

# REDES NEURAIS ARTIFICIAIS APLICADAS À CLASSIFICAÇÃO RÁPIDA DE FALTAS EM SISTEMAS ELÉTRICOS DE POTÊNCIA

M. Oleskovicz<sup>1</sup>

D. V. Coury<sup>2</sup>

R. K. Aggarwal<sup>3</sup>

<sup>1,2</sup>Dept<sup>o</sup> de Engenharia Elétrica  
Universidade de São Paulo  
Av. Dr. Carlos de Botelho, 1465

São Carlos (SP) - Brasil

<sup>1</sup>olesk@sel.eesc.sc.usp.br

<sup>2</sup>coury@sel.eesc.sc.usp.br

<sup>3</sup>School of Electronic and  
Electrical Engineering

University of Bath

Bath – BA2 7AY – UK

R.K.Aggarwal@bath.ac.uk

**Resumo** Este trabalho traz a aplicação de Redes Neurais Artificiais (RNAs) no reconhecimento de padrões para a classificação de faltas em um sistema de transmissão. A rede neural implementada, através da aplicação do *software NeuralWorks*, deve capturar o conhecimento das situações de faltas envolvidas frente às distintas situações de operação do sistema. A arquitetura de RNA emprega os valores amostrados das tensões e correntes trifásicas pós-falta tanto para o processo de treinamento como para o de testes. O *software ATP (Alternative Transient Program)* é utilizado para gerar os dados referentes à linha de transmissão (440 KV) em condições de falta para ambos os processos (treinamento e teste). Os resultados obtidos mostram que o desempenho global da arquitetura de RNA implementada é altamente satisfatório para a classificação de situações faltosas em um sistema de transmissão. De todos os casos considerados na fase de teste, as saídas apresentadas pela arquitetura mostram uma convergência rápida para os níveis requeridos após a ocorrência da falta.

**Palavras Chaves:** Sistemas Elétricos de Potência, Classificação de Faltas, Redes Neurais Artificiais (RNAs).

**Abstract:** This paper presents a neural network approach to fault classification for transmission line protection. The neural network was implemented using *NeuralWorks* software. The Artificial Neural Network (ANN) must acquire knowledge for the correct fault classification, facing different network conditions. For this approach the three phase voltage and current post-fault values were utilized as inputs, for training and test purposes. The *Alternative Transients Program (ATP)* software was used to generate data for the transmission line (440 kV) in a faulted condition. The results obtained showed that the global performance of the ANN architecture is highly satisfactory for fault classification. Considering all the studied cases, the ANN outputs converged to the correct levels very rapidly after fault occurrence.

**Keywords:** Electric Power Systems, Fault Classification, Artificial Neural Networks (ANNs).

## 1 INTRODUÇÃO

A proteção de sistemas de energia é projetada para salvar os equipamentos do sistema tais como geradores, transformadores, cabos e, além disso, manter a integridade que é necessária para o fornecimento contínuo e econômico da energia elétrica. Se sobre determinado componente ocorrer uma situação de falta, este deve ser isolado tão rapidamente quanto possível do resto do sistema, preservando assim a estabilidade do mesmo. Para a proteção de linhas de transmissão, utilizam-se convencionalmente os valores das tensões e correntes trifásicas registrados para detectar e classificar determinada falta e então enviar um sinal para os circuitos de interrupção que irão desconectar a linha faltosa. Em um sistema interconectado, o sistema de transmissão restante poderá então operar normalmente ou pelo menos trabalhar o mais próximo possível das condições normais.

Frente às considerações apresentadas para a implementação de um modelo completo de proteção de distância para linhas de transmissão é necessário, como primeiro passo, a **detecção** do defeito, ou seja, da situação de falta. Seguindo a esta, a confirmação e discriminação das fases envolvidas na falta (**classificação** da falta quanto ao tipo) e finalmente a **localização** da mesma no que diz respeito à verificação das zonas de proteção devem ser efetuadas. Assim, após esta seqüência de operações, haverá ou não a atuação dos disjuntores, quando conveniente.

Com os recentes avanços relacionados às técnicas de Inteligência Artificial, especificamente a teoria de Redes Neurais Artificiais (RNAs), encontram-se na literatura diferentes modelos designados à solução de problemas específicos. A teoria de RNAs provê uma alternativa, usando técnicas inteligentes, aos algoritmos tradicionais empregando métodos determinísticos. Dillon & Niebur (1996) apresentam uma avaliação geral da aplicação de RNAs em sistemas de potência. Relativo à aplicação no campo da proteção de sistemas, algumas propostas, empregando-se o reconhecimento de padrões à proteção de distância, são encontradas em

Artigo Submetido em 30/04/1999

1a. Revisão em 06/08/1999; 2a. Revisão em 05/01/2000

Aceito sob recomendação do Ed. Consultor Prof. Dr. Jorge Coelho

Khparde *et alii* (1991), Chakravarthy *et alii* (1992), Dalstein *et alii* (1996), Coury & Jorge (1998) e Coury & Oleskovicz (1998). Referentes à detecção de uma situação de falta encontramos as pesquisas desenvolvidas por Kandil *et alii* (1992), Al-Hasawi *et alii* (1997) e Su *et alii* (1997), bem como para a discriminação direcional, os resultados apresentados por Sidhu *et alii* (1995). Para a localização de faltas podemos referenciar Kanoh *et alii* (1991) e Yang *et alii* (1994) e para a classificação de faltas para linhas de transmissão devem finalmente ser citados os trabalhos defendidos por Ghosh & Lubkeman (1995), Dalstein & Kuliche (1995), Kezunovic & Rikato (1996), Aggarwal, *et alii* (1997) e Keerthipala *et alii* (1997).

O presente trabalho visa desenvolver um sistema completo de proteção (detecção, classificação e localização), utilizando-se de RNAs e está sendo desenvolvido por uma interação entre a Universidade de São Paulo (USP) através do Departamento de Engenharia Elétrica da Escola de Engenharia de São Carlos com a Universidade de Bath - Reino Unido. A pesquisa conjunta com uma instituição no exterior tem como principal objetivo a troca de experiências no que diz respeito à aplicação de RNAs em proteção de sistemas elétricos.

Este artigo apresenta resultados encontrados no desenvolvimento do módulo classificador de faltas, inserido no esquema de proteção anteriormente descrito, fazendo-se uso da teoria de RNAs. Como já enfatizado, este módulo é utilizado para a seleção da(s) fase(s) faltosa(s) e é de fundamental importância para os passos seguintes na proteção de linhas de transmissão. Deve ser também enfatizado que a topologia apresentada vem a contribuir não somente com a classificação mais rápida de faltas em sistemas elétricos, mas também apresenta uma topologia de rede mais otimizada, se comparada com as apresentadas na literatura.

## 2 O USO DE RNAS

Através da aplicação de RNAs, propõe-se um método alternativo para a proteção de linhas de transmissão, baseado em modelos que realizem as suas funções em um tempo menor, quando comparados aos dispositivos convencionais e que sejam imunes a mudanças operacionais do sistema. O incentivo para a aplicação de tal ferramenta vem da possibilidade de classificarmos a atuação de um sistema de proteção, como um problema de reconhecimento de padrões. Trabalhando com a identificação e classificação da informação em categorias, acredita-se que seja possível **detectar, classificar e localizar** uma situação de falta utilizando-se da capacidade de generalização, abstração e tolerância a faltas, características estas inerentes a um sistema de redes neurais.

Para a aplicação de RNAs ao problema de reconhecimento de padrões, relacionado à classificação de faltas em linhas de transmissão, é indispensável a elaboração de um conjunto de padrões que represente as situações de falta do sistema elétrico analisado, neste caso designado por *conjunto de dados*. Este conjunto de padrões, pode ser utilizado para o *treinamento supervisionado* de RNAs. Salienta-se que a formação deste conjunto deve, da melhor maneira possível, apresentar à rede neural as possíveis situações que a mesma possa encontrar, ou seja, situações representativas que definam claramente os tipos de falta que o sistema em questão está sujeito.

Outro aspecto importante para a análise das principais características inerentes a RNAs é a elaboração de um segundo conjunto de padrões, caracterizando um *conjunto de testes* a ser aplicado sobre a arquitetura de RNA após a fase de

treinamento. Sendo estas situações de faltas pertencentes ao conjunto de testes diferentes das situações utilizadas na fase de treinamento, será possível verificar a capacidade de generalização e adaptação da RNA às operações do sistema elétrico.

Uma vez completo o treinamento, a rede neural será capaz de fornecer as saídas desejadas não somente para entradas conhecidas, mas também a resposta mais plausível para qualquer entrada relacionada aos padrões treinados. Esta característica denota a capacidade de *generalização* da rede a partir de exemplos conhecidos, desde que estes sejam representativos. Dentre outras características, além da aprendizagem a partir de exemplos, a arquitetura da rede neural deve também apresentar a capacidade de *abstração* de características essenciais das entradas que contêm dados redundantes e ou irrelevantes. As redes neurais exibem ainda *tolerância a faltas*, uma vez que a informação é processada por elementos com processamento paralelo e distribuídos. Logo, danos parciais podem não causar mudanças significativas nas respostas da rede (Hertz *et alii*, 1991).

Devido às inúmeras situações aleatórias de faltas no sistema elétrico, o desempenho da rede neural a ser implementada dependerá da escolha de um conjunto representativo de treinamento e teste.

O *software NeuralWorks* (NeuralWorks Professional II/PLUS, 1998) foi empregado para implementar a topologia de RNA, treinando-a com o objetivo de se obter uma matriz de pesos fixa que descreva todas as informações de operações presentes no sistema de transmissão. O *software* provê um ambiente flexível para a aplicação das técnicas que envolvem a teoria de RNAs.

## 3 O SISTEMA DE POTÊNCIA ANALISADO

Com relação ao sistema elétrico em condição faltosa, dispõe-se de simulações utilizando o *software ATP - Alternative Transient Program* (ALTERNATIVE Transients Program, 1987) para obtenção do conjunto de dados. Por meio destas simulações busca-se uma aproximação às situações e características encontradas na prática. Com o uso de ferramentas destinadas às simulações, viabiliza-se a obtenção de dados próximos aos reais, já que estes, por condições técnicas ou financeiras, não estão disponíveis de imediato. Deve ser mencionado que, embora a técnica descrita seja baseada em simulações computacionais, considerações práticas como o transformador de potencial capacitivo, filtro *anti-aliasing* e erros de quantização da conversão analógica/digital também foram incluídas. A técnica também considera o arranjo físico e características dos condutores, acoplamento mútuo e linhas transpostas.

Como já comentado, este trabalho apresenta, em específico, um modelo de RNA implementado para a classificação das possíveis situações de faltas que um sistema de proteção possa a vir detectar. Para este esquema foram utilizados como valores de entradas para as arquiteturas de RNA analisadas, as tensões e correntes trifásicas pós-falta das situações analisadas. O *software ATP* é utilizado para gerar os dados da linha de transmissão (440 KV) nas condições de falta com a finalidade de treinar e testar o esquema proposto.

A topologia do sistema em questão é apresentada na figura 1.

No trabalho, consideram-se as características dos condutores e suas respectivas disposições geométricas nas torres de

transmissão. A estrutura da linha de transmissão de 440 KV (figura 2) corresponde a uma linha típica da CESP (Companhia Energética de São Paulo), empregada entre as cidades de Araraquara – Bauru e Jupia – Ilha Solteira.




Figura 1. Sistema de energia analisado

As simulações são realizadas sobre um sistema de transmissão real tendo como variáveis:

- a distância em quilômetros de aplicação da falta, em relação a um determinado barramento;
- a resistência de falta;
- o ângulo de incidência da falta;
- o tipo de falta considerada e
- a condição de operação do sistema elétrico.




Figura 2 - Estrutura da linha de transmissão (440 KV)

Outro importante apontamento refere-se ao ângulo de incidência da falta, onde, segundo Warrington (1968), este ocorre entre os  $40^\circ$  que antecedem o valor máximo de tensão. Para maior esclarecimento apresenta-se na figura 3 o comportamento da forma de onda de tensão e corrente sobre um sistema elétrico, para uma falta aplicada com um ângulo de incidência de  $90^\circ$ .

A tabela 1 mostra as localizações das faltas, resistências e ângulos de incidência das faltas utilizadas para compor os conjuntos de treinamento e teste. As informações referentes às condições de operação do sistema são representadas através de 138 diferentes situações para cada tipo de falta, obtidas pela combinação das variáveis anteriormente comentadas e mostradas na tabela 1. Este estudo considera faltas ocorridas entre fase-terra, fase-fase, fase-fase-terra e faltas trifásicas. Um total de 1380 diferentes situações de faltas em várias localizações do sistema foram consideradas para formar o

conjunto de dados. O conjunto de teste foi formado através de 840 diferentes situações de faltas (84 situações para cada tipo de falta).




Figura 3- Forma de onda da tensão e corrente, para uma falta fase-terra, com um ângulo de incidência de  $90^\circ$

Deve ser ressaltado que, nesta fase do trabalho foi escolhido um intervalo de resistência de faltas entre 0 e 100 para o treinamento da rede, o que não inclui faltas de alta impedância. Em uma segunda fase do trabalho, valores maiores de resistência de falta (até 500 ) tem sido introduzidos no treinamento, e resultados preliminares já mostram um alto grau de discernimento da rede também para estes casos.

Tabela 1 - Conjuntos de dados e teste utilizados

	Conjunto de dados	Teste
número de situações de faltas	6900 treinamento: 5520 validação: 1380	4200
localizações (km)	barramento DE 6 10 25 40 55 70 74	barramento DE 15 30 45 60
	barramento EF 86 100 125 150 175 200 220 224	barramento EF 90 115 140 165 190 215
	barramento FG 236 240 255 270 285 300 315 324	barramento FG 240 265 290 315
resistência de falta ( $\Omega$ ): fase-terra fase-fase	0,1 50,0 100,0 0,1 0,5 1,0	30,0 60,0 90,0 0,3 0,6 0,9
ângulo de inepção ( $^\circ$ )	0 90	30 60

Neste trabalho, o conjunto de dados é subdividido em um conjunto de treinamento e em um conjunto de validação. Este último é usado para avaliar a RNA durante a fase de treinamento; este procedimento é necessário para se evitar o sobre-treinamento da RNA. Nesta situação, o processo de treinamento deve ser interrompido quando se alcançar o menor erro (*Root Mean Square Error - RMS*) para o conjunto de

validação ainda na fase de treinamento. O tamanho do conjunto de treinamento e de validação corresponde a 80% e 20% de todos os exemplos do conjunto de dados respectivamente. Nos conjuntos de treinamento e validação utilizados, as condições de faltas apresentadas à RNA foram dispostas no arquivo de maneira aleatória.

Para esta aplicação, as tensões e correntes trifásicas pós-falta com relação ao barramento E (figura 1) foram tomadas a uma frequência amostral de 1 kHz (sendo a frequência do sistema de 60 Hz). Cinco janelas de dados com quatro amostras cada foram consideradas. Fixou-se as segundas amostras de tensões e correntes pós-faltas como sendo os valores iniciais a serem considerados na primeira janela de dados. A figura 4 mostra as cinco janelas de dados consideradas para uma condição de falta. Nesta figura também é ilustrado o movimento dos dados nas janelas subsequentes, onde há a troca das amostras consideradas. A janela 1 contém quatro amostras das tensões pós-falta (VA<sub>2</sub>, VA<sub>3</sub>, VA<sub>4</sub>, VA<sub>5</sub>, VB<sub>2</sub>, VB<sub>3</sub>, VB<sub>4</sub>, VB<sub>5</sub>, VC<sub>2</sub>, VC<sub>3</sub>, VC<sub>4</sub> e VC<sub>5</sub>). Também estão inclusas nesta janela as quatro amostras relativas às correntes pós-falta (IA<sub>2</sub>, IA<sub>3</sub>, IA<sub>4</sub>, IA<sub>5</sub>, IB<sub>2</sub>, IB<sub>3</sub>, IB<sub>4</sub>, IB<sub>5</sub>, IC<sub>2</sub>, IC<sub>3</sub>, IC<sub>4</sub> e IC<sub>5</sub>) com a respectiva resposta esperada por parte da rede neural para uma situação de falta ao longo da linha transmissão (S<sub>1</sub>, S<sub>2</sub>, S<sub>3</sub> e S<sub>4</sub>). Para uma situação que caracterize uma falta fase A – terra, relacionam-se as respostas S<sub>1</sub> = 1, S<sub>4</sub> = 1 com S<sub>2</sub> e S<sub>3</sub> = 0.

Primeira janela	VA <sub>2</sub>	VA <sub>3</sub>	VA <sub>4</sub>	VA <sub>5</sub>					
	VB <sub>2</sub>	VB <sub>3</sub>	VB <sub>4</sub>	VB <sub>5</sub>					
	VC <sub>2</sub>	VC <sub>3</sub>	VC <sub>4</sub>	VC <sub>5</sub>					
	IA <sub>2</sub>	IA <sub>3</sub>	IA <sub>4</sub>	IA <sub>5</sub>					
	IB <sub>2</sub>	IB <sub>3</sub>	IB <sub>4</sub>	IB <sub>5</sub>					
	IC <sub>2</sub>	IC <sub>3</sub>	IC <sub>4</sub>	IC <sub>5</sub>	S <sub>1</sub>	S <sub>2</sub>	S <sub>3</sub>	S <sub>4</sub>	
Segunda janela	VA <sub>3</sub>	VA <sub>4</sub>	VA <sub>5</sub>	VA <sub>6</sub>					
	VB <sub>3</sub>	VB <sub>4</sub>	VB <sub>5</sub>	VB <sub>6</sub>					
	VC <sub>3</sub>	VC <sub>4</sub>	VC <sub>5</sub>	VC <sub>6</sub>					
	IA <sub>3</sub>	IA <sub>4</sub>	IA <sub>5</sub>	IA <sub>6</sub>					
	IB <sub>3</sub>	IB <sub>4</sub>	IB <sub>5</sub>	IB <sub>6</sub>					
	IC <sub>3</sub>	IC <sub>4</sub>	IC <sub>5</sub>	IC <sub>6</sub>	S <sub>1</sub>	S <sub>2</sub>	S <sub>3</sub>	S <sub>4</sub>	
Terceira janela	VA <sub>4</sub>	VA <sub>5</sub>	VA <sub>6</sub>	VA <sub>7</sub>					
	VB <sub>4</sub>	VB <sub>5</sub>	VB <sub>6</sub>	VB <sub>7</sub>					
	VC <sub>4</sub>	VC <sub>5</sub>	VC <sub>6</sub>	VC <sub>7</sub>					
	IA <sub>4</sub>	IA <sub>5</sub>	IA <sub>6</sub>	IA <sub>7</sub>					
	IB <sub>4</sub>	IB <sub>5</sub>	IB <sub>6</sub>	IB <sub>7</sub>					
	IC <sub>4</sub>	IC <sub>5</sub>	IC <sub>6</sub>	IC <sub>7</sub>	S <sub>1</sub>	S <sub>2</sub>	S <sub>3</sub>	S <sub>4</sub>	
Quarta janela	VA <sub>5</sub>	VA <sub>6</sub>	VA <sub>7</sub>	VA <sub>8</sub>					
	VB <sub>5</sub>	VB <sub>6</sub>	VB <sub>7</sub>	VB <sub>8</sub>					
	VC <sub>5</sub>	VC <sub>6</sub>	VC <sub>7</sub>	VC <sub>8</sub>					
	IA <sub>5</sub>	IA <sub>6</sub>	IA <sub>7</sub>	IA <sub>8</sub>					
	IB <sub>5</sub>	IB <sub>6</sub>	IB <sub>7</sub>	IB <sub>8</sub>					
	IC <sub>5</sub>	IC <sub>6</sub>	IC <sub>7</sub>	IC <sub>8</sub>	S <sub>1</sub>	S <sub>2</sub>	S <sub>3</sub>	S <sub>4</sub>	
Quinta Janela	VA <sub>6</sub>	VA <sub>7</sub>	VA <sub>8</sub>	VA <sub>9</sub>					
	VB <sub>6</sub>	VB <sub>7</sub>	VB <sub>8</sub>	VB <sub>9</sub>					
	VC <sub>6</sub>	VC <sub>7</sub>	VC <sub>8</sub>	VC <sub>9</sub>					
	IA <sub>6</sub>	IA <sub>7</sub>	IA <sub>8</sub>	IA <sub>9</sub>					
	IB <sub>6</sub>	IB <sub>7</sub>	IB <sub>8</sub>	IB <sub>9</sub>					
	IC <sub>6</sub>	IC <sub>7</sub>	IC <sub>8</sub>	IC <sub>9</sub>	S <sub>1</sub>	S <sub>2</sub>	S <sub>3</sub>	S <sub>4</sub>	

Figura 4 - Janelas de dados

Como ilustrado, cinco janelas de dados representam cada condição de falta. Assim, o conjunto de dados é formado através de 6900 situações (1380 situações de faltas x 5 janelas de dados).

A tabela 2 mostra as respostas esperadas por parte da arquitetura de RNA relacionadas às fases A (S<sub>1</sub>), B (S<sub>2</sub>) e C

(S<sub>3</sub>) e a conexão a terra (S<sub>4</sub>) para todas as condições de faltas consideradas. Para aplicações práticas, o intervalo dos valores de 0-0,2 podem ser considerados como uma resposta por parte da RNA igual a 0 (zero) e os valores compreendidos entre 0,8-1 como uma resposta igual a 1 (um). Os outros valores podem ser considerados como casos incertos.

Tabela 2 - Respostas esperadas por parte da RNA

Situações De faltas	Respostas esperadas			
	S <sub>1</sub> Fase A	S <sub>2</sub> Fase B	S <sub>3</sub> Fase C	S <sub>4</sub> Terra
Fase A – Terra	1	0	0	1
Fase B – Terra	0	1	0	1
Fase C – Terra	0	0	1	1
Fase AB	1	1	0	0
Fase AC	1	0	1	0
Fase BC	0	1	1	0
Fase AB – Terra	1	1	0	1
Fase AC – Terra	1	0	1	1
Fase BC – Terra	0	1	1	1
Fase ABC	1	1	1	0


## 4 IMPLEMENTAÇÃO DO MÉTODO

O software *NeuralWorks* foi usado para implementar e treinar a topologia de RNA, para se obter os pesos apropriados que caracterizem as informações contidas no conjunto de dados.

Como já comentado, utilizou-se dos valores pós-falta das tensões e correntes trifásicas amostrados a 1 kHz dispostos através de cinco janelas de dados. Como resposta, a arquitetura de RNA implementada deve apresentar valores iguais ou próximos a um (1) ou zero (0), mostrando se a falta envolveu as fases A (S<sub>1</sub>), B (S<sub>2</sub>) e C (S<sub>3</sub>) ou não. A saída (S<sub>4</sub>) foi designada para indicar se a falta envolveu uma conexão a terra. Diferentes topologias de redes neurais MLP (Multi Layer Perceptron) foram avaliadas, buscando-se de maneira empírica a que melhor representasse o problema de classificação em questão. Por motivo de brevidade, somente será mostrada a arquitetura que apresentou melhor desempenho. Esta refere-se a uma rede neural que apresenta 24 unidades de processamento na camada de entrada, 16 unidades na camada escondida e uma camada de saída com apenas 4 unidades de processamento (figura 5).

Utilizou-se do algoritmo supervisionado "*Norm-Cum-Delta Learning Rule*", uma variação do algoritmo *backpropagation*, o qual é imune às alterações do tamanho da época (número de padrões aleatórios pertencentes ao conjunto de treinamento apresentados à arquitetura a cada iteração). Como uma alternativa para a função de transferência sigmoideal, a função de transferência tangente hiperbólica foi utilizada. A função de transferência tangente hiperbólica é muito similar à função sigmoideal em sua forma. Contudo a faixa dos seus valores de saída compreendem os valores de -1 a 1, contrária à faixa da função sigmoideal que é de 0 a 1. Observa-se, no entanto, que os valores de saída da função de transferência são usados como um multiplicador na equação de atualização dos pesos (algoritmo de treinamento *backpropagation* – Hertz, 1991). Em virtude desta questão, uma faixa de valores de 0 a 1 significa um multiplicador pequeno, quando a soma total dos valores a serem considerados em um determinado elemento de processamento possui um valor pequeno, ou, um alto multiplicador para valores elevados dessa soma. Desta análise pode-se induzir a rede neural a uma predisposição em aprender somente as saídas desejadas com valores altos (aproximados a 1) já que, as alterações nos pesos seriam maiores para valores

altos da soma (NeuralWorks - Reference Guide, 1998 ). No caso da função tangente hiperbólica, a mesma induz a uma distribuição dos pesos que favoreça tanto os valores baixos da soma a ser considerada pelo elemento, como também para os valores altos.



**Figura 5 - Arquitetura da RNA implementada**

Além de escalonar os valores das variáveis, o *software* faz uma normalização de todos os valores do conjunto de dados para que os mesmos permaneçam entre  $-1,0$  e  $1,0$ . Um ponto importante destas considerações, no uso dos valores base para a normalização das entradas, é que os mesmos valores que foram usados durante a fase de treinamento são também utilizados para a fase de teste.

O processo de treinamento alcançou um erro (RMS) de validação mínimo de 0.10 para todas as unidades na camada de saída, executado em um Pentium PC (350 MHz). Durante a fase de treinamento, utilizaram-se valores de taxas de aprendizagem distintas para as unidades da camada intermediária e de saída compreendidas entre 0,4 a 0,01 com valores de momento situados entre 0,2 a 0,001. O tempo aproximado da fase de treinamento corresponde a 24h. Salienta-se que esse tempo de 24h é devido, em grande parte, à realização do procedimento de *validação*, necessário para se evitar o sobre-treinamento da RNA. Para esta situação, o processo de treinamento é interrompido a cada determinado número de épocas, calculando-se o erro (RMS) para o conjunto de validação. Se este erro atual for menor do que o erro encontrado para os ciclos anteriores, as alterações na configuração da RNA são armazenadas, seguindo-se este procedimento até se atingir um valor mínimo do erro (RMS) para a fase de treinamento. Repetindo-se o mesmo treinamento, sem aplicação do teste de validação, o mesmo é executado em poucas horas. Os pesos da arquitetura, após a convergência, foram então armazenados, uma vez que o critério evitando-se o sobre-treinamento (menor erro para o conjunto de validação) foi respeitado.

Procurou-se obter, através do exposto, uma arquitetura de RNA que apresentasse um índice satisfatório para a classificação correta entre os dez tipos de faltas consideradas. De posse de tal arquitetura, com a sua matriz de pesos fixa, o próximo passo diz respeito à implementação de um algoritmo lógico computacional que venha a repetir ou melhorar os índices alcançados. Por este algoritmo, podemos, para cada janela de dados apresentada à RNA, computar as suas respostas, tomando-se uma decisão da correta classificação ou não, em função do número de respostas repetidas apresentadas pela RNA que descrevem a situação de falta experimentada. Como se consideraram cinco janelas de dados para representar cada situação de falta, a rede apresentou algumas das vezes, um erro de classificação nas cinco janelas. Em outros casos, três acertos e dois erros para cada conjunto de cinco janelas. Analisando-se as respostas apresentadas pela RNA quando da apresentação da 1ª a 5ª janela de dados, podemos computar o número de repetições para cada situação e então concluir sobre o tipo de falta indicado.

Utilizando-se da análise acima descrita, a Tabela 3 mostra a percentagem de respostas corretas da arquitetura empregada sujeita ao conjunto de teste formado por cinco janelas de dados para cada condição de falta. Atente-se ao fato de que os números colocados entre parênteses acima da percentagem de respostas corretas (Tabela 3), referem-se ao número absoluto de erros apresentados pela arquitetura de RNA entre as amostras destinadas a cada janela (84 amostras em cada janela para cada tipo de falta).

Ressalta-se que esta análise mais apurada do índice de acertos da rede foi possível devido a um preciso registro de todas as situações de faltas utilizadas tanto para a fase de treinamento como para a de teste.

Na Tabela 4, observam-se os índices percentuais obtidos para todos os tipos de faltas considerados para todas janelas. Com a quinta janela de dados, dispendo-se de 9ms após a ocorrência da falta, obtém-se um índice de acertos de 99,16% para todos os casos de faltas considerados.

Uma observação prática, segundo Stevenson (1986), nos diz que entre 70% a 80% das faltas nas linhas de transmissão ocorrem entre um só condutor e a terra. Um menor número de faltas refere-se às que envolvem todas as três fases, em torno de 5%. Desta maneira, conforme apresentado na Tabela 3, observa-se que para todos as situações de faltas que envolveram uma fase a terra (fase A – T, fase B – T e fase C – T) a arquitetura de RNA apresentou, considerando-se todas as janelas de dados e a análise das respostas, um índice de acertos próximo a 100% (média entre os índices de acertos dos três tipos possíveis das faltas fase-terra). Índices gerais de acerto bastante elevados também foram encontrados para as demais situações de faltas.


Nas Figuras 6 a 9 observamos as respostas apresentadas pela RNA nas cinco janelas de dados frente os tipos de falta A-T, AB, AB-T e ABC, respectivamente. A situação diz respeito a uma falta aplicada a 6 Km do barramento E (Figura 1), com uma resistência de falta fase – terra e fase – fase de  $0,1 \Omega$  com um ângulo de incidência da falta de  $90^\circ$ . Tais respostas podem ser comparadas com os valores apresentados na Tabela 2. Como pode ser visualizado, a RNA manteve estes valores próximos aos desejados para as situações de faltas apresentadas (Figuras 6 - 9). Atente-se ao fato de que estes padrões do conjunto de teste são completamente diferentes do conjunto de treinamento utilizado, conforme pode ser evidenciado pela Tabela 1 apresentada.

**Tabela 3 – Análise do índice de acertos da RNA frente ao conjunto de teste para as cinco janelas de dados apresentados**

<b>PRIMEIRA JANELA DE DADOS (5ms após a falta)</b>										
<b>Respostas corretas (%)</b>	<b>A-T*</b>	<b>B-T*</b>	<b>C-T*</b>	<b>AB</b>	<b>AC</b>	<b>BC</b>	<b>AB-T*</b>	<b>AC-T*</b>	<b>BC-T*</b>	<b>ABC</b>
	(2)	(1)	(1)	(7)	(17)	(40)	(30)	(0)	(0)	(12)
	97,62	98,81	98,81	91,67	<b>79,76</b>	<b>52,38</b>	<b>64,29</b>	100,00	100,00	<b>86,71</b>
<b>SEGUNDA JANELA DE DADOS (6ms após a falta)</b>										
<b>Respostas Corretas (%)</b>	<b>A-T*</b>	<b>B-T*</b>	<b>C-T*</b>	<b>AB</b>	<b>AC</b>	<b>BC</b>	<b>AB-T*</b>	<b>AC-T*</b>	<b>BC-T*</b>	<b>ABC</b>
	(4)	(1)	(3)	(18)	(20)	(40)	(35)	(0)	(0)	(27)
	95,24	98,81	96,43	<b>78,57</b>	<b>76,19</b>	<b>52,38</b>	<b>58,33</b>	100,00	100,00	<b>67,86</b>
<b>TERCEIRA JANELA DE DADOS (7ms após a falta)</b>										
<b>Respostas corretas (%)</b>	<b>A-T*</b>	<b>B-T*</b>	<b>C-T*</b>	<b>AB</b>	<b>AC</b>	<b>BC</b>	<b>AB-T*</b>	<b>AC-T*</b>	<b>BC-T*</b>	<b>ABC</b>
	(1)	(0)	(0)	(6)	(0)	(11)	(15)	(0)	(0)	(9)
	98,81	100,00	100,00	92,86	100,00	<b>86,90</b>	<b>82,14</b>	100,00	100,00	<b>89,29</b>
<b>QUARTA JANELA DE DADOS (8ms após a falta)</b>										
<b>Respostas corretas (%)</b>	<b>A-T*</b>	<b>B-T*</b>	<b>C-T*</b>	<b>AB</b>	<b>AC</b>	<b>BC</b>	<b>AB-T*</b>	<b>AC-T*</b>	<b>BC-T*</b>	<b>ABC</b>
	(1)	(0)	(0)	(6)	(0)	(14)	(15)	(1)	(0)	(11)
	98,81	100,00	100,00	92,86	100,00	<b>83,33</b>	<b>82,14</b>	98,81	100,00	<b>86,90</b>
<b>QUINTA JANELA DE DADOS (9ms após a falta)</b>										
<b>Respostas corretas (%)</b>	<b>A-T*</b>	<b>B-T*</b>	<b>C-T*</b>	<b>AB</b>	<b>AC</b>	<b>BC</b>	<b>AB-T*</b>	<b>AC-T*</b>	<b>BC-T*</b>	<b>ABC</b>
	(0)	(0)	(0)	(0)	(0)	(2)	(0)	(0)	(0)	(5)
	100,00	100,00	100,00	100,00	100,00	97,62	100,00	100,00	100,00	94,08

**Tabela 4 – Análise global do índice de acertos da RNA frente ao conjunto de teste para cada janela de dados apresentadas considerando todos os tipos de faltas**


<b>PRIMEIRA JANELA DE DADOS</b>	
<b>840 PADRÕES TESTADOS - 5ms após a falta</b>	
<b>Respostas corretas</b>	(110) <b>86,90%</b>
<b>SEGUNDA JANELA DE DADOS</b>	
<b>840 PADRÕES TESTADOS - 6ms após a falta</b>	
<b>Respostas corretas</b>	(143) <b>82,38%</b>
<b>TERCEIRA JANELA DE DADOS</b>	
<b>840 PADRÕES TESTADOS - 7ms após a falta</b>	
<b>Respostas corretas</b>	(42) 95,00%
<b>QUARTA JANELA DE DADOS</b>	
<b>840 PADRÕES TESTADOS - 8ms após a falta</b>	
<b>Respostas corretas</b>	(48) 94,29%
<b>QUINTA JANELA DE DADOS</b>	
<b>840 PADRÕES TESTADOS - 9ms após a falta</b>	
<b>Respostas corretas</b>	(7) 99,16



Respostas nas cinco janelas de dados  
Falta fase A-terra

Fase A     Fase B  
 Fase C     Terra


**Figura 6 – Respostas da RNA frente às cinco janelas de dados apresentadas para uma situação de falta aplicada à fase A – terra**



Respostas nas cinco janelas de dados  
Falta fases AB-terra

Fase A     Fase B  
 Fase C     Terra


**Figura 8 – Respostas da RNA frente às cinco janelas de dados apresentadas para uma situação de falta aplicada às fases AB – terra**



Respostas nas cinco janelas de dados  
Falta fases AB

Fase A     Fase B  
 Fase C     Terra

**Figura 7 – Respostas da RNA frente às cinco janelas de dados apresentadas para uma situação de falta aplicada às fases AB**



Respostas nas cinco janelas de dados  
Falta fases ABC

Fase A     Fase B  
 Fase C     Terra

**Figura 9 – Respostas da RNA frente às cinco janelas de dados apresentadas para uma situação de falta aplicada às fases ABC**

## 5 CONCLUSÃO

O uso de uma arquitetura de RNA como um modelo alternativo para a classificação de faltas em linhas de transmissão foi investigado neste trabalho. O modelo utiliza os valores pós-falta das tensões e correntes trifásicas apresentados através de cinco janelas de dados. Para este estudo são consideradas faltas fase-terra, fase-fase, fase-fase-terra e faltas trifásicas.

Os resultados obtidos ilustram que o desempenho global da arquitetura é satisfatório para classificação de faltas no sistema. Deve ser destacado que para aproximadamente 99,16% de todos os 4200 padrões testados obteve-se as corretas respostas por parte da RNA.

Nas respostas apresentadas pela rede, o que se verificou na grande maioria das situações erroneamente classificadas é o envolvimento do terra, quando este não estava presente ou uma situação contrária. Como se consideraram cinco janelas de dados para representar cada situação de falta, a rede apresentou algumas das vezes um erro de classificação nas cinco janelas. Em outros casos, três acertos e dois erros para cada conjunto de cinco janelas. Analisando-se as respostas apresentadas pela RNA quando da apresentação da 1<sup>a</sup> a 5<sup>a</sup> janela de dados, podemos computar o número de repetições para cada situação e então concluir sobre o tipo de falta encontrado. Assim sendo, obtendo-se a resposta final para a classificação desta análise, temos os seguintes índices de acertos para a mesma:

- considerando somente a primeira janela de dados, 5ms após a ocorrência da falta, um índice total de acertos correspondente a 86,90%;
- analisando até a terceira janela de dados este índice de acertos total passa para 95,00% (7ms após a ocorrência da falta);
- estendendo tal análise à quarta e quinta janela de dados, temos ao final do processo um índice total de acertos de 99,16%. Este dispendo-se de 9ms após a ocorrência da falta.

Este tempo gasto para a tomada da decisão na classificação vem em muito melhorar o desempenho dos dispositivos de proteção já que, pelos métodos convencionais, esta é realizada dispendo de no mínimo 8 a 10 ms. Deve ainda ser enfatizado que a topologia de rede apresentada é bastante otimizada devido ao fato de possuir somente uma camada intermediária e possuir na camada de saída apenas quatro neurônios, representando os 10 tipos possíveis de falta no sistema.

Também deve ser ressaltado que esta ferramenta abre uma nova dimensão na filosofia da aplicação da proteção que ainda deve ser amplamente investigada e que, possivelmente, permitirá resolver muitos dos complexos problemas ainda existentes na área.

## AGRADECIMENTOS

Os autores gostariam agradecer ao Departamento de Engenharia Elétrica e Eletrônica da Universidade de Bath (Inglaterra) pelas facilidades proporcionadas quando do desenvolvimento deste trabalho, bem como ao apoio financeiro recebido por parte da FAPESP - Fundação de Amparo à Pesquisa do Estado de São Paulo. Além destes, os nossos agradecimentos á empresa NeuralWare - *Aspen Technology* da qual provém o *software NeuralWorks* empregado neste trabalho.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Aggarwal, R. K.; Xuan, Q. Y. and Johns, A. T. (1997). Fault classification for double-circuits using self-organisation mapping neural network. *UPEC'97 - 32<sup>nd</sup> Universities Power Engineering Conference*, Vol.2, pp.440-443.
- Al-Hasawi, W. M.; Abbasy, N. H. and Mansour, M. (1997). Using fault induced transients and neural networks for T. L. ultra high-speed fault detection and classification. *IPST'97 - International Conference on Power Systems Transients*, Seattle, pp.412-417.
- ALTERNATIVE Transients Program (1987). Rule Book, Leuven EMTP Center (LEC).
- Chakravarthy, S. K.; Nayar, C. V. and Achuthan, N. R. (1992). Applying Pattern Recognition in Distance Relaying. Part 1: Concept. and Part 2: Feasibility, *IEE Proceedings-C*, Vol.139, No.4, pp.301-314.
- Coury, D. V. and Jorge, D. C. (1998). Artificial Neural Network Approach to Distance Protection, *IEEE Transactions on Power Delivery* (Jan.), Vol.13, No.1, pp.102-108.
- Coury, D. V. and Oleskovicz, M. (1998). Multi-layer neural networks applied to distance relaying. *International Journal of Electrical Power and Energy Systems*, Elsevier Science, England, Vol.20, No. 8, pp. 539-542.
- Dalstein T. and Kuliche, B. (1995). Neural network approach to fault classification for high speed protective relaying. *IEEE Transmission on Power Delivery*, Vol.10, No.2, pp.1002-1011.
- Dalstein, T.; Friedrich, T.; Kuliche, B. and Sobajic, D. (1996). Multi Neural Network Based Fault Area Estimation For High Speed Protective Relaying, *IEEE Transactions on Power Delivery*, Vol.11, No.2, pp.740-747.
- Dillon, T. S. and Niebur, D. (1996). *Neural networks applications in power systems*. CRL Publishing, London, England.
- Ghosh, A. K. and Lubkeman, D. L. (1995). The classification of power systems disturbance waveforms using a neural network approach. *IEEE Transactions on Power Delivery*, Vol.10, No.1, pp.109-115.
- Hertz, J.; Krogh, A. and Palmer, R. G. (1991). *Introduction to the theory of neural computation*, Santa Fe Institute Studies in the Sciences of Complexity, Vol.1, Addison-Wesley.
- Kandil, N.; Sood, V. K.; Khorasani, K. and Patel, R. V. (1992). Fault identification in AC-DC transmission system using neural networks. *Transactions on Power Systems*, Vol.7, No.2, pp.812-819.
- Kanoh, H.; Kaneta, M. and Kanemaru, K. (1991). Fault Location for Transmission Lines Using Inference Model Neural Network, *Electrical Engineering in Japan*, Vol.111, No. 7, pp.84-92.
- Keerthipala, W. W. L.; Wai, C. T. and Huisheng, W. (1997). Neural network based classifier for power system



- protection. *Electric Power Systems Research*, Vol.42, pp.109-114.
- Kezunovic, M. and Rikato, I. (1996). Detect and Classify faults using neural nets. *IEEE Computer Applications in Power*, pp.42-47.
- Khaparde, S. A.; Kale, P. B. and Agarwal, S. H. (1991). Application of Artificial Neural Network in Protective Relaying of Transmission Lines, *First International Forum on Application of Neural Networks to Power Systems*, Seattle, WA, pp.139-143.
- NeuralWorks - Reference Guide (1998). *A software reference for NeuralWorks Professional II/Plus and NeuralWorks Explorer*. NEURALWARE, a subsidiary of Aspen Technology, Inc.
- NeuralWorks Professional II/PLUS (1998). Version 5.23, NEURALWARE, a subsidiary of Aspen Technology, Inc.
- Sidhu, T. S.; Singh, H. and Sachdev, M. S. (1995). Design, Implementation and Testing of an Artificial Neural Network Based Fault Direction Discriminator for Protecting Transmission Lines, *IEEE Transactions on Power Delivery*, Vol.10, No.2, pp.697-706.
- Stevenson Jr., W. D. (1986). *Elementos de análise de sistemas de potência*. Rio de Janeiro, McGraw-Hill do Brasil.
- Su, W. B.; Mao, P. L.; Bo, Z. Q.; Aggarwal, R. K. and Johns, A. T. (1997). A fault detection technique for compositive transmission circuits using artificial neural networks. *UPEC'97 - 32<sup>nd</sup> Universities Power Engineering Conference*, Vol.1, pp.291294.
- Warrington, A. R. Van C. (1968). *Protective relays. Their theory and practice*. London, Chapman & Hall, Vol.2, 3 ed.
- Yang, H.; Chang, W. and Huang, C. (1994). A New Neural Networks Approach to On-Line Fault Section Estimation Using Information of Protective Relays and Circuit Breakers, *IEEE Transactions on Power Delivery*, Vol.9, No.1, pp.220-229.