

Sistema inteligente para a detecção de falhas de manobras em seccionadores de subestações de potência

INTELLIGENT SYSTEM FOR FAULT MECHANICAL DETECTION IN POWER SWITCH OPERATION

André Colen Carrasco
Germano Lambert-Torres
GAIA – Grupo de Aplicações de Inteligência Artificial,
UNIFEI – Universidade Federal de Itajubá

RESUMO

Este artigo tem por objetivo desenvolver um sistema capaz de detectar falhas incipientes e verificar a correta operação de abertura e fechamento de seccionadores de alta tensão pela análise digital da curva do torque fornecida pelo motor de acionamento durante as manobras do seccionador, superando assim as dificuldades envolvidas com o monitoramento direto dos contatos da parte ativa. Este sistema será baseado na utilização de dispositivos dedicados ao Processamento Digital de Sinais (DSP's) associado a algoritmos de Redes Neurais, para identificação de padrões de falhas recorrentes durante as manobras dos seccionadores. Os sinais a serem processados pelo DSP serão os valores do torque do motor de acionamento, calculado pelos valores instantâneos da potência elétrica fornecida. A análise, em tempo real, da curva do torque fornecida pelo motor durante as operações de abertura e fechamento possibilitará um monitoramento indireto da posição dos contatos principais do seccionador, aumentando a confiabilidade de operação do sistema elétrico. As informações fornecidas pelo sistema de detecção de falhas permitirão uma manutenção preditiva mais eficiente dos seccionadores, baseada nas indicações de desajustes ou quebras de componentes no sistema mecânico de acionamento e parte ativa da chave.

PALAVRAS CHAVE

Sistema Inteligente, Subestações Elétricas, Equipamentos de Potência.

ABSTRACT

The purpose of this paper is to present the development of a system capable of detecting incipient

malfunction and also verifying the correct operation of opening and closing of high voltage switches thru digital analysis of the torque curve supplied by the drive engine during the maneuvers of the switch, surpassing the difficulties involved with the direct monitoring of the contacts. This system will be based on the use of dedicated devices to the Digital Signals Processing (DSP's) associated to the algorithms of Artificial Neural Networks, for pattern recognitions of recurrent malfunction during the maneuvers of the high voltage switches. The signals to be processed by the DSP will be the values of the torque of the drive engine, calculated by the immediate values of the electric power supplied. The real-time analysis of the curve of the torque supplied by the engine during the operations of opening and closing will make possible for an indirect monitoring of the position of the main contacts of the high power switch, increasing the trustworthiness of the electrical system operation. The information supplied by the detection system of malfunction will allow a more efficient preventive maintenance of the switches, based on the indication of misaligned or broken components in the mechanical system of power switch.

KEYWORDS

Intelligent Systems, Power Substation, Power Equipment.

INTRODUÇÃO

Chaves seccionadoras são extremamente importantes e largamente utilizadas nas redes de distribuição de energia. Elas têm o papel de energizar ou não barramentos, ramos, linhas de transmissão, ou subestações. Para a manutenção desse equipamento,

muitas vezes se faz necessário o desligamento do ramo, interrompendo assim o fornecimento de energia [1].

A correta manutenção das chaves seccionadoras e o supervisionamento técnico constante se fazem necessários para evitar tal transtorno e possíveis prejuízos.

São conhecidos diversos defeitos em seccionadores de alta tensão, desde falta de alimentação no cubículo de acionamento, falta de lubrificação nas junções, até fechamento incorreto das fases.

Este trabalho visa elaborar um instrumento computacional capaz de determinar a distância o comportamento de uma chave seccionadora, assim como

supervisionar o seu funcionamento e detectar possíveis defeitos. Este instrumento deverá fazer uso de técnicas de processamento digital de sinais e de reconhecimento de padrões para classificar o funcionamento da chave seccionadora.

CHAVE SECCIONADORA UTILIZADA

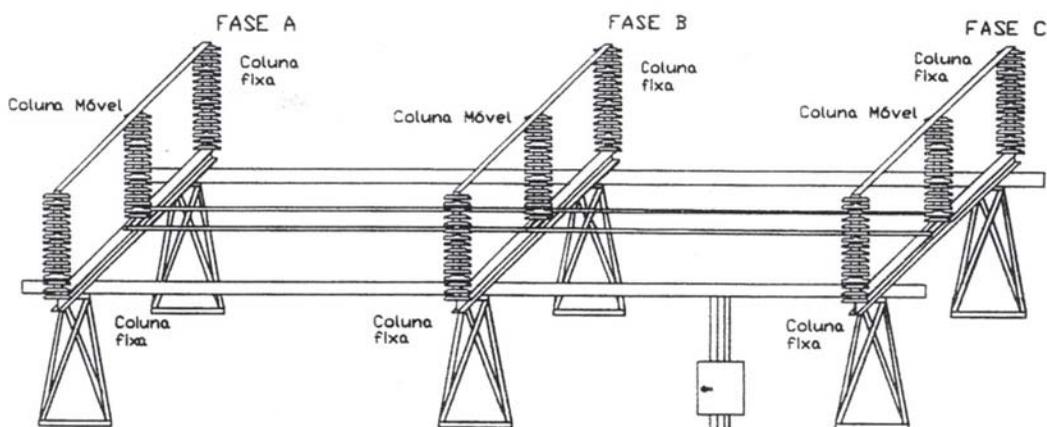
A chave seccionadora estudada é mostrada na Figura 1 e possui as seguintes características:

- Fabricante: Bowthorpe Power Equipment – Banbury – England
- Modelo: R500
- Tensão Nominal: 345 KV / 60 Hz
- Corrente Nominal: 1250 A

A Figura 2 apresenta um esquemático da chave



Figura 1 – A chave seccionadora estudada



Cubículo de acionamento

Figura 2 – Visão geral da chave seccionadora

DESENVOLVIMENTO DO SISTEMA

ETAPAS DO SISTEMA

A análise em tempo real da curva do torque fornecida pelo motor durante as operações de abertura e fechamento possibilitará um monitoramento indireto da posição dos contatos principais do seccionador, aumentando a confiabilidade de opera-

ção do sistema elétrico. As informações fornecidas pelo sistema de detecção de falhas permitirão uma mais eficiente manutenção preditiva dos seccionadores, baseada nas indicações de desajustes ou quebras de componentes no sistema mecânico de acionamento e parte ativa da chave. As etapas a serem cumpridas neste estudo são ilustradas na Figura 3.

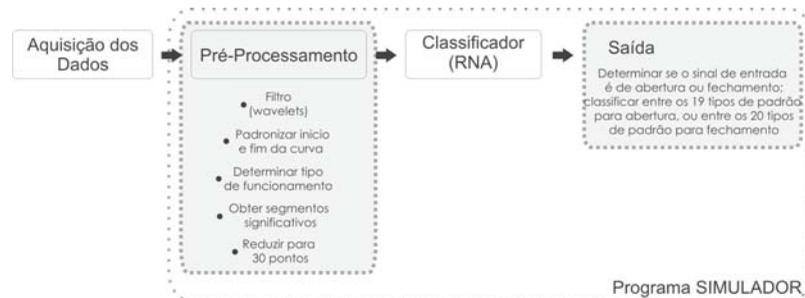


Figura 3 – Etapas do sistema projetado

FASE DE AQUISIÇÃO

As curvas obtidas na fase de aquisição dos dados formaram um banco de dados inicial com 165 curvas, entre as manobras de abertura e fechamento da chave. Cada curva obtida possui cerca de 20.000 pontos e uma taxa de amostragem de 0.5 ms (milissegundos). As curvas obtidas nos ensaios foram separadas de acordo com o tipo de teste realizado. Para abertura, foram

ensaiados 18 tipos de defeitos, adquirindo-se 3 curvas em cada teste, e 27 curvas para o funcionamento normal. Para fechamento da chave, 19 tipos de defeitos foram ensaiados, adquirindo-se 3 curvas em cada teste e 27 curvas para o funcionamento normal. A Figura 4 abaixo ilustra as curvas obtidas na fase de aquisição dos dados.

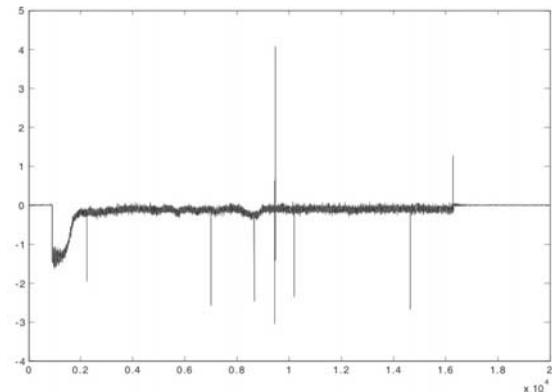
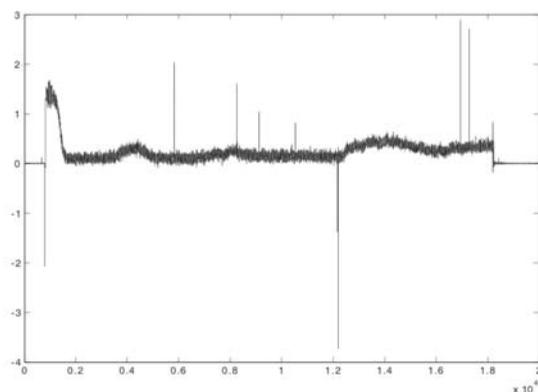


Figura 4 – Curvas de fechamento e abertura, respectivamente, sem pré-processamento

O pré-processamento projetado foi subdividido, e tem o intuito de otimizar o funcionamento do classificador [2, 3]. A Figura 5 apresenta as etapas do pré-processamento.

Assim, o pré-processamento deverá, respectivamente: eliminar os ruídos presentes; padronizar o iní-

cio e o final de cada curva; determinar se a curva é de abertura ou de fechamento; obter os segmentos significativos de cada curva (diferentes para abertura e fechamento); e reduzir os segmentos para 30 pontos.

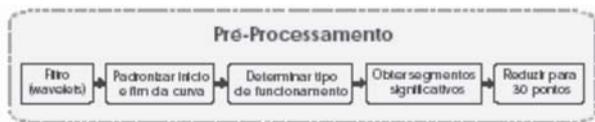


Figura 5 – Etapas do pré-processamento

ELIMINANDO OS RUÍDOS

Para eliminar os ruídos presentes, utilizou-se a análise de wavelets como um filtro [4, 5], conforme demonstrado no item anterior. Os resultados podem ser observados na Figura 6.

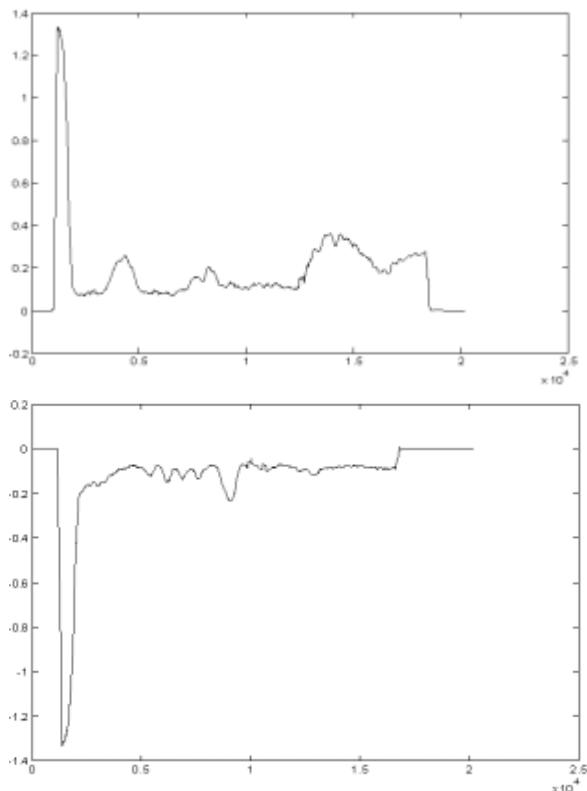


Figura 6 – Curvas de fechamento e abertura pós-análise de wavelets

PADRONIZANDO AS CURVAS

A padronização do início e do final de cada curva se faz necessário para obtermos uma referência de início e fim de cada evento.

Determinou-se o início do evento no primeiro ponto mais próximo (em módulo) de 0,05.

O final de cada evento se dará no ponto 18.000 subsequente ao início do evento. Ou seja, cada curva terá 18.000 pontos.

As Figuras 7 ilustram os resultados obtidos:

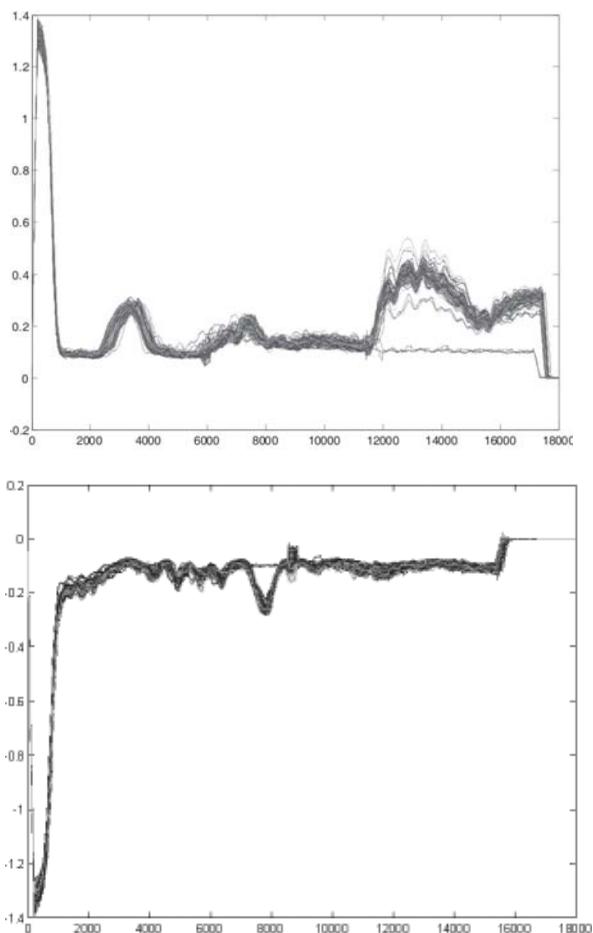


Figura 7 – Curvas de fechamento e abertura padronizadas

DETERMINANDO O TIPO DE FUNCIONAMENTO

Como o movimento das manobras é oposto (abertura e fechamento da chave seccionadora), os dados coletados também os são.

De acordo com o banco de dados utilizados, as curvas que possuem valores positivos são de fechamento, e as curvas que possuem valores negativos são curvas de abertura. Este conceito foi utilizado para determinar se o evento é de fechamento ou de abertura da chave seccionadora. A Figura 8 apresenta estas curvas.

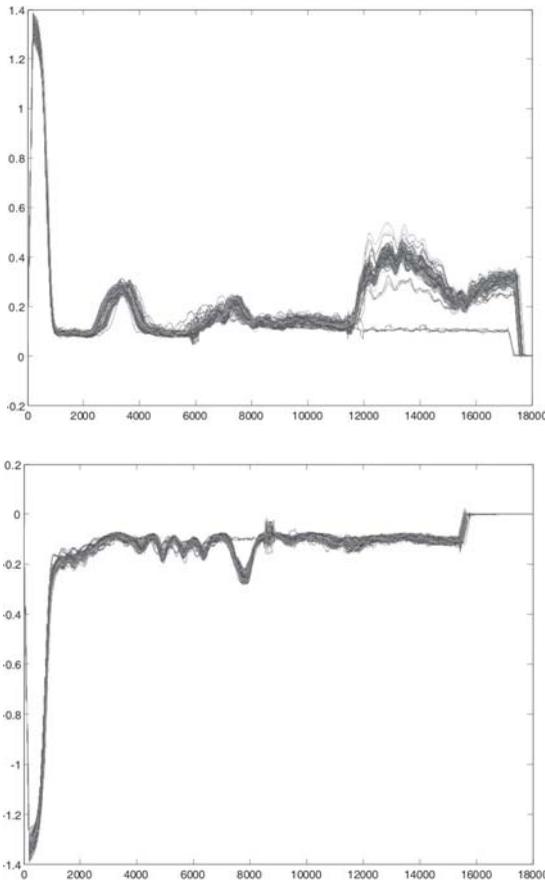


Figura 8 – Curvas de fechamento (valores positivos) e abertura (valores negativos)

Para simplificar a visualização das curvas a partir deste ponto, todas as curvas de abertura serão convertidas para valores em módulo, pois a informação contida em sua natureza já foi extraída.

OBTENDO OS SEGMENTOS SIGNIFICATIVOS

Pela análise gráfica, observa-se que muitos pontos são comuns a todas as curvas, tanto para fechamento quanto para abertura da chave. O intuito dessa fase será obter os segmentos mais significativos em cada tipo de curva (abertura ou fechamento), para aumentar a precisão do classificador.

A escolha será feita somente em regiões que o padrão de cada teste seja válido, ou seja, que exista um padrão para cada tipo de teste. Isso se faz necessário, pois há possibilidade de se encontrar regiões que embora contenham valores diferentes em cada tipo de teste, não existe lógica ou não são parecidos para testes idênticos.

Para as curvas de fechamento da chave, o segmento significativo foi extraído dos pontos 12.001 até o ponto 17.500, enquanto para as curvas de abertura da chave, o primeiro segmento significativo foi extraído do ponto 1.001 até o ponto 2.000, e o segundo do ponto 4.000 até 8.500, conforme ilustra a Figura 9.

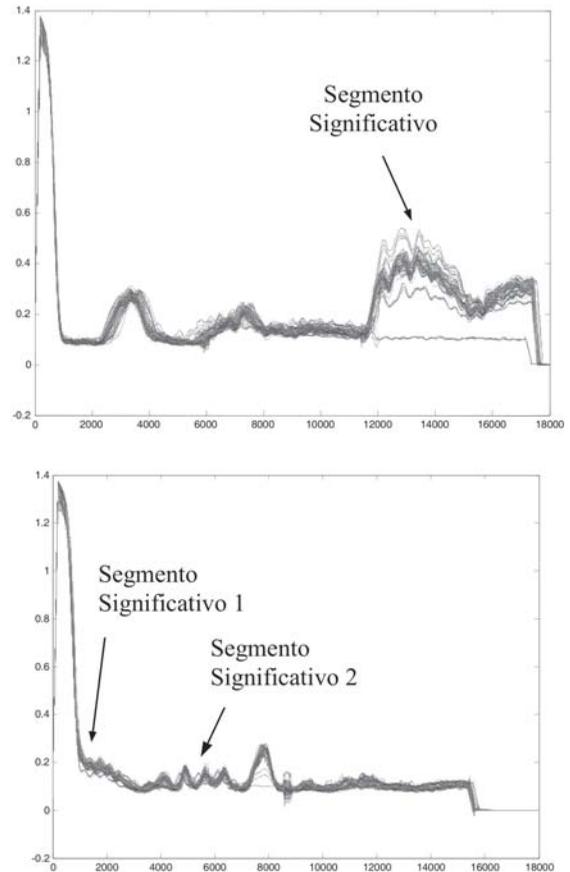


Figura 9 – Segmento significativo para as curvas de fechamento e abertura

Assim, as curvas que inicialmente tinham cerca de 20.000 pontos, foram resumidas em 5.500 pontos (ditos significativos), como mostrado na Figura 10.

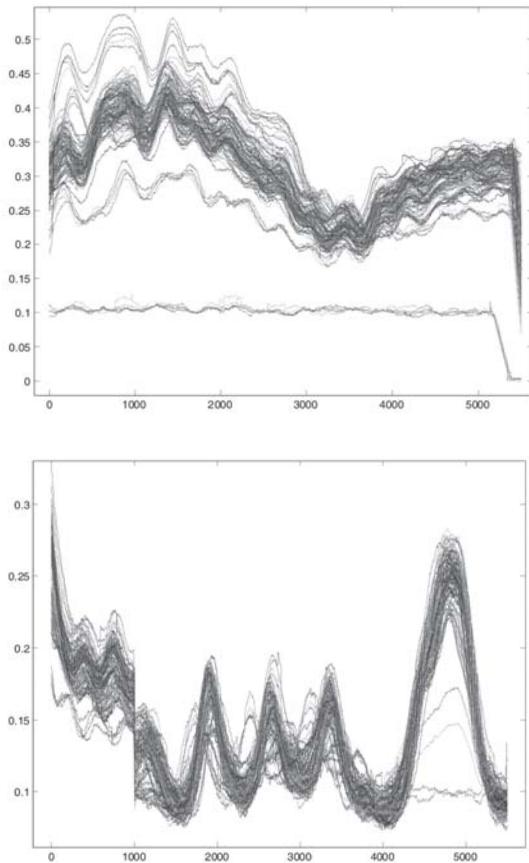


Figura 10 – Segmento significativo de fechamento e abertura, 5.500 pontos

REDUZINDO OS SEGMENTOS SIGNIFICATIVOS

De acordo com o propósito deste trabalho, o classificador a ser utilizado será uma Rede Neural Artificial (RNA) e, a priori, foi definido que a entrada da rede seria composta de 30 neurônios. Então, devem-se reduzir os segmentos significativos para 30 pontos. Os novos pontos foram obtidos através da média aritmética de 21 pontos a cada intervalo de 185 pontos do segmento significativo. A Figura 11 ilustra os resultados.

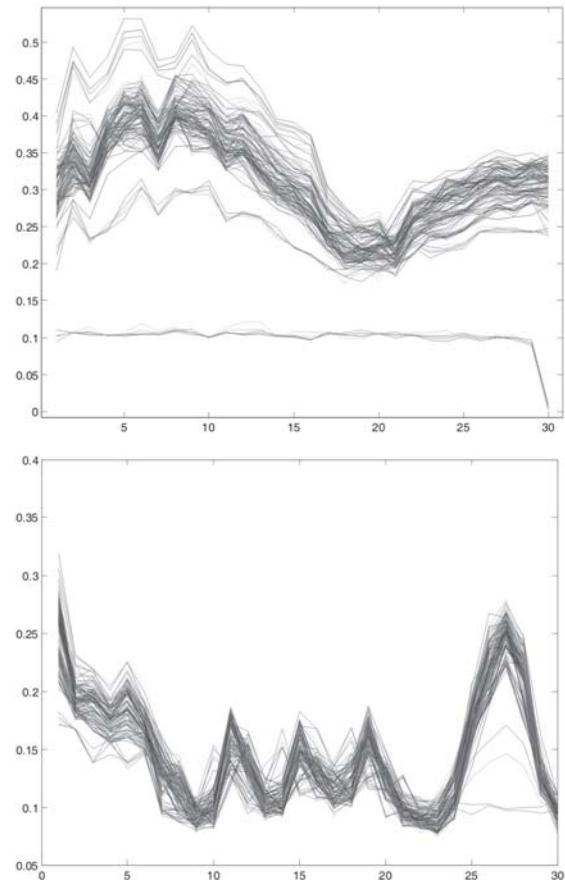


Figura 11 – Curvas de fechamento e abertura, reduzidas a 30 pontos

FASE DE TREINAMENTO

Na a fase de treinamento das redes o banco de dados inicial foi aumentado, criando-se 2 curvas para os testes com apenas 3 curvas, da seguinte maneira: curva1- validação; curva2 – treinamento; curva3 – treinamento; curva4 – média aritmética entre as curvas 2 e 3, treinamento; curva5 – média aritmética entre as curvas 1, 2 e 3, treinamento. Para as curvas de funcionamento normal foram utilizadas 5 curvas para validação e as 22 restantes, no treinamento.

A rede projetada para classificar as curvas de abertura da chave seccionadora possui 3 camadas, sendo que a primeira possui 30 neurônios, 25 na camada oculta e 18 na última camada – rede 30/25/18. Para a rede de fechamento, a primeira camada possui 30 neurônios, a segunda, 25 e a última, 19 – rede 30/25/19.

As redes foram treinadas para que cada neurônio de saída representasse um tipo de defeito, ou seja, se

a curva inserida na rede representar um defeito do tipo 1, o neurônio 1 na saída da rede deve ser ativado (+1) enquanto os demais devem permanecer não-ativados (-1). Se a curva inserida na entrada da rede representar funcionamento normal da chave, todos

os neurônios de saída devem permanecer não-ativados (-1). Para o treinamento da rede utilizou-se o algoritmo *back-propagation*, e, em todas as camadas, a função de ativação utilizada foi a TANSIG. As redes projetadas são ilustradas na Figura 12.

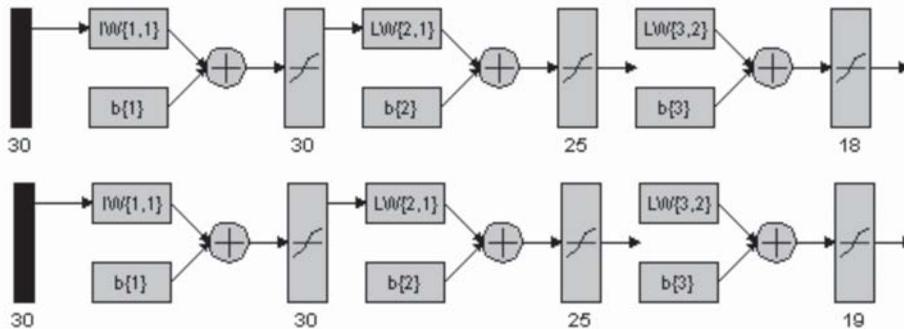


Figura 12 – Redes de abertura e fechamento, respectivamente

RESULTADOS E DISCUSSÃO

Após 200 épocas de treinamento, as redes convergiram para erros de aderência na ordem de 10^{-7} . Os resultados obtidos na validação das redes estão nas tabelas abaixo:

Tabela 1 – Resultados obtidos na validação das redes

		ABERTURA DA CHAVE																					
		Curvas Reais Utilizadas: Tipo de Curva																					
		N	N	N	N	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
Saídas da Rede : Neurônio	1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	2	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	3	-1	-1	-1	-1	-1	0.9	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	4	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	5	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	6	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	7	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	8	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	9	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	0.7	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	10	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	11	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	12	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
	13	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1
	14	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1
	15	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1
	16	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1
	17	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1
	18	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1

		FECHAMENTO DA CHAVE																						
		Curvas Reais Utilizadas: Tipo de Curva																						
		N	N	N	N	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
Saídas da Rede: Neurônios	1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	2	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	3	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	4	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	5	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	6	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	7	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	8	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	9	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	10	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
	11	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
	12	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
	13	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1
	14	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1
	15	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1
	16	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1
	17	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1
	18	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1
	19	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1

Conforme tabela acima, as redes foram validadas. A partir dos pesos obtidos, foi desenvolvido o programa

ma SIMULADOR capaz de realizar todos os cálculos contidos no pré-processamento e no classificador (RNA) de forma a facilitar os procedimentos do usuário. O programa desenvolvido em linguagem C, realiza a coleta dos dados nos arquivos indicados e retorna o resultado da classificação. Todos os dados e cálculos foram manipulados no ambiente MATLAB.R13.

CONCLUSÕES

Observou-se nos testes de validação das redes, erros de pequena ordem devido a mudanças no perfil das curvas de validação. Concluímos que o sistema projetado para classificar os padrões nas manobras de abertura e fechamento da chave seccionadora foi validado. Para trabalhos futuros, planeja-se a ampliação do banco de dados, possíveis mudanças na estrutura da rede e utilização de variáveis climáticas para aumentar a eficiência do sistema.

REFERÊNCIAS

SILVA, A.P. Alves da; INSFAN A.H.S.; LAMBERT-TORRES, G. Alarm Processing based on Associative Neural Memories with explanation capability. *Journal on Engineering Intelligent Systems*, Vol. 7, No.2, pp. 109-115, 1999.

FARAG, W.A.; QUINTANA, V. H.; LAMBERT-TORRES, G. A Genetic-Based Neuro-Fuzzy approach for modeling and control of dynamical systems”, *IEEE Trans. on Neural Networks*, Vol. 9, No. 5, pp. 756-767, September 1998.

NEIBUR, D, et al. Artificial Neural Networks for Power Systems: state of the art. Neural networks applications in power Systems,p. 37-110, 1996.

HAYKIN, S. Redes Neurais: princípios e práticas. [S.l]: Bookman, 2001.

LOONEY, C.G. Pattern Recognition Using Neural Networks: theory and algorithms for engineers and scientists: Oxford University Press, 1997.