorreto, baixa conf.	Incorreto, alta conf.	Correto, Total
Modelos “aberto/fechado”						
CNN	99.6576%	0.0049%	0%	0%	0.3374%	99.6626%
SIFT+SVM	99.5517%	0.1921%	0.1034%	0.1281%	0.0246%	99.8177%
SIFT+GAUSS	99.5099%	0.0640%	0.1404%	0.0074%	0.2783%	99.6453%
HOG+SVM	98.4261%	1.0517%	0.1231%	0.2389%	0.1601%	99.4902%
HOG+GAUSS	93.2785%	2.6379%	4.0147%	0.0222%	0.0468%	96.1232%
Modelos “horizontais”						
CNN	97.8621%	0.2882%	1.8078%	0.0099%	0.0320%	98.4261%
SIFT+SVM	99.7118%	0.0887%	0.0394%	0.0616%	0.0985%	99.8374%
SIFT+GAUSS	98.0296%	0%	2.0837%	0.0616%	0%	98.0296%
HOG+SVM	79.1926%	16.9085%	3.8915%	0.0074%	0%	96.4311%
HOG+GAUSS	0%	93.6085%	6.3594%	0.0320%	0%	93.8918%
Modelos detectores de outliers						
CNN	37.2035%	32.5164%	13.9873%	6.9235%	9.3692%	69.7889%
SIFT+SVM	21.3443%	33.6667%	22.9379%	10.7559%	11.2953%	55.0282%
SIFT+GAUSS	1.6872%	32.7455%	31.3071%	16.0563%	18.2040%	34.4425%
HOG+SVM	59.5256%	25.9895%	8.7633%	3.5615%	2.16%	85.5151%
HOG+GAUSS	7.8717%	2.4039%	1.0640%	0.3941%	88.2663%	10.2756%

Na Tabela 2, na coluna “Correto, total”, o valor indicado corresponde ao percentual de acerto do modelo considerando tanto respostas com alta taxa de confiança quanto baixa taxa de confiança, e considerando saídas “desconhecidas” como mudanças de estado.

A partir dos dados da Tabela 2, é evidente que os modelos “aberto/fechado” tiveram um bom desempenho, sendo o SIFT+SVM o modelo com maior taxa de acerto. Dentre os poucos erros desses modelos, alguns foram casos de manobras não detectadas, o que indica que os modelos estão, pelo menos parcialmente, tomando decisões com base no ambiente ao redor da chave. Outras causas de erro incluem problemas de iluminação e visibilidade, e oclusão por cabos que aparecem com muito brilho à noite. Os modelos “horizontais” também tiveram bom resultado, embora ligeiramente inferior aos modelos “aberto/fechado”. Entretanto, percebeu-se que os modelos “horizontais” tiveram melhor desempenho na identificação de manobras: o número de manobras não detectadas foi menor que nos modelos “aberto/fechado”.

As outras causas de erros foram semelhantes às dos modelos “aberto/fechado”. O percentual de acerto dos modelos detectores de outliers foi bastante inferior ao dos outros modelos, mas esse comportamento era esperado, devido ao caráter estrito desses modelos. Mesmo assim, os modelos Gaussianos multidimensionais não tiveram um desempenho adequado nesse grupo. O modelo que utiliza descritores HOG com SVM teve o melhor resultado, com taxa de acerto de 85,5% e conseguindo detectar todas as alterações de estado de manobras. Isso indica que, embora isoladamente esses modelos não apresentam bom resultado, alguns deles podem ser utilizados como uma etapa inicial de filtragem de imagens muito similares às observadas no treinamento.

Quanto à combinação de modelos, fez-se também o teste com alguns conjuntos de modelos, tendo em mente os resultados percentuais individuais de cada modelo, mas com uma certa heterogeneidade de abordagens, para garantir que propriedades diferentes da imagem seriam levadas em consideração. Dentre os conjuntos de modelos testados, o que obteve melhor resultado foi a combinação do modelo “aberto-fechado” com descritores SIFT e SVM, o modelo “horizontal” com CNN e o modelo detector de outliers com descritores HOG e SVM. Essa combinação teve apenas 9 erros em todo o dataset de teste (o que corresponde a 0,0222% do espaço amostral).

### 3.0 - CONCLUSÃO

Este trabalho comprovou a possibilidade de automatização do processo de identificação do estado de chaves em subestação através de técnica de visão computacional, o que significa não apenas capturar imagens, mas realizar a interpretação autônoma das mesmas, gerando informação relevante ao Centro de Operação de forma online. Uma das principais dificuldades para validar o correto funcionamento deste sistema foi a impossibilidade de abrir as chaves dos alimentadores na subestação, por afetar o fornecimento de energia.

Uma alternativa que está sendo pesquisada é a utilização de técnica de escaneamento 3D a laser do ambiente do pátio da subestação, com geração de nuvem de pontos e criação de imagens virtuais das chaves no estado aberto.

Desta forma, poder-se-á realizar o treinamento e verificação de todas as chaves em todos os estados possíveis. Este sistema foi validado com pequenas chaves de alimentadores de distribuição, que puderam ser processadas utilizando algoritmos em 2D. O próximo desafio será identificar o estado de chaves seccionadoras de grande porte em subestações de transmissão que, devido à sua geometria complexa, exigirão processamento 3D com captura de, pelo menos, duas imagens de ângulos diferentes para cada chave.

### 4.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) LECUN, Y.; BENGIO, Y.; HINTON, G. . Deep learning, Nature 521 (7553), 2015.
- (2) NASSU, B. T. ; MARCHESI, B. ; LIPPMANN JR, L. ; WAGNER, R. ; ZARNICINSKI, V. ; ALMEIDA, A. C. . Image-Based State Recognition for Disconnect Switches in Electric Power Distribution Substations. In: SIBGRAP'18 31st Conference on Graphics, Patterns and Images, Foz do Iguacu Brazil, 2018.
- (3) LIPPMANN JR, L. ; MARCHESI, B.; WAGNER, R. ; CUSTODIO, E. S. ; HEUER, F. ; SEIDEL, D. ; SALLES, F. ; OLIVEIRA, C. ; MARTINI, L. G. ; NASSU, B. T. Videomonitoramento com reconhecimento automático de imagens para suporte à operação de dispositivos em subestações. In: Anais do XXIV SNPTEE, 2017.
- (4) MAHALANOBIS, P. C. On the generalised distance in statistics. Proceedings of the National Institute of Sciences of India. 2 (1), pp.49–55, 1936.



## 5.0 - DADOS BIOGRÁFICOS



Lourival Lippmann Junior é graduado em Engenharia Eletrônica pelo Instituto Tecnológico de Aeronáutica ITA (1980), pós-graduado Mestre em Engenharia Elétrica e Informática Industrial pela UTFPR (1993). Tem experiência na área de Energia e Computação, com ênfase em Arquitetura de Sistemas, redes de comunicação, redes inteligentes para setor elétrico - instrumentação, medição, supervisão e automação de sistemas de energia, processamento de imagens e DSP.



Vanderlei Zarnicinski possui graduação em Engenharia Industrial Elétrica pela Universidade Tecnológica Federal do Paraná UTFPR (1996) e Mestrado em Informática pela Pontifícia Universidade Católica do Paraná (2006). Atualmente é engenheiro eletricitista - COPEL Distribuição. Tem experiência na área de Engenharia Elétrica, com ênfase em Automação de Subestações e Redes de Distribuição.



Marcos Scremin possui graduação em Engenharia Elétrica pela Universidade Positivo (2004) e Curso de Aperfeiçoamento em Manutenção de Sistemas Elétricos pela UNIFEI / FUPAI - Universidade Federal de Itajubá / Fundação de Pesquisa e Assessoria à Indústria (2009). Atualmente é engenheiro de manutenção de subestações na COPEL Geração e Transmissão. Tem experiência na área de Engenharia Elétrica, com ênfase em subestações de Transmissão e Distribuição de Energia Elétrica.



Bruno Marchesi é graduado em Engenharia Industrial Elétrica – Eletrônica/Telecomunicações pela UTFPR (1996), pós-graduado Mestre em Engenharia pela UTFPR (1998). Possui experiência em equipamentos de medição para a qualidade da energia elétrica; sistema para reconhecimento automatizado e inteligente de estados de chaves seccionadoras em subestações de energia; despacho otimizado; rede de comunicação híbrida com meios alternativos; investigação de métodos de menor custo para prospecção e avaliação do potencial solar brasileiro.



Amanda Canestraro de Almeida é graduada em Engenharia Elétrica pela UFPR (2013) e Mestre em Engenharia Elétrica também pela UFPR (2015). Trabalha no Lactec há 10 anos na área de eletrônica atuando principalmente no desenvolvimento de softwares embarcados e em aplicações de software voltadas para soluções para o sistema elétrico. Possui experiência no desenvolvimento de SmartGrids e dispositivos IoT para o setor de energia elétrica e também na área de visão computacional. Possui publicações em eventos relevantes do setor elétrico, incluindo publicações de visão computacional. É co-autora de patente desenvolvida para o setor elétrico.



Rafael Wagner é graduado em Engenharia de Computação pela PUC-PR (1999), pós-graduado Especialista em Engenharia de Produção pela PUC-PR (2001). Atua com P&D há mais de 19 anos em eletrônica e informática. Premiado em 2016 com o Smart Grids Excellence Awards da 14th Latin American Utility Week.



Victor Barpp Gomes é graduando em Engenharia de Computação pela UTFPR (previsão de conclusão em 2019). É técnico em Informática pelo IFSC (2015). Foi medalhista na Olimpíada Brasileira de Física nos anos de 2011 (prata), 2012 (ouro) e 2013 (bronze), e terceiro lugar na Olimpíada de Física Básica da UTFPR em 2018. Realiza estágio na área de Eletrônica, sendo treinado em Sistemas Embarcados.



Bogdan Tomoyuki Nassu possui graduação (2003) e mestrado (2005) em Ciência da Computação pela Universidade Federal do Paraná UFPR, e doutorado em Estudos Avançados Interdisciplinares pela Universidade de Tokyo (2008). É professor da Universidade Tecnológica Federal do Paraná UTFPR em Curitiba/PR desde 2012. Atuou em projetos de P&D nos Institutos Lactec entre 2001 e 2005; e foi pesquisador no instituto de pesquisa do grupo Japan Railways (JR), entre 2008 e 2011. Tem experiência na área de Ciência da Computação, com ênfase em visão e inteligência computacional.