



GPC/023

21 a 26 de Outubro de 2001
Campinas - São Paulo - Brasil

GRUPO DE ESTUDO DE PROTEÇÃO, MEDIÇÃO E CONTROLE EM SIST. DE POTÊNCIA

UM ESQUEMA COMPLETO PARA DETECÇÃO, CLASSIFICAÇÃO E LOCALIZAÇÃO DE FALTAS EM LINHAS UTILIZANDO REDES NEURAIS

Mário Oleskovicz* e Denis Vinicius Coury

Raj K. Aggarwal

EESC – USP

University of Bath

RESUMO

O presente estudo visa apresentar um modelo alternativo e completo de proteção para linhas de transmissão que venha a realizar a **detecção**, **classificação** e a **localização** de uma situação faltosa. Pela aplicação de Redes Neurais Artificiais, busca-se obter arquiteturas de redes fixas as quais representarão todo o conhecimento armazenado do sistema de proteção. Com estas arquiteturas e pela implementação de um algoritmo computacional apropriado, espera-se então, obter as respostas sobre todas as prováveis condições de operação do sistema. Deve ser enfatizado que o esquema proposto se mostra altamente preciso com alta velocidade de atuação, apresentando características bastante desejáveis ao sistema de proteção.

PALAVRAS-CHAVE: Sistemas Elétricos de Potência, Detecção, Classificação e Localização de Faltas, Redes Neurais Artificiais (RNAs).

1. - INTRODUÇÃO

A proteção de sistemas de energia é projetada para salvaguardar os equipamentos do sistema tais como geradores, transformadores, cabos e, além disto, 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 sequência 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 desta natureza designados à solução de problemas específicos. Dillon & Niebur (1) 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 Dalstein *et alii* (2) e Coury & Oleskovicz (3). Referentes à detecção de uma situação de falta encontramos as pesquisas desenvolvidas por Al-Hasawi *et alii* (4) e Su *et alii* (5), bem como para a discriminação direcional, os resultados apresentados por Sidhu *et alii* (6). Para a localização de faltas podemos referenciar Kanoh *et alii* (7) e Yang *et alii* (8) e para a classificação de faltas para linhas de transmissão devem finalmente ser

* Escola de Engenharia de São Carlos - USP, Departamento de Engenharia Elétrica, Av. Trabalhador Sancarlense 400, CEP: 13566-590, São Carlos - SP, Fone: (0XX16) 273 9366 Ramal 220, e-mail: olesk@sel.eesc.sc.usp.br

citados os trabalhos defendidos por Kezunovic & Rikato (9) e Aggarwal, *et alii* (10).

Através da aplicação de RNAs, apresenta-se no que segue, 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 *software NeuralWorks* (11) é empregado neste estudo para implementar as topologias de RNAs, treinando-as com o objetivo de se obter as matrizes de pesos fixas que descrevam todas as informações de operações presentes no sistema de transmissão. Com estas matrizes de pesos fixas, pode-se considerá-las através de um algoritmo computacional e obter as respostas desejadas sobre todas as condições de operação do sistema em análise. Este algoritmo, implementado em linguagem de programação “C”, têm como objetivo de aplicação a conexão de todos os módulos de redes neurais implementados e será convenientemente abordado.

2. - UMA VISÃO GERAL DO ESQUEMA

A topologia do sistema elétrico analisado em todo o processo é a representada na Figura 1. A estrutura da linha de transmissão de 440 KV corresponde a uma linha típica da CESP (Companhia Energética de São Paulo), empregada entre as cidades de Araraquara – Bauru e Jupiá – Ilha Solteira.




FIGURA 1 - Sistema de energia analisado

Devido às inúmeras situações aleatórias de faltas no sistema elétrico, o desempenho das redes neurais implementadas depende muito da escolha de um conjunto representativo de treinamento e teste. Todas as simulações realizadas para formar estes conjuntos, dispuseram do *software ATP – Alternative Transients Program* (12) e foram aplicadas sobre o sistema de transmissão tendo como variáveis:

- a distância em quilômetros de aplicação da falta, em relação ao barramento E;
- a resistência de falta entre fases e fase a terra;
- o ângulo de incidência da falta;
- o tipo de falta considerada (faltas entre uma fase com conexão a terra, duas fases com e sem conexão a terra e faltas trifásicas) e

- a condição de operação do sistema elétrico.

Deve ser mencionado que embora a técnica descrita é baseada em simulações computacionais, considerações práticas como o transformador de potencial capacitivo, amostragem do sinal (frequência de 1 kHz), filtro *anti-aliasing* (frequência de corte de 300 Hz) e erros de quantização da conversão analógica/digital (Conversor Analógico/Digital de 12 Bits), também foram incluídas. A técnica também considera o arranjo físico e características dos condutores, acoplamento mútuo e linhas transpostas.

Como apresentado anteriormente, o desenvolvimento do trabalho está dividido em módulos, que dizem respeito à implementação das arquiteturas de redes neurais para a **detecção, classificação e localização** da falta com a conseqüente atuação do sistema de proteção se necessário. Na Figura 2, apresenta-se um modelo alternativo para a proteção no que diz respeito à aplicação de RNAs, o qual é o objetivo da pesquisa.

Para a Rede Neural Artificial 1 (RNA1), referente à **detecção** da falta, três janelas de dados com quatro amostras dos valores trifásicos das tensões e correntes a uma frequência de 1 kHz, considerando-se amostras de pré e pós falta, foram utilizados para treinar e testar a arquitetura. Observa-se pelos resultados encontrados que, para a grande maioria das situações, com no máximo até três amostras pós falta (3ms) a rede é capaz de distinguir entre uma situação de falta à frente ou reversa à um determinado ponto do sistema, ou ainda, se for o caso, acusar uma condição normal de operação.

Com a confirmação de uma situação de falta em sentido reverso ou a frente do ponto escolhido, o módulo de classificação (RNA2) atua distinguindo as fases envolvidas entre os dez (10) tipos de faltas (dispondo-se de 4 a 9ms após a ocorrência do surto).

Resta agora determinar as zonas de atuação dos relés de distâncias (a partir de 9ms após a ocorrência da falta), para a conseqüente operação do sistema de proteção, as quais são indicadas pelas redes RNA3, RNA4 e RNA5.

3. - O PROCESSO DE TREINAMENTO

3.1 A detecção da falta

O objetivo deste módulo de detecção é reconhecer entre situações de faltas ocorrendo em sentido reverso a determinado ponto do sistema elétrico (barramento E) ou faltas ocorrendo à frente deste mesmo ponto, bem como reconhecer ainda as situações normais de operação, como descrito anteriormente.




FIGURA 2 - Modelo alternativo para a proteção aplicando-se redes neurais artificiais

Para formar um conjunto de dados representativo, 333 situações para cada tipo de falta foram escolhidas e aplicadas sobre o sistema. Três janelas de dados, com quatro amostras cada, foram consideradas, dispondo-se de até 3ms após a ocorrência da situação de falta. Somando-se a estas situações foram incorporados ao conjunto de dados, 2016 padrões descrevendo as características normais do sistema.

Para cada módulo (detecção, classificação e localização), 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. 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 às RNAs foram dispostas no arquivo de maneira aleatória.

Na Tabela 1 ilustram-se as duas respostas esperadas por parte da RNA1. Nesta, se os padrões apresentados a RNA1, seja na fase de treinamento ou durante a fase de teste, descreverem uma situação normal do sistema, a resposta deverá ser um valor próximo ou igual a 0 (zero) para as duas saídas (D_1 e D_2). Encontram-se

também ilustradas na tabela, as respostas esperadas se situações de faltas reversas ou à frente forem observadas.

Para todos os módulos representados por RNAs, convencionou-se que as saídas observadas no intervalo de 0 a 0,3 indicariam uma resposta igual a 0 (zero) e que valores situados entre o intervalo de 0,7 a 1,0, respostas iguais a 1 (um). Os demais valores indicariam uma indecisão por parte das RNAs.

Neste módulo de detecção, várias arquiteturas de redes neurais MLP (*Multi Layer Perceptron*) foram avaliadas, variando-se como por exemplo, o número de elementos de processamentos (neurônios) na camada intermediária, taxas de aprendizagem e de momento, número de ciclos de treinamento, número de padrões pertencentes ao conjunto de dados, número de janelas empregadas e demais parâmetros quando convenientes. Índices aceitáveis foram observados com uma arquitetura que apresenta 24 unidades de processamento na sua camada de entrada, 9 unidades de processamento na camada intermediária e 2 elementos na camada de saída (arquitetura 24-9-2).

Conforme apresentado na Tabela 2, verifica-se que a arquitetura 24-9-2 foi capaz de reconhecer todos os padrões (índice de acerto de 100%), classificando-os entre condições normais de operação e situações de faltas reversas e ou a frente de determinada ponto. Tais resultados, bem como o conjunto de teste aplicado sobre a configuração, serão apresentados e discutidos posteriormente.

3.2 A classificação da situação

Para este módulo, um total de 1380 diferentes situações de faltas sobre o sistema foram consideradas para formar o conjunto de dados, tomando-se cinco janelas de dados.

A Tabela 1 mostra as respostas esperadas por parte da arquitetura de RNA2 relacionadas às fases A (C_1), B (C_2) e C (C_3) e a conexão a terra (C_4) para todas as condições de faltas consideradas. Como resposta, a arquitetura de RNA2 implementada deve apresentar valores iguais ou próximos a um (1) ou zero (0), mostrando se a falta envolveu as fases A (C_1), B (C_2) e C (C_3), com ou sem conexão a terra (C_4).

Diferentes topologias de redes neurais MLP foram avaliadas, buscando-se de maneira empírica a que melhor representasse o problema de classificação em questão. A arquitetura escolhida apresenta 24 unidades na camada de entrada, 16 unidades na camada escondida e uma camada de saída com apenas 4 unidades de processamento (arquitetura 24-16-4).

TABELA 1- Respostas esperadas por parte das RNAs

MÓDULO DE DETECÇÃO			MÓDULO DE CLASSIFICAÇÃO ANN2 (24-16-4)					MÓDULO DE LOCALIZAÇÃO			
Situação	D ₁	D ₂	Tipo de falta	C ₁	C ₂	C ₃	C ₄	Zona	L ₁	L ₂	L ₃
Normal	0	0	A-E	1	0	0	1	1	1	0	0
Falta reversa	1	0	B-E	0	1	0	1	2	0	1	0
Falta à frente	0	1	C-E	0	0	1	1	3	0	0	1
ANN1 (24-9-2)			AB	1	1	0	0	ANN3 (24-48-44-3) ANN4 (24-42-40-3) ANN5 (24-24-20-3)			
			AC	1	0	1	0				
			BC	0	1	1	0				
			AB-E	1	1	0	1				
			AC-E	1	0	1	1				
			BC-E	0	1	1	1				
			ABC	1	1	1	0				

A Tabela 2 mostra a percentagem de respostas corretas da arquitetura empregada sujeita ao conjunto de teste formado. Como pode ser observado, os resultados obtidos são altamente satisfatórios e serão comentados no item 4.

3.3 A localização do defeito

Nesta abordagem, tomando-se como referência a Figura 1, as zonas de proteção foram definidas com as seguintes proporções:

- Zona de proteção primária: até 142,5 km a partir do barramento E, o que corresponde a 95% da LT2;
- Primeira zona de transição: $142,5 \pm 2,85$ km a partir do barramento E, o que corresponde a um índice de incerteza de $\pm 2\%$ para a zona de proteção primária;
- Zona de proteção secundária: até 195 km a partir do barramento E, o que corresponde a 130% da LT2;
- Segunda zona de transição: $195 \pm 3,9$ km a partir do barramento E ($\pm 2\%$ de 195 km) e
- Zona de proteção terciária: até 240 km a partir do barramento E, o que corresponde a 150% da LT2.

As duas zonas de transição mencionadas resultam do fato da mudança de valores próximos ou iguais a 0 (zero) para valores próximos ou iguais a 1 (um), ou vice-versa, que devem ser apresentados pela RNA, quando da passagem entre os pontos que caracterizam as zonas de proteção.

As três redes (RNA3, RNA4 e RNA5) que fazem parte deste módulo (Figura 2), apresentam três unidades de processamento em suas camadas de saída, cada uma sendo responsável por uma zona de proteção. A saída L₁ relaciona-se à zona de proteção primária e as saídas L₂ e L₃ as zonas de proteções secundária e terciária respectivamente. Neste módulo, saídas com valores próximos ou iguais a 0 (zero) indicam o não envolvimento da área de proteção e saídas com valores iguais ou próximos a 1 (um) o envolvimento, ou seja, a ocorrência de uma situação de falta na zona de

proteção indicada. As respostas esperadas por este módulo também estão ilustradas na Tabela 1.

Para formular o conjunto de dados utilizado para o treinamento da RNA3, fez-se a combinação dos parâmetros já mencionados, resultando em 1225 diferentes situações para cada um dos três tipos de faltas. Para esta rede em questão, 4 janelas de dados foram empregadas no processo. Ao total foram avaliadas 63 arquiteturas e a RNA escolhida, apresenta 24 unidades de processamento em sua camada de entrada, duas camadas intermediárias com 48 e 44 unidades cada e uma camada de saída com 3 unidades.

Para as situações de faltas que envolvam duas fases com ou sem conexão a terra, a arquitetura escolhida dentre várias tentativas apresenta as suas 24 unidades de processamento da camada de entrada conectadas as suas duas camadas intermediárias com 42 e 40 unidades e estas, a sua camada de saída com 3 unidades (arquitetura 24-42-40-3). As situações de faltas entre duas fases sem conexão a terra foram representadas por 615 padrões para cada uma dos três tipos de faltas, levando-se em conta 5 janelas de dados. Já as situações de faltas que envolvem duas fases com conexão a terra, 1075 condições de faltas foram consideradas para cada tipo de falta, sendo as mesmas, apresentadas através de 7 janelas de dados.

Com respeito a localização das faltas trifásicas, quatro janelas de dados foram empregadas no processo de treinamento. O conjunto de dados foi formado por 1525 diferentes situações de faltas. Com o intuito de se encontrar uma RNA que melhor atendesse em resposta as zonas de proteção, 25 arquiteturas foram analisadas e a escolhida apresenta 24 unidades de processamento na camada de entrada e 3 unidades na camada de saída. Para as duas camadas intermediárias, foram alocados 24 unidades de processamento (primeira camada intermediária) e 20 unidades de processamento para a segunda camada intermediária (arquitetura 24-24-20-3).

4. - TESTES REALIZADOS

Pelo que foi apresentado e observado nas implementações dos módulos anteriores, nota-se que as redes neurais empregadas convergiram rapidamente para uma resposta esperada. No entanto, tomando-se como exemplo um conjunto de cinco respostas do módulo de classificação, muitas das vezes estas respostas divergem em um número de classificações corretas e errôneas. Tendo este fato em análise, procurou-se então melhorar a tomada de decisão frente aos módulos implementados, optando-se em não analisar unicamente uma resposta da rede neural e sim, o conjunto das respostas pertinentes à cada módulo de detecção, classificação e de localização.

Para o módulo de detecção, verifica-se que são necessários 3ms pós-falta para a tomada de decisão, logo, as respostas das três janelas de dados serão analisadas. Já para o módulo de classificação o número de janelas de dados necessárias varia de três a cinco, o mesmo ocorrendo para o módulo de localização.

O algoritmo computacional implementado, obedece a uma forma seqüencial de ativação dos módulos considerados. Sendo assim, para uma fase de teste do mesmo, 4050 novos casos de prováveis situações que possam a vir ocorrer sobre o sistema de transmissão em análise foram simulados e apresentados, caso a caso, ao algoritmo em fase de experimento.

O conjunto de teste formulado compreende 405 diferentes casos para cada tipo de falta. As situações de faltas analisadas são compostas pela combinação das seguintes variáveis:

- Localização da falta (km) - 88, 105, 115, 125, 135, 145, 155, 165, 175, 185, 195, 202, 208, 212, 218, 222, 223, 225, 238, 243, 248, 253, 258, 263, 268, 273, 278, 282, 288, 293, 298, 302, 308, 313, 318, e 320;
- Resistência de falta (Ω) - fase a terra: 30, 60, 90 e fase - fase: 0,3, 0,6, e 0,9;
- Ângulo de incidência da falta ($^{\circ}$) - 20, 50, e 80.

Apresentando-se as situações simuladas caso a caso, as respostas por parte do algoritmo foram registradas a medida que cada módulo implementado era ativado e desativado, passando os sinais amostrados em análise para o módulo seguinte.

A Tabela 2 apresenta em síntese todos os resultados registrados, onde o Tempo de Processamento (T.P.) em destaque, provém basicamente da soma dos intervalos de tempo entre cada valor amostrado do sinal considerado (1 ms.) A percentagem de Respostas Corretas (R.C.) também está evidenciada, sendo que, para as RNAs 1 e 2, valores próximos a 100% são observados.

No que diz respeito ao módulo de localização, relembra-se que duas áreas de incertezas ($\pm 2\%$) foram definidas sobre o sistema em questão. Este fato vem e muito a esclarecer os índices apresentados, já que, a grande maioria das respostas incorretas apresentadas por este módulo recaem sobre estas supostas áreas de transição.

5. - CONCLUSÕES

O uso de arquiteturas de RNAs como modelos alternativos para a detecção, classificação e localização de faltas em linhas de transmissão foram investigadas nesta pesquisa. Os modelos utilizam os valores de pré e de pós-falta das tensões e correntes trifásicas apresentados através de janelas de dados. Para este estudo são consideradas faltas fase a terra, fase-fase, fase-fase a terra e faltas trifásicas.

Referindo-se aos casos testados para o módulo de detecção, as saídas da rede neural designadas a esta função convergiram rapidamente, para a grande maioria dos casos, à níveis corretos dispondo-se de até 3 ms. após a ocorrência da falta. Além de monitorar as condições normais de operação do sistema, este módulo também trabalha como um discriminador direcional, reconhecendo entre situações de faltas a frente ou em sentido reverso de um determinado ponto sobre o sistema. Com respeito ao módulo de classificação, este foi capaz de corretamente discriminar as fases envolvidas nas situações de faltas apresentadas, em um tempo situado entre 4 e 9 ms. após a ocorrência da falta. Finalmente, considerando as três zonas de proteção e todos os tipos de faltas citados, os resultados claramente mostram que esta aproximação conduz a níveis aceitáveis para a função de localizar a situação de falta sobre o sistema, com tempo situado entre 8 a 15 ms. após a ocorrência da mesma.

Deve ser enfatizado, que uma extensão da zona de proteção primária foi alcançada para um valor de 95% do comprimento da linha analisada. Tal acréscimo desta zona de proteção, vem a melhorar a confiabilidade e o desempenho do sistema de proteção como um todo.

6. - AGRADECIMENTOS

Os autores gostariam de agradecer aos Departamentos de Engenharia Elétrica e Eletrônica da Universidade de Bath (Inglaterra) e da Escola de Engenharia de São Carlos/USP (Brasil) 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.

TABELA 2 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados

Respostas Corretas - RC (%) e o Tempo de Processamento - TP (ms.) para cada módulo					
MÓDULO	TP	fase a terra	fase-fase	fase-fase a terra	trifásicas
DETECÇÃO 4050 padrões testados	RC	100	100	100	100
	2	71,94	76,46	82,14	84,44
	3	23,29	22,63	16,79	15,56
	4 - 5	4,77	0,91	1,07	-
CLASSIFICAÇÃO 4050 padrões testados	RC	99,92	100	99,26	98,52
	4	24,20	-	-	-
	5	37,94	4,44	6,18	-
	6	31,36	21,89	12,92	-
	7	5,60	17,12	31,28	30,37
	8	0,58	31,93	35,48	26,91
	9	0,24	13,58	10,54	24,70
	10 - 17	-	11,04	2,86	17,54
	RC	94,65	88,78	95,97	92,84
	8	0,61	-	0,31	-
LOCALIZAÇÃO 3240 padrões testados	9	4,12	2,06	6,50	-
	10	14,10	6,38	15,53	5,03
	11	19,60	22,02	27,01	17,61
	12	21,13	18,11	23,46	21,07
	13	17,39	20,06	13,89	28,63
	14	12,34	8,54	5,02	13,59
	15	4,42	7,41	2,76	3,72
	16 - 18	0,94	4,20	1,49	3,19

7. - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) DILLON, T. S. and NIEBUR, D. *Neural networks applications in power systems*. CRL Publishing, London, England, 1996.
- (2) DALSTEIN, T.; FRIEDRICH, T.; KULICHE, B. and SOBAJIC, D. Multi Neural Network Based Fault Area Estimation For High Speed Protective Relaying, *IEEE Transactions on Power Delivery*, 1996, Vol.11, No.2, pp.740-747.
- (3) COURRY, D. V. and OLESKOVICZ, M. Multi-layer neural networks applied to distance relaying. *International Journal of Electrical Power and Energy Systems*, Elsevier Science, England, 1998, Vol.20, No. 8, pp. 539-542.
- (4) AL-HASAWI, W. M.; ABBASY, N. H. and MANSOUR, M. 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, 1997, pp.412-417.
- (5) SU, W. B.; MAO, P. L.; BO, Z. Q.; AGGARWAL, R. K. and JOHNS, A. T. A fault detection technique for compositive transmission circuits using artificial neural networks. *UPEC'97 - 32nd Universities Power Engineering Conference*, 1997, Vol.1, pp.291294.
- (6) SIDHU, T. S.; SINGH, H. and SACHDEV, M. S. Design, Implementation and Testing of an Artificial Neural Network Based Fault Direction Discriminator for Protecting Transmission Lines, *IEEE Transactions on Power Delivery*, 1995, Vol.10, No.2, pp.697-706.
- (7) KANO, H.; KANETA, M. and KANEMARU, K. Fault Location for Transmission Lines Using Inference Model Neural Network, *Electrical Engineering in Japan*, 1991, Vol.111, No. 7, pp.84-92.
- (8) YANG, H.; CHANG, W. and HUANG, C. A New Neural Networks Approach to On-Line Fault Section Estimation Using Information of Protective Relays and Circuit Breakers, *IEEE Transactions on Power Delivery*, 1994, Vol.9, No.1, pp.220-229.
- (9) KEZUNOVIC, M. and RIKATO, I. Detect and Classify faults using neural nets. *IEEE Computer Applications in Power*, 1996, pp.42-47.
- (10) AGGARWAL R. K., XUAN Q. Y., JOHNS A. T. and Bennett A. Fault classification technique for double-circuit lines based on a combined unsupervised/supervised neural network, *IEEE Transactions on Power Delivery*, 1999, Vol. 14, No. 4, pp. 1250-1256.
- (11) NEURALWORKS PROFESSIONAL II/PLUS. Version 5.23, NEURALWARE, a subsidiary of Aspen Technology, Inc., 1998.
- (12) ALTERNATIVE Transients Program. Rule Book, Leuven EMTP Center (LEC), 1987.