

# Sistema de Monitoramento de Chaves Seccionadoras por Visão Computacional e Redes Neurais Artificiais para Suporte ao Sistema de Controle Supervisório da CHESF

D. F. Colaço, A. R. de Alexandria, P. C. Cortez, UFC, J. B. B. Frota, CEFETCE, J. N. de Lima, A. E. A. L. Calazans, F. A. Façanha, CHESF

Resumo - As chaves seccionadoras são equipamentos de fundamental importância para a manutenção em linhas e subestações de alta tensão, tendo o mesmo grau de importância o monitoramento de seu correto funcionamento. Este trabalho descreve a aplicação inovadora de um sistema de visão artificial com o objetivo de monitorar o estado de chaves seccionadoras em subestações de alta tensão. O sistema descrito neste trabalho utiliza redes neurais artificiais do tipo SOM, permitindo agrupar diversos processos que compõem um sistema de visão artificial típico. São descritos os conceitos básicos das áreas de sistema artificial e de redes neurais. O sistema é desenvolvido em linguagem de programação C++, dotado de interfaces de fácil operação. Na obtenção dos resultados, consideram-se três ambientes: um para simulação em laboratório e dois projetos pilotos instalados na subestação Fortaleza II/CHESF. Estes pilotos são usados para os testes de monitoramento de chaves seccionadoras de 230 kV do tipo EV-2000 e do tipo semi-pantográfica em chaves de 500 kV. Os resultados comprovam a eficiência do sistema desenvolvido, pois, consegue acertar em 100% nas situações de identificação de estados aberto e fechado, reduzindo seu desempenho apenas em situação de transição de estados, portanto, em situações dinâmicas que não são relevantes para o estágio atual do protótipo.

Palavras-chave – visão artificial, redes neurais artificiais, chaves seccionadoras, manutenção.

## I. INTRODUÇÃO

O setor elétrico atualmente desempenha papel vital para o desenvolvimento de qualquer nação. Este setor é constituído por um sistema de alta complexidade, envolvendo uma grande quantidade e diversidade de equipamentos, cada um com seu modo de operação e características peculiares. Cada vez mais se tem optado por soluções de automação para operação de sistemas de forma a melhorar vários parâmetros de qualidade, destacando-se a confiabilidade e a segurança em manobras.

Nesse tipo de solução, um sistema supervisório, capaz de obter informações em tempo real, através de medidas digitais, sobre os estados/controle de todos os equipamentos do sistema elétrico sob supervisão, tem papel fundamental, permitindo inclusive a visualização gráfica de seus estados. Dentre estes equipamentos, as chaves seccionadoras, responsáveis por manobras no sistema elétrico, têm importância crucial, principalmente em sistemas de alta tensão, pois, somente a correta observação de seus estados, permite manobras seguras e confiáveis para este sistema [1]. Adiciona-se a isto o fato de que tais manobras são essenciais em serviços de manutenção de equipamentos e das linhas de

transmissão do sistema elétrico, incluindo-se a manutenção destas mesmas chaves. No entanto, do lado de alta tensão, é difícil a instalação de sensores eficientes no monitoramento de estados destas chaves, pois, a existências de campos elétricos e magnéticos fortes podem dificultar medidas corretas de seu estado real. Além disso, a correta avaliação do estado real de tais chaves, até o presente momento, somente pode ser confiável pela visualização *in loco*, constituindo-se um sério problema para a confiabilidade de manobras em subestações de alta tensão.

Diversos trabalhos têm sido desenvolvidos para a automatização e controle de subestações, avaliando a comunicação de dados em tempo real e o tempo de processamento do sistema SCADA (*Supervisory Control and Data Acquisition*) [2], especificações de sistemas de telecontroles, evidenciando a importância da supervisão dos estados dos equipamentos em subestações [1], sistema de automatização de subestações na COPEL [3], importância do controle dos estados das chaves seccionadoras na redução de perdas em redes de distribuição de energia elétrica [4], entre outros. Entretanto, em nenhum dos trabalhos pesquisados na literatura especializada, encontram-se trabalhos de monitoramento de chaves seccionadoras por visão computacional ou artificial, destacando-se como uma inovação na aplicação desta abordagem para esta questão.

No contexto apresentado, o projeto proposto visa desenvolver um sistema de visão artificial capaz de identificar automaticamente o estado real destas chaves, a partir da análise de imagens digitais obtidas das mesmas. Isto complementa um dos principais paradigmas de sistemas de medição que é a confiabilidade na medida objetiva [5], uma vez que o sistema proposto faz a verificação do estado real de chaves seccionadoras independente do operador.

O restante do trabalho está organizado da seguinte forma: a seção II descreve toda a metodologia desenvolvida no projeto, envolvendo os materiais e métodos; na seção III são apresentados os resultados e discussões sobre os mesmos; finalizando com a seção IV, em que são apresentadas algumas conclusões.

## II. MATERIAIS E MÉTODOS

Nesta seção, inicialmente são apresentados conceitos e funções básicos sobre os materiais e equipamentos usados para, em seguida, fazer a descrição dos mesmos. Quando se tratar dos métodos empregados, são definidos os conceitos

teóricos necessários ao entendimento dos mesmos, bem como de seus desempenhos.

#### A. Chaves seccionadoras

As chaves seccionadoras são dispositivos de manobras de abertura e fechamento de circuitos, utilizadas em alta tensão, assegurando uma desconexão visível dos condutores, além de serem utilizadas em manobras entre circuitos, de forma a possibilitar transferência de cargas e isolamento de equipamentos e circuitos [6,7]. Neste trabalho, utilizam-se as chaves de 230kV e de 500kV, sendo que a primeira é do tipo EV – 2000, mostrada na Figura 1, e a segunda do tipo semi-pantográfica, mostrada na Figura 2. Um pólo de uma chave seccionadora de 230 kV (fora de uso) é montada no pátio do Laboratório de Teleinformática – LATIN para fins de simulação manual de seus estados com um sistema de visão em desenvolvimento.

#### B. DVR

O DVR (*Digital Video Recorder*) é um equipamento que permite gravar vídeos e também ser usado como servidor destes vídeos, podendo distribuí-los pela *internet*. É fabricado pela empresa AI Digital, modelo JAD-400.



Figura 1. Chave seccionadora de 230 kV, do tipo EV-2000.



Figura 2. Chave seccionadora de 500 kV, do tipo semi-pantográfica.

#### C. Câmeras

As câmeras são responsáveis pela aquisição de imagens e vídeos das chaves seccionadoras para possibilitar a

identificação de seu estado real. São usadas câmeras coloridas marca VTV, modelo DSP220x, SONY HAD CCD, auto foco, auto íris, zoom óptico 22x, zoom digital 10x, lente 3,9 a 85,8 mm. Esta câmera possui dispositivo de controle PTZ (*pan tilt e zoom*), modelo PNT-TILT 301-0 UTD.OR referente ao posicionamento da câmera e controle de zoom das lentes, através de interface serial RS-485 com o DVR. Sua taxa de aquisição chega a 30 *frames* por segundo.

#### D. Outros

Outros acessórios importantes que fazem parte do material são: placa I/O para interfaceamento com a câmera (DSP220x) e DVR, através de porta serial RS485; gabinetes das câmeras, cabo coaxial tripolar 67% de malha e fontes de alimentação adequadas.

#### E. Conceitos Teóricos Básicos

Inicialmente são apresentados conceitos básicos para entendimento dos métodos e algoritmos que compõem o sistema proposto.

##### Imagem Digital

Uma imagem digital é caracterizada por uma função em duas dimensões  $f(x,y)$ , em que  $x$  e  $y$  são as coordenadas de um determinado ponto, denominado de *pixel*, podendo ser representada matematicamente por uma matriz. Neste caso, os componentes desta matriz são os *pixels* e as linhas e colunas expressam as coordenadas destes [8].

As imagens digitais podem ser coloridas ou em níveis de cinza. No primeiro caso, assumem três canais que, no sistema RGB, são os canais R (*Red*), G (*Green*) e B (*Blue*), sendo representada por uma matriz para cada canal [8].

Um vídeo digital é formado por uma seqüência de imagens digitais, denominadas de *frames*.

##### Sistema típico de visão artificial

Segundo Filho e Neto [9], um sistema de Visão Artificial ou Computacional é definido como um sistema computadorizado capaz de adquirir, processar e interpretar imagens correspondentes a cenas reais. Um sistema típico de Visão Artificial está representado na Figura 3, em que se encontra subdividido em seus vários processos, descritos a seguir [8,10].

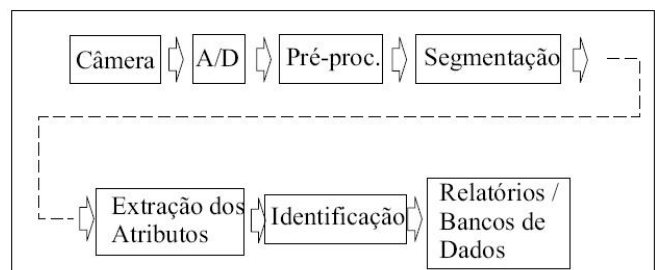


Figura 3. Diagrama de bloco de um sistema típico de visão artificial.

O primeiro processo em um sistema de visão é a aquisição de imagem. Neste processo, uma iluminação adequada a ser utilizada na cena é de fundamental importância, proporcionando uma imagem, cuja qualidade pode facilitar os outros processos do sistema. Outras modalidades diferentes da luz visível, como o infravermelho, microondas,

raios-x, raios gama, entre outras radiações eletromagnéticas, ou ondas acústicas (sistemas de imagens ultra-som) ou ainda campo magnético (tomografia), podem ser utilizadas para se constituir a imagem de entrada do sistema [11,12]. Para a aquisição de imagens, um dispositivo, adequadamente especificado para esta aplicação, deve ser utilizado, normalmente uma câmera de vídeo ou máquina fotográfica. Dispositivos com tecnologia CCD e CMOS são os mais utilizados atualmente. Em caso de saída analógica da câmera de vídeo ou câmera fotográfica, a utilização de um conversor analógico/digital se faz necessária [13].

Após a aquisição da imagem, esta deve ser submetida a um pré-processamento, que consiste normalmente em operações de Processamento Digital de Imagens realizadas para extrair ruído, efetuar restauração ou realce ou somente a representação apropriada dos dados de entrada. Este processo é necessário para condicionar a imagem para o processo seguinte que é a segmentação [10].

A segmentação é um processo de separar as várias regiões que compõem uma imagem, de acordo com suas propriedades. A técnica de segmentação a ser utilizada varia com a aplicação do sistema. Este processo é de fundamental importância em qualquer sistema de visão artificial, de tal forma que o desempenho deste sistema é inteiramente dependente do processo de segmentação. Uma segmentação adequada é um passo substancialmente importante para o seu correto funcionamento.

As feições ou atributos de regiões segmentadas são extraídos no processo de extração de atributos, sugeridos pelo próprio nome. Estes atributos podem ser representados por símbolos de modo a facilitar a aplicação dos processos seguintes que são de classificação e de interpretação dos resultados.

O processo de identificação consiste na classificação dos objetos selecionados, empregando-se técnicas de reconhecimento de padrões, estatística ou Inteligência Artificial. Por último, os dados obtidos no processo de classificação são apresentados da forma mais conveniente possível para a aplicação, podendo ser na tela do computador, relatórios, banco de dados, ou outra forma qualquer de saída de dados, uma ação de controle ou supervisão, etc.

### Redes neurais artificiais

O cérebro humano é formado por cerca de 10 bilhões de neurônios, sendo que suas estruturas são de maior complexidade estrutural e funcional existentes no organismo humano [14]. Estas unidades estão densamente interconectadas, o que resulta em uma arquitetura altamente complexa e com nível de inteligência ainda não igualado por nenhum computador [15]. Diversas modelagens matemáticas já foram criadas para representar os neurônios, cada qual refletindo o conhecimento disponível na época, assim como diversas arquiteturas para interconexão dos neurônios modelados. Assim surgiram as Redes Neurais Artificiais (RNA), na busca de se conseguir reproduzir uma das capacidades mais fascinantes do cérebro do humano, a capacidade de aprender.

Na busca de se obter uma maior semelhança com a estrutura biológica, as arquiteturas artificiais devem possuir diversos neurônios em uma estrutura de pesos de conexões,

que permite o aprendizado e a adaptação da rede, organizados segundo uma arquitetura paralela (apesar da execução em um computador seqüencial), de forma que a falha de um neurônio afete o mínimo possível no funcionamento da rede. Assim uma rede neural é um processador distribuído altamente paralelo, formado por unidades simples (neurônios), sendo a mesma capaz de adquirir conhecimento segundo um processo de aprendizado [16].

Como já explicado, a rede é formada por uma estrutura paralela, sendo utilizado um algoritmo para sua execução em um computador seqüencial. Através desta interconexão paralela dos neurônios as redes neurais são capazes de modelar relações lineares e não lineares, podendo calcular diversas funções matemáticas complexas que são realizadas em um computador digital [17]. Assim, as redes neurais podem ser usadas em diversas tarefas de classificação e reconhecimento de padrões, sendo utilizadas como funções discriminantes [16]. Aplicações de redes neurais artificiais em sistemas de Visão Artificial são encontradas abundantemente na literatura [19, 20].

### Neurônio artificial

O neurônio artificial é muito semelhante aos neurônios biológicos na sua estrutura e funcionamento. O neurônio possui a princípio um ou mais sinais de entrada, e uma única saída. As entradas em um neurônio artificial podem ser comparadas aos estímulos para o neurônio natural [14]. Todas as entradas devem apresentar seu estímulo ao mesmo tempo (em paralelo) e esse paralelismo pode ser conseguido nos computadores atuais (seqüenciais) através de um algoritmo que simula este paralelismo.

O primeiro modelo matemático para o neurônio, proposto por McCulloch e Pitts, possui uma saída binária, e as várias entradas têm um ganho arbitrário podendo ser excitatórias ou inibitórias. Os ganhos presentes nas entradas são chamados de pesos sinápticos (ou somente pesos). Assim o valor do sinal de entrada juntamente com os pesos determina a saída do neurônio (ativa ou não ativa) [16]. Neste modelo, as entradas são representadas computacionalmente por um vetor  $\mathbf{x}$  ( $x_1, x_2, x_3, \dots, x_n$ ), assim como os pesos sinápticos por um vetor  $\mathbf{w}$  ( $w_1, w_2, w_3, \dots, w_n$ ). Assim, quando as entradas são apresentadas para os neurônios, elas são multiplicadas pelos pesos e a soma destes resultados é o sinal de excitação do neurônio  $E$ , pode ser expresso por

$$E = \sum_{i=0}^n x_i * w_i \quad . \quad (1)$$

Desta forma, o sinal de excitação  $E$  é o resultado da soma das entradas multiplicadas por seus respectivos pesos em um dado instante de tempo, sendo que o conhecimento adquirido pelo neurônio é armazenado nos seus pesos.

Após o cálculo do sinal de excitação, este se torna um parâmetro em uma outra equação, que baseado no valor desse sinal determina a saída do neurônio, essa é a função de ativação. A função de ativação, também conhecida como limiar lógico (*threshold*), pode ter muitas formas ou métodos, podendo ser simples ou complexa, sendo esta

função responsável por enviar para a saída do neurônio o valor repassado pelo sinal de excitação. Na Figura 4 são apresentadas algumas típicas funções de ativação.




Figura 4. Exemplos de funções típicas de ativação de neurônios: a) degrau; b) pseudo-linear; c) sigmoidal; d) tangente hiperbólica.

A saída de um neurônio, mapeada por sua função de ativação, pode servir como entrada para outros neurônios, ou servir como resposta final na saída da rede, existem ainda redes em que o sinal de saída pode além de ir a outro neurônio, ou para fora da rede, ir também para a entrada do próprio neurônio que gerou a saída, servindo como uma realimentação. Assim pode-se representar o neurônio completo na forma pelo modelo da Figura 5, em que "Σ" representa o sinal de excitação e "T" sua função de ativação.




Figura 5. Modelo de um neurônio artificial.

Existem diversos tipos de redes neurais, dependendo das ligações entre os neurônios, dentre estas se destacam as redes do tipo SOM (*Self Organizing Map*).

#### Redes neurais SOM

O modelo proposto por Kohonen [18] consiste em uma rede neural do tipo *feedforward*, com treinamento não-supervisionado. Este modelo normalmente se apresenta em uma camada única dispostos linearmente (1-D) ou em um plano (2-D). Considerando uma rede de duas dimensões, a rede de Kohonen não impõe nenhuma organização topológica, podendo ser quadrada, triangular, retangular etc. Este modelo de rede é classificado como uma rede auto-organizável SOM, em que os neurônios estão dispostos em um reticulado, que pode ser unidimensional ou

bidimensional, conforme mostrado na Figura 6. Nesta Figura é apresentada uma rede bidimensional em uma topologia quadrada formada por nove neurônios arranjados numa disposição 3x3.




Figura 6. Modelo de uma rede SOM.

Quando um padrão é apresentado a uma rede do tipo SOM, os neurônios competem entre si para determinar quem melhor responde ao padrão de entrada. O neurônio que gerar a menor distância euclidiana, entre as entradas e o vetor de saída, é escolhido o neurônio vencedor e este tem seus pesos ajustados de forma a responder melhor a este padrão de entrada. Assim a rede de Kohonen apresenta a propriedade de se modificar, a fim de que um neurônio apresente uma resposta melhor para um determinado padrão de entrada [18].

Dentro do modelo de aprendizado não-supervisionado, não somente o neurônio vencedor tem seus pesos ajustados, mas como também os neurônios que se situam dentro de uma vizinhança de raio  $r$ . Este paradigma é baseado na teoria de que as células nervosas corticais são arranjadas anatomicamente em função dos estímulos que recebem dos sensores às quais estão conectadas [18].

Cada neurônio, numa rede do tipo SOM, representa de fato uma saída da rede, ou seja, uma rede com 10 neurônios na camada de saída apresenta até 10 possibilidades de saídas. Outra característica dessa rede é que os neurônios estão totalmente conectados (ligações sinápticas), logo se existem 10 entradas na rede, cada neurônio da camada de saída tem 10 entradas, cada uma ligada a um ponto da camada de entrada. Cada conexão sináptica possui um peso, de forma que se houver 10 pontos de entrada e 3 neurônios na camada de saída, devem haver 30 conexões (10 para cada neurônio) e conseqüentemente 30 pesos sinápticos (10 para cada neurônio). Nesta arquitetura porém, não se usa a função de ativação nem o sinal de excitação.

#### Vizinhança

Um neurônio apresenta um conjunto de vizinhos, denominado de vizinhança, que se organizam topologicamente formando regiões que apresentam uma melhor resposta a um dado estímulo. Esta característica é semelhante ao cérebro, em que existem centros de atividade mais intensificados dependendo da atividade que esta sendo realizada.

No início o conjunto de vizinhos é extenso, este vai diminuindo com o tempo, à medida que a rede se organiza. De fato, para sua melhor ordenação, o conjunto de vizinhos inicia extenso e é monotonicamente diminuído com o tempo de processamento da rede, pois, se a vizinhança inicia muito

pequena em relação ao mapa, este não se ordenara globalmente [14]. Uma proposta bastante utilizada é que no final do processo o raio de vizinhança deve ser zero, e somente o neurônio vencedor tem seus pesos ajustados.

O ajuste dos pesos dos neurônios no conjunto de vizinhos permite que neurônios, próximos ao neurônio vencedor, tenham as mesmas condições de disputa com o neurônio vencedor nas iterações seguintes, aumentando a competição pelo melhor aprendizado na rede.

#### Adaptação dos neurônios

A adaptação dos neurônios consiste no ajuste de seus pesos afim de melhorar sua resposta para um determinado estímulo, este processo é fundamental para formação ordenada da rede.

Para o ajuste de pesos primeiro deve-se determinar quem é o neurônio vencedor. Como já explicado, o neurônio vencedor é aquele que apresenta a menor distância euclidiana  $d_t(n)$  entre o padrão de entrada e seus pesos, calculada por

$$d_t(n) = \sum_{i=1}^I (x_t(i) - w_{n,i}(t))^2 \quad (2)$$

em que  $x_t(i)$  é a  $i$ -ésima componente do vetor de entrada no tempo  $t$ ,  $w_{n,i}(t)$  é o  $i$ -ésimo componente do vetor de pesos de um neurônio  $n$  no tempo  $t$ ,  $i$  é o índice das entradas e pesos para uma rede com  $I$  entradas e  $d_t(n)$  é a distância Euclidiana do neurônio  $n$  no tempo  $t$ . Assim, a distância euclidiana é a soma do quadrado da diferença entre cada entrada e seu peso correspondente. Na prática, a menor distância euclidiana representa o neurônio, cujo valor dos pesos mais se assemelha ao valor da entrada apresentada [18]. Desta forma, em cada interação, os neurônios que apresentam a menor distância euclidiana, bem como os neurônios que fazem parte do seu conjunto de vizinhos, devem ter seus pesos ajustados para melhor responder aquela entrada, os demais neurônios não são alterados.

A adaptação, valor da variável para o instante seguinte  $t+1$ , é um processo simples, e consiste em tomar-se a diferença entre os dois vetores ( $x$  e  $w$ ) e somar uma fração desta diferença ao vetor de pesos original, sendo que o ajuste dos pesos dos neurônios vizinhos segue este mesmo princípio, expresso por

$$w_n(t+1) = w_n(t) + a_s(t) * (x(t) - w_n(t)), \quad (3)$$

em que  $a_s(t)$  (taxa de aprendizado), corresponde à fração da diferença entre  $x$  e  $w$  que é somada à  $w$ . Assim se não houver  $a_s(t)$  todos os pesos se tornam iguais às entradas do padrão recém apresentado, e se esses pesos não são alterados até que este padrão seja apresentado novamente, a nova distância euclidiana é zero, de forma que não haveria possibilidade para aprendizado nem para competição. Para tanto é necessário que  $0 < a_s < 1$ . Outro detalhe é que  $w(t+1)$  significa que, no próximo padrão a ser apresentado, devem-se utilizar os novos pesos [18].

É comum iniciar  $a_s$  (Equação 3) com um valor alto (aproximadamente um), em seguida decrementá-lo (seguindo alguma regra ou função) até que se aproxime de zero. Assim, o ordenamento do mapa acontece no período inicial, tanto pelo raio de vizinhança maior como pelo  $a_s$  maior.

#### Iterações

O número de iterações ou número de épocas, corresponde à quantidade de vezes que os padrões de entrada são apresentados à rede. Em cada época, deve-se apresentar todos os padrões de entrada. Cada vez que um padrão é apresentado, o neurônio vencedor e seus vizinhos passam pelo processo de adaptação. Quando o último padrão é apresentado, inicia-se uma nova época, em que todos os padrões devem ser apresentados novamente. Uma medida empírica que tem sido adotada é a de perfazer-se 500 iterações, para cada neurônio na camada de saída. Assim se houver 10 neurônios na camada de saída, devem-se realizar 5.000 iterações. Observa-se que isto não constitui uma regra, sendo apenas recomendações baseadas em observações de determinados pesquisadores [14].

#### Algoritmo de treinamento da rede SOM

Os passos para realização do treinamento de uma rede SOM são [18]:

1. especificar o número de épocas;
2. iniciar com valores aleatórios os pesos dos  $N$  neurônios na camada de saída;
3. especificar o raio da vizinhança inicial de cada neurônio (é recomendado que o raio inicial seja do tamanho da própria rede);
4. apresentar uma entrada à rede;
5. calcular para cada neurônio da camada de saída a distância euclidiana entre a entrada e os pesos do neurônio de saída;
6. selecionar o neurônio vencedor (aquele que apresentar a menor distância euclidiana);
7. atualizar os pesos do neurônio vencedor e dos neurônios presentes em seu conjunto de vizinhos;
8. decrementar o raio da vizinhança se ainda houver neurônios vizinhos;
9. se ainda houver algum padrão não apresentado nesta época, voltar ao passo 4;
10. incrementar número de épocas e
11. se ainda não atingiu o número de épocas, voltar ao passo 4 e apresentar novamente todos os padrões.

É importante que o valor inicial dos pesos sejam diferentes e bem menores do que os padrões de entrada. Se os pesos são iniciados com valores semelhantes às entradas, haverá na rede uma tendência de gerar determinados neurônios vencedores, impedindo sua auto-organização.

#### Neurônios vencedores

Após o treinamento da rede, pode-se rotular cada neurônio de acordo com o padrão que este classifica. Desta forma, se, por exemplo, a rede está classificando objetos, o neurônio vencedor que representa um determinado objeto pode ser rotulado com o nome deste objeto. Entretanto, nada impede que mais de um neurônio classifique o mesmo objeto, de fato que isto pode ocorrer devido a vizinhança. Caso isto ocorra, há mais de um neurônio com o mesmo rótulo.

#### Classificação de padrões

Quando a rede já está treinada e deseja-se apresentar um padrão para que a rede o classifique, devem-se seguir os passos:

1. iniciar os pesos dos neurônios na camada de saída com os valores finais obtidos na fase de treinamento;



2. apresentar o padrão à rede;
3. calcular para cada neurônio a distância euclidiana entre o padrão de entrada e os pesos do neurônio e
4. selecionar como neurônio vencedor aquele que apresentar a menor distância Euclidiana.

A determinação do neurônio vencedor implica na classificação do padrão.

*Estratégia de reconhecimento de estado de chaves seccionadoras utilizada*


Neste trabalho, para o reconhecimento do estado real de chaves seccionadoras são adotados três estados possíveis, definidos pela equipe de manutenção da CHESF:

- aberto - em que o circuito em que a chave está inserida encontra-se totalmente aberto;
- fechado – em que o circuito em que a chave está inserida encontra-se totalmente fechado e
- anormal - em que o circuito em que a chave está inserida encontra-se nem totalmente fechado, nem totalmente aberto.


Na Figura 7 são apresentadas imagens de uma chave seccionadora semi-pantográfica de 500kV, em diferentes estados. A situação anormal pode ocorrer em caso de falhas ou durante o processo de abertura ou fechamento. Situações de falhas existem quando é dado um comando para abrir e a chave não muda para o estado aberto, mantendo-se na posição fechada ou estabilizando em uma posição entreaberta ou quando é dado um comando para fechar e a chave não muda para o estado fechado, mantendo-se na posição aberta ou entreaberta.



a)



b)



c)

Figura 7. Imagens de uma chave seccionadora em diferentes estados: a) fechada; b) entreaberta e c) aberta.

Visando o reconhecimento automático do estado da chave, efetua-se a aquisição de imagens mostrando detalhes da chave nas regiões A e B, conforme indicado na Figura 8. A ausência da haste da chave na região A e sua presença na região B, determina que a chave está aberta. Por outro lado, sua presença na região A e ausência na região B, determina que a chave está fechada. Situações, diferente destas, são consideradas falhas ou estado entreaberto da chave (anormal).



Figura 8. Detalhes da chave seccionadora: região (A) e região (B).

Para facilitar o reconhecimento do estado das chaves seccionadoras, principalmente as de 230 kV, pois estas chaves, durante a abertura ou fechamento realizam um movimento de rotação no contato móvel de 90 graus, é efetuada a colagem de um adesivo sobre a superfície da haste da chave seccionadora, conforme ilustrado na Figura 9. Observa-se que este modelo de chave seccionadora somente se encontra fechado se o engate for realizado com sucesso e isto só ocorre quando se completa tal rotação de seu contato móvel. Como a haste da chave possui uma cor metálica uniforme, não há como afirmar, a partir de informações visuais, o estado real da chave sem ter-se um ponto de referência, ponto este implementado pela inclusão do adesivo mencionado. Isto também facilita a identificação por parte da rede neural, diferenciando drasticamente a imagem da haste do fundo.



Figura 9. Detalhe do adesivo (marcação) sobre o contato móvel.

Várias imagens em diversas situações e condições de iluminação e posição são adquiridas de forma a ter-se imagens-exemplos significativas dos estados da chave. Cada imagem obtida possui a resolução de  $60 \times 60$  pixels e é convertida para tons de cinza. Uma rede neural SOM é treinada de acordo com os padrões de imagens obtidos. As imagens se encontram focadas na região de interesse que possui a marcação já mencionada.

Duas redes neurais SOM do tipo 1-D com 16 neurônios são utilizadas. Uma rede é aplicada no reconhecimento do estado do ponto A e a outra do ponto B, pontos estes exemplificados na Figura 8. Como a entrada da rede é a imagem completa do detalhe da chave, a rede neural possui 3.600 entradas ( $60 \times 60$  pixels), uma entrada para cada pixel da imagem. Cada rede neural é treinada com os padrões do estado aberto e fechado, bem como o estado anormal (entreato), sendo cada uma especialista. Ao final do treinamento, os resultados dos neurônios vencedores são rotulados manualmente de forma que a chave seja capaz de apresentar uma saída compatível com os três estados da chave. Esta rotulação manual é efetuada mediante verificação visual do responsável pelo treinamento da rede neural logo após o seu treinamento, identificando qual o padrão de estado obtido no referido treinamento.

O treinamento é efetuado somente na instalação do sistema de reconhecimento da chave ou quando manutenções são necessárias.

Após o treinamento, a rede pode ser usada para identificar em que estado se encontra uma dada chave, utilizando-se para tanto de uma imagem a ser processada pela rede neural. Neste caso, as imagens dos detalhes da chave são apresentadas à rede neural, ou seja, as imagens das regiões A e B (Figura 8) para que, de acordo com qual neurônio se apresenta ativo nesta situação de entrada, seja possível o reconhecimento do estado desta chave.

#### Sistema desenvolvido

O sistema descrito neste trabalho é desenvolvido para a plataforma Windows, implementado na linguagem de programação C++, utilizando-se da IDE C++ Builder v.6.0 da Borland.

Diversos processos que compõem um sistema de visão típico, mostrado na Figura 3, são agrupados em um único processo que é o processo de extração de atributos, excetuando-se o pré-processamento que é suprimido,

embora, caso seja realizado, pode influir no desempenho do sistema.

Este sistema possui várias telas de interface de comunicação com o usuário, dentre estas, as principais se encontram mostradas nas Figuras 10, 11 e 12 que se seguem.



Figura 10. Interface de configuração de vídeo e aquisição de imagens.

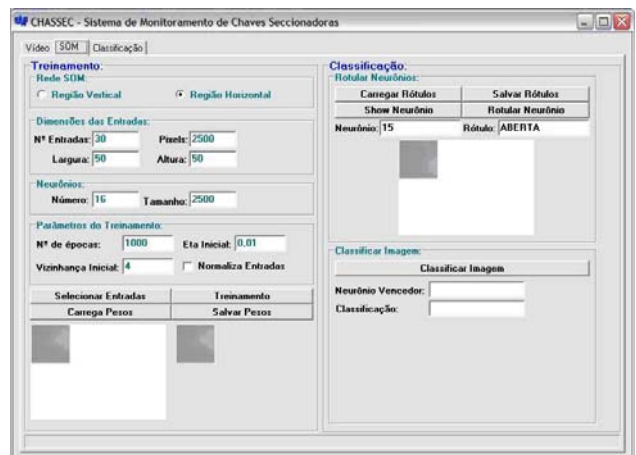


Figura 11. Interface de treinamento da rede SOM.

A interface de configuração de vídeo e de aquisição de imagens permite realizar ajustes de vídeo em tempo real e capturar as regiões da imagem que são utilizadas no treinamento das redes SOM.



Figura 12. Interface do sistema em operação.



A interface de treinamento da rede SOM possibilita configurar os parâmetros de treinamento da rede, selecionar as entradas que são utilizadas na rede e, finalmente, rotular os neurônios que são empregados na identificação do estado da chave.

Na tela de reconhecimento, as imagens das chaves seccionadoras são capturadas e avaliadas pela rede SOM, permitindo a identificação automática do estado da chave seccionadora. Esta tela também permite a possibilidade de se realizar um levantamento estatístico das identificações realizadas com sucesso e dos erros cometidos, recurso utilizado somente na fase de testes do sistema.

### III. RESULTADOS

Encontra-se instalado um pólo de uma chave de 230 kV, do tipo EV-2000 no LATIN, cuja finalidade foi desenvolver as simulações, aguardando a instalação de dois projetos pilotos na Subestação da Fortaleza II/CHESF. Isto contribuiu muito para o desenvolvimento do sistema.

Os testes com imagens obtidas no LATIN são promissores e confiáveis, pois, foram simulados diversos aspectos, inclusive variação de iluminação, além de todos os estados da chave, obtendo-se 100% de acerto. Entretanto, as condições não são exatamente iguais às dos projetos pilotos instalados na subestação Fortaleza II/CHESF.

Os pilotos foram instalados para as chaves de 230kV e de 500kV, cujos resultados são mostrados na seção de resultados. Também foi instalado nestes pilotos um sistema de aquisição de imagens digitais de chaves (com marcações adequadas) na chave (três pólos) da rede de 230kV, bem como equipamentos DVR para gravação e disponibilização de vídeos digitais pela *intranet* da CHESF.

A identificação dos estados fechado, aberto e anormal, definidos pela equipe da CHESF são usados para obtenção de resultados.

Nos resultados aqui apresentados não estão considerados no período noturno, pois, verificou-se que a iluminação existente é insuficiente para que o sistema possa operar adequadamente. Esta situação pode ser solucionada com a instalação apropriada de holofotes direcionados para as chaves seccionadoras em monitoramento pelo sistema.

As imagens podem ser obtidas somente após a informação do sistema de controle da subestação de que haverá mudança de estado.

Os resultados estão divididos, conforme as tensões das chaves, de 230 kV e de 500 kV.

#### A. Chaves semi-pantográficas de 500kV

Nas chaves semi-pantográficas, instaladas na rede de 500kV, apresentadas na Figura 13, cada uma das redes neurais foram treinadas com 32 imagens (60x60 (*pixels*)) contendo os padrões de chave aberta e de chave fechada. O teste do sistema foi realizado mediante o uso de 70 imagens, com diferentes condições de luminosidade e de posicionamento das chaves.

As duas redes funcionando em conjunto obtêm um percentual de acerto de aproximadamente 96%, errando somente nas situações em que a chave estava iniciando a mudança de estado de fechada para entreaberta, como apresentada na Figura 13. Nos estados de chave totalmente

aberta, totalmente fechada e em alguns casos de chave entreaberta, o sistema acertou 100%.



a)



b)

Figura 13. Imagens das chaves seccionadoras em diferentes estados: a) chave totalmente fechada, b) chave anormal (entreaberta).

#### B. Chaves de 230kV do tipo EV-2000


Nas chaves do tipo EV-2000, instaladas na rede de 230kV, apresentadas na Figura 14, cada uma das redes neurais foram treinadas com 32 imagens (60x60 (*pixels*)) contendo os padrões de chave aberta e de chave fechada.

O teste do sistema foi realizado mediante o uso de 70 imagens, com diferentes condições de luminosidade e de posicionamento das chaves. Com as duas redes, funcionando em conjunto, é obtido um percentual de acerto de aproximadamente 75%, errando-se somente nas situações em que a chave está iniciando a mudança de estado de fechada para entreaberta, em que a chave está por fazer o giro final que caracteriza a mudança de estado. A diferença entre estes estados é mínima, como apresentado na Figura 15. Nos estados de chave totalmente aberta, totalmente fechada e em alguns casos de chave entreaberta, o sistema acertou 100%.





Figura 14. Conjunto de chaves do tipo EV – 2000 na rede 230kV.



a)



b)

Figura 15. Imagens das chaves seccionadoras em diferentes estados: a) chave entreaderta, b) chave totalmente fechada.

#### IV. CONCLUSÕES

Este trabalho apresenta um protótipo de um sistema de visão artificial com a finalidade de monitoramento de chaves seccionadoras de alta tensão, 230 kV e 500 kV, utilizando-se redes neurais artificiais. São descritos os conceitos essenciais para a compreensão do trabalho, especialmente sobre redes neurais artificiais e visão computacional. Para a obtenção dos resultados são usados três locais: um para

simulação, com um pólo de uma chave de 230kV, instalado no LATIN; dois pilotos instalados na subestação Fortaleza II/CHESF, um numa chave de 230 kV e o outro numa chave de 500 kV, ambos contendo os três pólos.

Com base nos resultados pode-se afirmar que o sistema apresenta condições de operação, pois, em todas as situações apresentadas, exceto em algumas de transição de estados, apresentou um elevado percentual de acerto. Entretanto, é importante destacar que não houve condições de testes durante o período noturno, podendo necessitar de ajustes no protótipo.

Este trabalho, em pesquisa à literatura especializada, constitui uma inovação na aplicação de sistemas de visão artificial com a finalidade de monitoramento de chaves seccionadoras. Esta é a principal contribuição deste trabalho.

#### V. AGRADECIMENTOS

Os autores agradecem ao técnico em manutenção da subestação da CHESF FORTALEZA II, Marcos Vinicius e toda a equipe de manutenção que deram apoio incondicional ao trabalho prático.

Os autores também agradecem aos revisores pelas valiosas contribuições para a elaboração do texto final deste artigo.

#### VI. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] G. Grandi, "Metodologia para especificação de telecontrole em subestações de energia elétrica," Tese de Doutorado, Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Santa Catarina, 2000.
- [2] R. P. Siqueira, "Um modelo de implementação de mudança de modo em sistemas de automação de energia," Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Federal Tecnológica do Paraná, 2006.
- [3] V. C. Zambenedetti, A. C. Frisch, E. L. Parolin, E. L. Pepplow, L. S. Abe, M. S. Filho, "Desenvolvimento de interface do protocolo DNP v3.0 para o sistema de automação de subestações (SASE) e redes de distribuição da Copel," LACTEC/COPEL, Curitiba-PR. Relatório Técnico de Pesquisa ANEEL, 2000.
- [4] C. L. Filho, P. A. Vargas, F. J. von Zuben, "Redução de perdas em redes de distribuição de energia elétrica através de sistemas classificadores," SBA: Controle & Automação Sociedade Brasileira de Automática, vol. 14 (3), pp. 298-308, jul./sep. 2003.
- [5] D. S. Sink, T. C. Tuttle, *Planejamento e Medição Performance*, Rio de Janeiro: Qualitymark, 1993, p. 343.
- [6] M. P. Pereira, D. Ary e outros, *Equipamentos Elétricos, Especificações e Aplicação em Subestações de Alta Tensão*, Rio de Janeiro: Furnas, 1985, p. 143.
- [7] E. Kuffel, W. S. Zaengl, J. Kuffel, *High Voltage Engineering Fundamentals*, [S.l.]: Newnes, 2000, p.194.
- [8] R. C. Gonzalez, R. E. Woods, *Digital Image Processing*, 2ª Ed., Prentice Hall, 2002, p. 793.

- [9] O. M. Filho, H. V. Neto, *Processamento Digital de Imagens*, Rio de Janeiro: BRASPORT Livros e Multimídia Ltda, 1999, p. 132.
- [10] A. D. Marshall, R. R. Martin, *Computer Vision, Models and Inspection*, World Publishing Company, Londres: Inglaterra, 1992, p.152.
- [11] F. V. Heidjen, *Image Based Measurement Systems Object Recognition*, England: John Wiley and Sons Ltda, 1994, p. 158.
- [12] T. Tsuji, Development of night-vision system, IEEE Transaction on Intelligent Transportation Systems IEEE Transaction on Dielectrics and Electrical Insulation, 3 (3), pp. 203-209, sept. 2002.
- [13] C. A. Carneiro, D. L. Rodrigues, F. M. P. Garcia, "Plataforma de aquisição de sinais de vídeo com processamento digital de imagens em hardware," apresentado XV Congresso Brasileiro de Automática - CBA 2004, Gramado-RS, setembro 2004.
- [14] M. A. Tafner, M. Xerez, I. W. Rodrigues, *Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação*, Editora EKO, 1996, p. 201.
- [15] A. P. Timoszczuk, "Reconhecimento Automático do Locutor com Redes Neurais Pulsadas," Tese de Doutorado, Escola Politécnica, Universidade Federal de São Paulo, São Paulo, 2004.
- [16] S. Haykin, *Neural Networks: a Comprehensive Foundation*, 2ª ed., Englewood Cliffs, Prentice Hall, 1999, p. 842.
- [17] M. B. de Paula, "Reconhecimento de Palavras Faladas Utilizando Redes Neurais Artificiais," Monografia de Graduação, Instituto de Física e Matemática, Universidade Federal de Pelotas, 2000.
- [18] T. Kohonen, *Self-Organizing Maps*, 3ª ed. Berlin: Springer-Verlag, 2001, p. 521.
- [19] A. R. Alexandria, "Sistema de reconhecimento de óptico de algarismos para medidores convencionais de energia," Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia de Teleinformática da Universidade Federal do Ceará, 2005.
- [20] M. E. Petersen, D. Ridder, D. Handels, "Image processing with neural networks: a review," The Journal of the Pattern Recognition Society, v. 35, pp. 2279-2301, 2002.