



## GRUPO V

### GRUPO DE ESTUDO DE PROTEÇÃO, MEDIÇÃO, CONTROLE E COMUNICAÇÃO EM SISTEMAS DE POTÊNCIA (GPC)

#### UM NOVO MÉTODO PARA CLASSIFICAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO BASEADO EM RECONHECIMENTO DE PADRÕES

Renan Giovanini

Denis Vinicius Coury\*

Departamento de Engenharia Elétrica  
Escola de Engenharia de São Carlos - USP

#### RESUMO

Este artigo apresenta o desenvolvimento de um *software* para a classificação de faltas em uma linha de transmissão através de uma rede neural artificial multicamadas. Na geração dos dados foi utilizada uma linha de transmissão de 400 kV com comprimento de 100 Km, simulada através do *software* TEER. Todos os tipos de faltas (AT, BT, CT, AB, BC, AC, ABT, BCT, ACT, ABC) foram simulados com suas possíveis variações (ângulo de incidência da falta, distância da falta e resistência da falta) e resultados altamente encorajadores são apresentados. O método proposto apresenta tempos de resposta bastante rápidos comparados com métodos convencionais.

#### PALAVRAS-CHAVE

Proteção - Linhas de Transmissão - Redes Neurais Artificiais - Classificação de Faltas

#### 1.0 - INTRODUÇÃO

Proteger as linhas de transmissão é uma das tarefas mais importantes no sentido de salvaguardar os sistemas elétricos de potência. Faltas em linhas de transmissão precisam ser localizadas precisamente e extintas o mais rápido possível. Para tal, o esquema de proteção de linhas se utiliza de valores amostrados de correntes e tensões para a execução das seguintes tarefas:

- Detecção da Falta: módulo que sinaliza que uma falta ocorreu;
- Classificação: módulo que deverá indicar o tipo de falta ocorrido e as fases envolvidas na mesma para passos posteriores, no mais curto espaço de tempo, e finalmente;

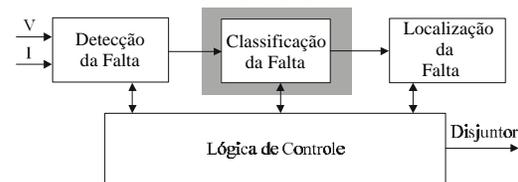
- Localização: módulo que determinará a localização da falta, através do cálculo da impedância aparente.

A Figura 1 ilustra as partes funcionais de um relé. Neste esquema, grandezas trifásicas de corrente (IA, IB, IC) e tensão (VA, VB, VC) compõem as entradas do sistema. Um módulo de controle lógico monitora todas as partes do relé.

Após a detecção da falta e classificação da mesma, o relé efetua o cálculo da impedância aparente para a verificação da zona de proteção na qual a falta se insere (localização).

Dentro deste contexto, a classificação correta e rápida da falta é um passo importante para a lógica de controle do relé.

FIGURA 1 : PARTES FUNCIONAIS DE UM RELÉ



Para a utilização de sistemas de proteção de ultra velocidade de operação, o módulo classificador deve realizar uma decisão precisa do tipo de falta envolvida em menos de 10 ms, após a ocorrência desta, com o intuito de se obter o sinal de abertura o mais rápido possível. Alguns métodos convencionais (1,2) têm lidado com este problema, porém os tempos para estimativa do tipo de falta são excessivamente longos. Este trabalho apresenta um projeto de um novo sistema que provê uma rápida e confiável estimativa do tipo de falta através de medidas de valores de tensão e corrente trifásicos em tempo real.

\* Departamento de Engenharia Elétrica – Escola de Engenharia de São Carlos – USP  
C.P. 359 - CEP 13560-970 - São Carlos - SP – Brasil  
e-mail: coury@sel.eesc.sc.usp.br

O novo método se utiliza da teoria de Redes Neurais Artificiais (RNA's), método cada vez mais utilizado em problemas relacionados a sistemas elétricos de potência (3,4,5,6) para a tarefa de classificação de falta quanto ao tipo nos níveis de tempo requeridos para um moderno sistema de proteção.

## 2.0 - RNA'S COMO CLASSIFICADORAS DE PADRÕES

### 2.1 - Descrição

Em 1986, Rumelhart, Hinton e Williams (7,8) apresentaram uma regra capaz de ajustar o comportamento de uma RNA com camadas escondidas. Em termos gerais, uma RNA contém uma camada de entrada, uma camada de saída e possivelmente uma ou mais camadas escondidas. Cada camada pode possuir uma ou várias unidades de processamento (neurônios). Uma representação esquemática de um neurônio pode ser visualizada na Figura 2.

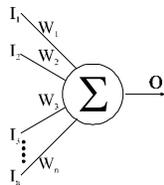


FIGURA 2 : REPRESENTAÇÃO ESQUEMÁTICA DE UM NEURÔNIO

O neurônio recebe sua entrada através de um conjunto de links ponderados. A sua ativação será assim definida através da somatória destas entradas ponderadas. A saída do neurônio é definida por uma função *threshold*, sendo freqüentemente representada pela função sigmoidal :

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

A saída do neurônio será então propagada, ou para outros neurônios ou para a saída da rede. Uma RNA será então um conjunto de neurônios organizados em camadas como apresentado na Figura 3:

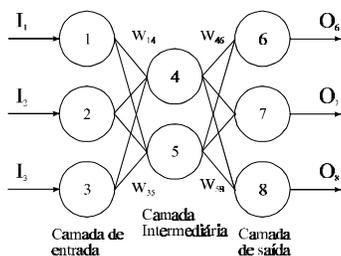


FIGURA 3 : REPRESENTAÇÃO ESQUEMÁTICA DE UMA RNA

Deve-se salientar que os neurônios são conectados apenas em um sentido através dos links (Rede *FeedForward*). O funcionamento da rede consistirá então na apresentação dos dados de entrada e a conseguinte propagação destes através das camadas seguintes até o cálculo final da saída.

### 2.2 - Treinamento

Para que uma RNA possa fazer uma correta classificação, um conjunto de dados deve ser apresentado descrevendo todas as classes envolvidas no problema. Estes dados são compostos basicamente por vetores de entrada e pelos respectivos vetores de saída. A RNA utilizada neste estudo foi treinada pelo algoritmo conhecido como *Backpropagation Learning Algorithm* proposto por Rumelhart (7,8). Esta regra de aprendizado, também conhecida como Regra Delta Generalizada, explora o gradiente da função erro. Calculando o erro individual da padrão  $m$ ,  $E_m$  :

$$E_m = \frac{1}{2} \sum_z (t_{mz} - o_{mz})^2 \quad (2)$$

onde  $t_{mz}$  é a saída desejada para o padrão  $m$  e  $o_{mz}$  é a saída atual da rede. O erro total será então a soma de todos os erros individuais :

$$E = \sum_z E_m \quad (3)$$

A minimização do erro é obtida através da atualização dos pesos. Este processo segue a direção negativa do crescimento da função gradiente,

$$\Delta w_{ij} = -h \frac{\partial E}{\partial w_{i,j}} \quad (4)$$

ou

$$\Delta w_{i,j}^m = h d_j^m o_i^m \quad (5)$$

onde

$$d_j = (1 - o_j) o_j (o_j - t_j) \quad (6)$$

para neurônios  $j$  localizados na camada de saída e

$$d_j = (1 - o_j) o_j \sum_i d_i w_{i,j} \quad (7)$$

para neurônios  $j$  localizados na camada escondida. A partir destas relações podemos calcular recursivamente a correção dos pesos no sentido da

camada de saída à camada de entrada. Após todas as correções serem calculadas, os pesos são atualizados. O processo é então reiniciado até que o erro E fique abaixo de um valor especificado.

### 3.0 - O SISTEMA ELÉTRICO UTILIZADO

O sistema elétrico utilizado consiste de uma linha de transmissão trifásica de 400 kV, 100 Km de extensão, que pode ser visualizada nas Figuras 4 e 5.

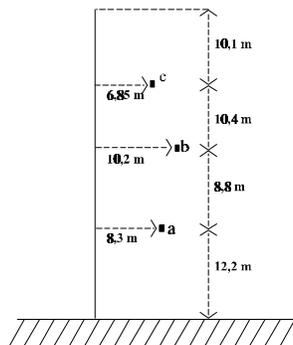


FIGURA 4 : ARRANJO FÍSICO DOS CONDUTORES DA LINHA

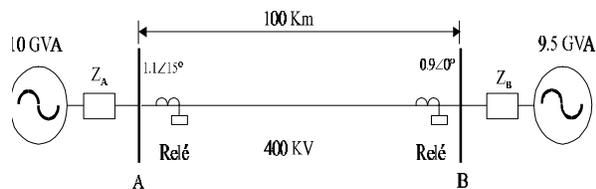


FIGURA 5 : SISTEMA ELÉTRICO DE POTÊNCIA UTILIZADO

Com base no sistema acima existem 10 diferentes tipos de faltas que podem ocorrer ao longo das linhas de transmissão :

- 3 faltas do tipo fase-terra (AT, BT, CT);
- 3 faltas do tipo fase-fase (AB, AC, BC);
- 3 faltas do tipo 2 fases-terra (ABT, ACT, BCT);
- 1 falta do tipo trifásica (ABC) com ou sem conexão à terra.

A Figura 6 mostra uma situação típica para uma falta fase-fase (envolvendo as fases A e B) ocorrida a 33 ms, no sistema elétrico do tipo ilustrado acima, para o relé localizado próximo ao barramento A.

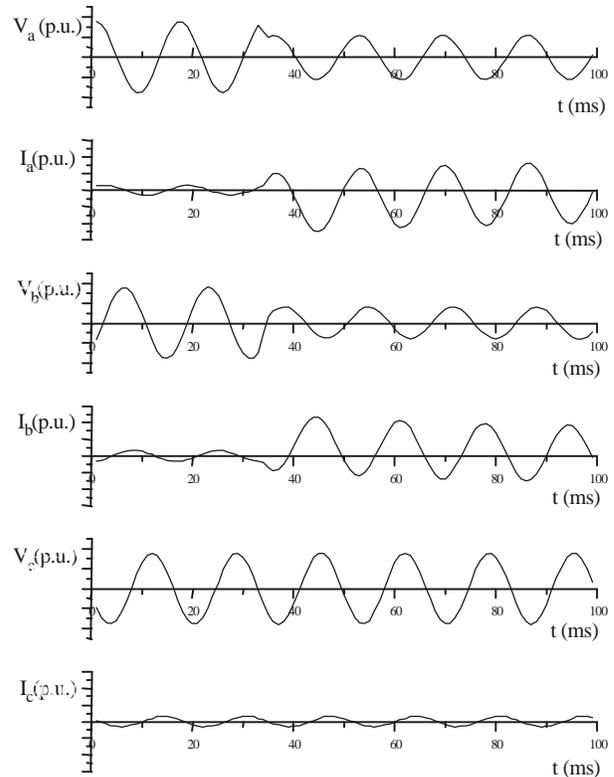


FIGURA 6 : FALTA FASE-FASE (FASES A-B) NO SISTEMA ELÉTRICO UTILIZADO

## 4.0 - CLASSIFICAÇÃO DE FALTAS USANDO RNA'S

### 4.1 - Geração de dados

Para a realização do treinamento das redes, foram gerados 3420 arquivos de padrões. Como estes dados seriam difíceis de serem obtidos na prática, foi utilizado um programa computacional de simulação de transitórios em linhas de transmissão de extra alta tensão (EAT) desenvolvido por Johns e Agarwall na Bath University, conhecido como TEER (9). Deve ser enfatizado que a simulação computacional utilizada leva em consideração aspectos práticos tais como efeito dos transdutores, filtros analógicos e erros de quantização, sendo os dados obtidos bem próximos aos encontrados na prática. A técnica também considera o arranjo físico dos condutores (Figura 4), a característica dos condutores e o efeito dos parâmetros dependentes da frequência durante a falta. Assim, para a geração de padrões considerada, foram variados os seguintes parâmetros :

- tipos de falta : AT, BT, CT, ABT, ACT, BCT, AB, AC, BC, ABC;
- distância de falta : 1, 10, 30, 50, 70, 90 Km;

- ângulo de incidência de falta : 0, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170, 180°;
- resistência de falta : 1, 17, 80  $\Omega$ .

Cabe salientar que os arquivos de padrões foram gerados a uma taxa amostral de 1kHz e que as distâncias de falta tem o barramento A do sistema proposto como referência.

#### 4.2 - Topologia da RNA considerada

Para o processo de treinamento das diferentes topologias de redes neurais testadas, utilizou-se o software SNNS (*Stuttgart Neural Network Simulator*) (10), e o método *Backpropagation*.

Para o treinamento da rede para classificação da falta quanto ao tipo foram utilizados apenas dados de pós-falta, considerando-se que a falta tenha sido detectada por métodos convencionais. Estes dados foram compostos basicamente por três amostras consecutivas de cada corrente (IA, IB, IC) acrescidas de três amostras consecutivas da corrente de seqüência 0 (I<sub>0</sub>). Para a formação do conjunto de treinamento levou-se em conta que a detecção da falta poderia ser feita na 1<sup>a</sup>, 2<sup>a</sup> ou 3<sup>a</sup> amostra pós-falta, obtendo-se portanto 3 conjuntos distintos de padrões de treinamento para a mesma situação de falta. Na Figura 7, ilustra-se a janela móvel de dados utilizada para o treinamento para uma fase faltosa.

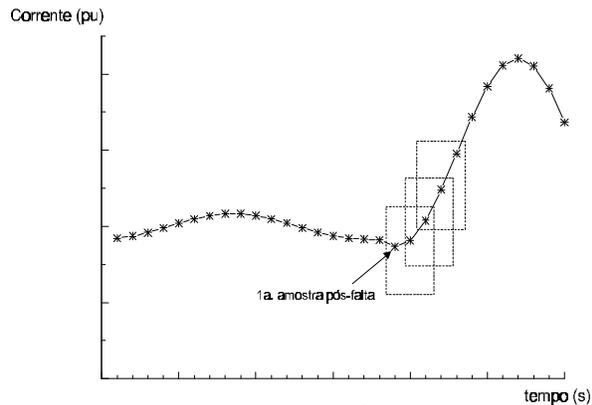


FIGURA 7 : JANELA MÓVEL DE DADOS PARA O TREINAMENTO DA RNA

A partir então desta regra de formação, obteve-se um conjunto de 10.260 padrões para a realização do treinamento da rede classificadora, derivado dos 3.420 arquivos de padrões gerados pelo software TEER.

Para o treinamento em questão, considerando-se quatro saídas para a rede neural (IA, IB, IC e I<sub>0</sub>), utilizou-se a convenção de que para as fases envolvidas na falta, o valor de saída da rede deveria ser igual a 1, enquanto que para as fases não envolvidas na falta deveria ser

igual a 0. Esta convenção pode ser visualizada na Tabela 1.

TABELA 1: CONVENÇÃO UTILIZADA PARA O TREINAMENTO DA RNA

	Valor de saída para a Fase A	Valor de saída para a Fase B	Valor de saída para a Fase C	Valor de saída para a Terra
Falta AT	1	0	0	1
Falta BT	0	1	0	1
Falta CT	0	0	1	1
Falta AB	1	1	0	0
Falta AC	1	0	1	0
Falta BC	0	1	1	0
Falta ABT	1	1	0	1
Falta ACT	1	0	1	1
Falta BCT	0	1	1	1
Falta ABC	1	1	1	0

A Rede Neural Artificial que obteve o melhor discernimento entre os diferentes tipos de falta em um sistema elétrico é composta por doze unidades de processamento na camada de entrada, duas camadas intermediárias, com vinte unidades de processamento respectivamente, e quatro unidades na camada de saída. Os quatro neurônios de saída correspondem respectivamente as fases A, fase B, fase C e Terra, como descrito anteriormente.

Esta rede pode ser melhor visualizada na Figura 8.

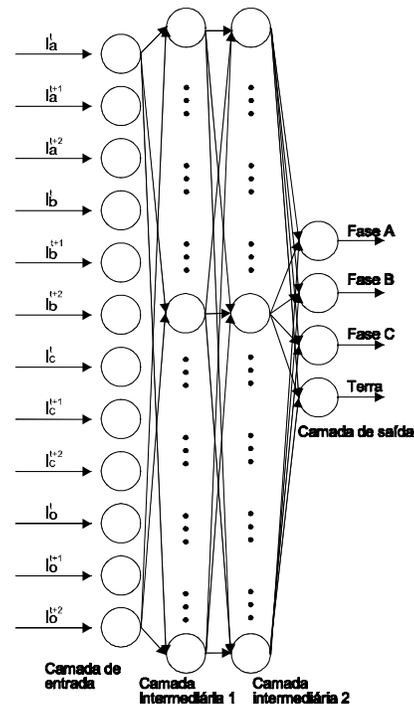


FIGURA 8 : RNA UTILIZADA NOS ESTUDOS

## 5.0 - RESULTADOS

De forma a podermos verificar a capacidade de discernimento do esquema de classificação proposto, foram realizados 440 testes. Os testes foram gerados através de condições de faltas não vistas no treinamento. Para tal, simularam-se diferentes tipos de faltas no TEER com diferentes distâncias, ângulos de incidência, e resistência de falta com relação aos padrões de treinamento. Os parâmetros variados no teste foram :

- tipo de falta : AT, BT, CT, ABT, ACT, BCT, AB, AC, BC, ABC;
- distância de falta : 3, 7, 16, 23, 31, 44, 57, 69, 73, 87, 94 Km;
- ângulo de incidência de falta : 35, 94°;
- resistência de falta : 5, 70  $\Omega$ .

A seguir apresentam-se algumas tabelas que evidenciam a precisão do esquema de classificação, dada a mudança das condições de falta.

Foi obtido 100% de acerto quanto à classificação, onde em 21% dos casos a falta foi classificada utilizando-se 3 amostras de pós-falta, 70% utilizando-se de 4 amostras de pós-falta e 8% utilizando-se de 5 amostras de pós-falta.

As Tabelas 2 a 5 mostram testes realizados com a rede classificadora para os tipos de falta CT, BC, ABT e ABC respectivamente para ângulos de incidência de falta de 35° e 94° e resistências de falta de 5 e 70  $\Omega$ . Como podemos verificar, todos os testes obtiveram respostas bem próximas das esperadas por parte do esquema de classificação proposto.

TABELA 2 : TESTE DA REDE CLASSIFICADORA  
(parâmetros utilizados : Ângulo de incidência de falta=35°; Resistência de Falta=5 $\Omega$ )

Distância (Km)	Falta CT Resposta obtida			
	3	0.000	0.000	1.000
7	0.000	0.000	1.000	1.000
16	0.009	0.000	1.000	1.000
23	0.007	0.000	1.000	1.000
31	0.003	0.000	1.000	1.000
44	0.000	0.000	1.000	1.000
57	0.000	0.000	1.000	1.000
69	0.000	0.000	1.000	1.000
73	0.000	0.000	1.000	1.000
87	0.000	0.000	1.000	1.000
94	0.000	0.000	1.000	1.000
Resposta esperada	0.000	0.000	1.000	1.000

TABELA 3 : TESTE DA REDE CLASSIFICADORA  
(parâmetros utilizados : Ângulo de incidência de falta=94°; Resistência de Falta=5 $\Omega$ )

Distância (Km)	Falta BC Resposta obtida			
	3	0.001	1.000	1.000
7	0.001	1.000	1.000	0.000
16	0.001	1.000	1.000	0.000
23	0.001	1.000	1.000	0.000
31	0.001	1.000	1.000	0.000
44	0.001	1.000	1.000	0.000
57	0.001	1.000	1.000	0.000
69	0.001	1.000	1.000	0.000
73	0.001	1.000	1.000	0.000
87	0.001	1.000	1.000	0.000
94	0.001	1.000	1.000	0.000
Resposta esperada	0.000	1.000	1.000	0.000

TABELA 4 : TESTE DA REDE CLASSIFICADORA  
(parâmetros utilizados : Ângulo de incidência de falta=35°; Resistência de Falta=70 $\Omega$ )

Distância (Km)	Falta ABT Resposta obtida			
	3	1.000	1.000	0.000
7	1.000	1.000	0.000	1.000
16	1.000	1.000	0.000	1.000
23	1.000	1.000	0.000	1.000
31	1.000	1.000	0.000	1.000
44	1.000	1.000	0.000	1.000
57	1.000	1.000	0.000	1.000
69	1.000	1.000	0.000	1.000
73	1.000	1.000	0.000	1.000
87	1.000	1.000	0.000	1.000
94	1.000	1.000	0.000	1.000
Resposta esperada	1.000	1.000	0.000	1.000

TABELA 5 : TESTE DA REDE CLASSIFICADORA  
(parâmetros utilizados : Ângulo de incidência de falta=94°; Resistência de Falta=70 $\Omega$ )

Distância (Km)	Falta ABC Resposta obtida			
	3	1.000	1.000	1.000
7	1.000	1.000	1.000	0.000
16	1.000	1.000	1.000	0.000
23	1.000	1.000	1.000	0.000
31	1.000	1.000	1.000	0.000
44	1.000	1.000	1.000	0.000
57	1.000	1.000	1.000	0.000
69	1.000	1.000	1.000	0.000
73	1.000	1.000	1.000	0.000
87	1.000	0.999	1.000	0.000
94	1.000	1.000	1.000	0.001
Resposta esperada	1.000	1.000	1.000	0.000

## 6.0 - CONCLUSÕES

Este trabalho aborda a aplicação de um classificador de faltas, baseado em Redes Neurais Artificiais, como módulo importante para proteção de uma linha de transmissão.

Testes mostram que o sistema proposto foi capaz de classificar corretamente faltas quanto ao tipo em 100% dos casos estudados. Deve ainda ser ressaltado que na maior parte dos casos (91%) a classificação foi completada com no máximo 4 amostras de pós-falta (4 ms) e em todos os casos estudados a classificação foi completada com até 5 amostras de pós-falta (5 ms). Isto demonstra a rapidez na tarefa de classificação embutida no método proposto principalmente levando-se em consideração os tempos apresentados pelos métodos convencionais. Assim, a utilização de tal método resultaria em maior rapidez para a tarefa de proteção em um sistema elétrico. Ainda, deve ser mencionado que a determinação do tipo de falta não foi afetada pela resistência de falta, ângulo de incidência e distância da falta, demonstrando que o classificador proposto é altamente confiável.

## 7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) COURY, D. Um Estimador Ótimo Aplicado a Proteção Digital dos Sistemas de Potência. Tese de Mestrado, EESC - USP, 1987.
- (2) PHADKE, A. G., HLIBKA, T., IBRAHIM, M. A Digital Computer System for EHV Substation: Analysis and Field Tests. IEEE Transaction on Power Apparatus and Systems, PAS-95 (1), 1976.
- (3) KANO, H., KANETA, M., KNEMARU, K. Fault Location for Transmission Lines Using Inference Model Neural Network. Electrical Engineering in Japan, 111 (7) : 84 -92, 1991.
- (4) DALSTEIN, T., KULICHE, B. Neural Network Approach to Fault Classification for High Speed Protective Relaying. IEEE Transaction on Power Delivery, 10 (2) : 1002-1009, 1995.
- (5) SIDHU, T. S., SINGH, H., 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, 10(2) : 697 - 706, 1995.
- (6) COURY, D.V., JORGE, D.C. Artificial Neural Network Approach to Distance Protection of

Transmission Lines . IEEE Transactions on Power Delivery, 13(1): 102-108, 1998.

- (7) RUMELHART, D., MCCLELLAND, J.L. Parallel distributed processing. Explorations in the Micro structure of Cognition. Volume 1 : Foundations. MIT Press, Cambridge, Massachusetts, 1986.
- (8) RUMELHART, D., MCCLELLAND, J.L. Parallel distributed processing. Explorations in the Micro structure of Cognition. Volume 2 : Psychological and Biological Models. MIT Press, Cambridge, Massachusetts, 1986.
- (9) JONHS, A.T., AGARWALL, R.K. Digital Simulation of Faulted EHV Transmission Lines with Particular Reference to Very-High-Speed Protection. Proceedings of IEE, 123(4): 353-359, 1976.
- (10) INSTITUTE FOR PARALLEL AND DISTRIBUTED HIGH PERFORMANCE SYSTEMS, UNIVERSITY OF STUTTGART. SNNS V4.1 User's Manual. 1995.

## 8.0 - DADOS BIOGRÁFICOS

**Renan Giovanini** nasceu em Porto Ferreira, São Paulo, em 1974. Formou-se em Engenharia Elétrica pela Universidade de São Paulo, campus São Carlos, em 1998. Atualmente é aluno de mestrado pela mesma universidade. Suas áreas de interesse são proteção de sistemas de potência bem como utilização de redes neurais para diagnósticos de falhas e faltas em sistemas de potência.

**Denis Vinicius Coury** nasceu em Araxá, Minas Gerais, em 1960. Formou-se em Engenharia Elétrica pela Universidade Federal de Uberlândia em 1983, recebeu o título de Mestre pela Universidade de São Paulo em 1986 e o título de Ph.D. pela Universidade de Bath – Inglaterra em 1992. Trabalhou para o Instituto de Pesquisas Tecnológicas ( IPT ) entre 1985 e 1986. Juntou-se ao Departamento de Engenharia Elétrica da Universidade de São Paulo, São Carlos, em 1986 onde atualmente é professor livre docente no Grupo de Sistemas de Potência. Sua área de interesse concentra-se na proteção de sistemas de potência bem como na utilização de novas técnicas como sistemas inteligentes e redes neurais artificiais para controle e diagnóstico de faltas.