



**SNPTEE  
SEMINÁRIO NACIONAL  
DE PRODUÇÃO E  
TRANSMISSÃO DE  
ENERGIA ELÉTRICA**

GPC - 17  
16 a 21 Outubro de 2005  
Curitiba - Paraná

**GRUPO V  
GRUPO DE ESTUDO DE PROTEÇÃO, MEDIÇÃO E CONTROLE EM SISTEMAS DE POTÊNCIA - GPC**

**CONSTRUÇÃO AUTOMÁTICA DE BASES DE DADOS –  
UMA EXPERIÊNCIA DE P&D ENTRE A CHESF E A UFCG**

**Benemar Alencar de Souza \***

**GSE - UFCG**

**RESUMO**

Redes neurais artificiais vêm sendo aplicadas ao problema de diagnóstico de faltas em linhas de transmissão com resultados bastante satisfatórios. Em tais aplicações é imprescindível a construção de um conjunto de padrões que representem as situações de faltas nestas linhas, o qual é comumente denominado de Base de Dados. Este trabalho tem como objetivo apresentar uma metodologia de construção automática de Bases de Dados para o treinamento de redes neurais artificiais para análise de ocorrências em sistemas de potência.

**PALAVRAS-CHAVE**

Diagnóstico de Faltas, Redes Neurais Artificiais, Base de Dados, ATP.

**1.0 - INTRODUÇÃO**

No contexto atual do setor elétrico brasileiro, a análise oscilográfica das perturbações ocorridas no sistema elétrico é de importância fundamental no processo de avaliação dos parâmetros da Qualidade da Energia, bem como no desempenho da proteção. A oscilografia constitui-se na aquisição das grandezas do sistema elétrico (correntes e tensões), além de sinalizações provenientes de cadeias de proteção quando da ocorrência de uma falta no sistema. Os equipamentos designados para isto são denominados oscilógrafos, cujos equipamentos mais recentes, de tecnologia digital, são também chamados de Registradores Digitais de Perturbação (RDP).

Além do interesse da empresa em dispor de registros que comprovem a sua isenção no caso desses eventos, existem também questões regulatórias impostas pelo Operador Nacional do Sistema (ONS), que exigem a monitoração de determinados pontos de conexão do sistema à rede básica. Neste sentido, a Companhia Hidro Elétrica do São Francisco (CHESF) tem se empenhado na concepção de uma rede de oscilografia que monitore constantemente o seu sistema. Atualmente, a CHESF possui cerca de 350 equipamentos que são monitorados constantemente pelos RDP e relés digitais com função de oscilografia incorporada. A monitoração do sistema, entretanto, gerou problemas no gerenciamento e manutenção do sistema de aquisição de dados. Na tentativa de solucionar alguns desses problemas, a CHESF, juntamente com a Universidade Federal de Campina Grande (UFCG), participaram de um Projeto de Pesquisa e Desenvolvimento (P&D) que teve como objetivo desenvolver e implantar em sua rede de oscilografia, um sistema de análise automático de registros. A experiência de P&D resultou num software denominado de **Neuranálise**<sup>®</sup> (1).

O Neuranálise<sup>®</sup> efetua, de forma automática, a triagem e pré-análise dos registros oscilográficos provenientes dos RDP da rede oscilográfica da CHESF. Na forma como foi concebido, ele foi incorporado ao sistema de oscilografia, integrando-se à rede de aquisição de dados já instalada. O Neuranálise<sup>®</sup> baseou-se no uso da transformada wavelet e das redes neurais artificiais, sendo constituído por três módulos:

\* Av. Aprígio Veloso, 882 - Bodocongó - CEP 58.109-970 - Campina Grande - PB - Brasil  
Tel.: (083) 310-1140 - Fax: (083) 310-1140 - e-mail: benemar@dee.ufcg.edu.br

- **Neurabase**<sup>®</sup>: módulo de geração da Base de Dados a ser utilizada no aprendizado da rede neural. Possui uma interface gráfica e utiliza o software ATP – *Alternative Transient Program*, para modelagem do sistema elétrico e simulação dos diversos cenários de falta.
- **Neurarede**<sup>®</sup>: módulo de construção e treinamento da rede neural. Possui uma interface gráfica e utiliza a Base de Dados construída pelo Neurabase<sup>®</sup>.
- **Neurareg**<sup>®</sup>: módulo de análise e triagem de registros. Utiliza a transformada wavelet e uma rede neural, previamente treinada com o Neurarede<sup>®</sup>.

O módulo Neurareg<sup>®</sup> utiliza uma rede neural perceptron com uma camada oculta e treinamento supervisionado. A entrada da rede neural são os valores amostrados de tensão e corrente nas fases da linha, junto com as componentes de seqüência zero, provenientes dos canais analógicos dos RDP.

Para as etapas de treinamento, validação e teste da rede neural é necessário se elaborar um conjunto de padrões com valores de tensão e corrente que representem as situações de falta no sistema elétrico a ser analisado, o qual é comumente denominada de Base de Dados. A construção das Bases de Dados é uma das etapas mais importantes em aplicações envolvendo redes neurais artificiais, visto que o desempenho da rede dependerá da representatividade do conjunto de padrões escolhidos para o seu treinamento. No caso particular de diagnóstico de faltas em linhas de transmissão, essa representatividade é comprometida pela pequena diversidade de registros de faltas reais no sistema, tendo em vista, por exemplo, que aquelas que envolvem as três fases não correspondem a mais do que 5% das perturbações que ocorrem no sistema (2). Para realizar o treinamento da rede, de tal forma que um grande número de cenários de falta seja considerado, é necessário o uso de casos simulados.

Este artigo tem como objetivo apresentar o funcionamento do Neurabase<sup>®</sup>, ou seja, apresentar a metodologia desenvolvida para construção automática das Bases de Dados.

## 2.0 - AS REDES NEURAS ARTIFICIAIS E O PROBLEMA DE CLASSIFICAÇÃO DE FALTAS

Nos últimos anos, vários métodos analíticos vêm sendo implementados com o objetivo de classificarem faltas em linhas de transmissão. Muitos deles, no entanto, apresentam desempenho comprometido pela influência de ruído nas medições, pela presença de harmônicos e até mesmo, por mudanças nas condições de operação do sistema (3). Desta forma, métodos alternativos diversos vêm sendo propostos e dentre eles, destacam-se as redes neurais artificiais, as quais têm apresentado desempenho superior aos métodos analíticos tradicionais, no que diz respeito à velocidade, precisão e robustez no diagnóstico (4)-(5)-(6).

Nas aplicações das redes neurais ao problema de classificação de faltas, prevalecem os métodos que utilizam treinamento supervisionado. Neste caso, é necessária a elaboração de um conjunto de padrões representativos e distintos (Base de Dados), o qual é dividido em três subconjuntos: treinamento, validação e teste. A partir da apresentação do *subconjunto de treinamento*, a rede é capaz de extrair as características de cada classe a ser identificada, adquirindo conhecimento do problema em questão. Essa fase é interrompida periodicamente para apresentação do *subconjunto de validação*. O objetivo desta fase é avaliar a qualidade do treinamento da rede através da monitoração do erro médio quadrático do subconjunto de validação. Espera-se que a rede adquira a capacidade de generalização, ou seja, a capacidade de classificar padrões similares aos já apresentados. Finalmente, para avaliar o desempenho da rede, aplica-se o *subconjunto de teste*, que é constituído de padrões distintos dos apresentados à rede até então, determinando-se a porcentagem de acerto alcançado na separação das classes desse conjunto.

No Projeto de P&D desenvolvido optou-se pela utilização das redes neurais artificiais do tipo perceptron de múltiplas camadas (redes MLP), a exemplo do que já vem sendo usada em projetos similares ao que se refere esta aplicação (5)-(6). A entrada da rede implementada utiliza os valores amostrados de tensão e corrente nas três fases, tendo em vista que esta informação está disponível nos registros dos canais analógicos dos RDP. A saída da rede é a indicação do tipo de falta referente às amostras apresentadas como sinais de entrada. Essa indicação foi feita utilizando-se codificação binária positiva para a saída da rede, conforme apresentado na Tabela 1. Além da situação de falta, a rede também deve ser capaz de identificar a situação de operação normal do sistema. É necessário então, que a Base de Dados contenha padrões relativos às situações de falta e normal. Logo, o problema de classificação de faltas em linhas de transmissão consiste na separação de onze classes distintas.

Um dos principais problemas envolvendo aplicações de redes neurais está na elaboração das Bases de Dados, pois é necessária uma grande quantidade de padrões para se realizar um treinamento adequado da rede neural. A etapa de construção das Bases de Dados pode ser bastante trabalhosa e até mesmo difícil de ser realizada. A metodologia desenvolvida para construção das Bases de Dados para treinamento de redes neurais artificiais aplicadas ao problema de diagnóstico de faltas, visa simplificar e automatizar o processo de construção. Esta metodologia é apresentada a seguir.

**TABELA 1 – Respostas desejadas da rede neural**

Tipo de Falta	Fase A saída 1	Fase B saída 2	Fase C saída 3	Terra saída 4
AT	1	0	0	1
BT	0	1	0	1
CT	0	0	1	1
AB	1	1	0	0
AC	1	0	1	0
BC	0	1	1	0
ABT	1	1	0	1
ACT	1	0	1	1
BCT	0	1	1	1
ABC	1	1	1	0
normal	0	0	0	0

### 3.0 - METODOLOGIA DE CONSTRUÇÃO DE BASES DE DADOS

O passo inicial na construção de uma Base de Dados é a escolha do sistema elétrico. No caso deste Projeto, o sistema escolhido como protótipo foi o sistema leste da CHESF, mais precisamente, uma das linhas de transmissão entre as subestações de Campina Grande II (CGD) e Natal II (NTD). Essa linha, denominada 04V4, é de classe 230 kV e possui uma extensão de aproximadamente 190 km (Figura 1).

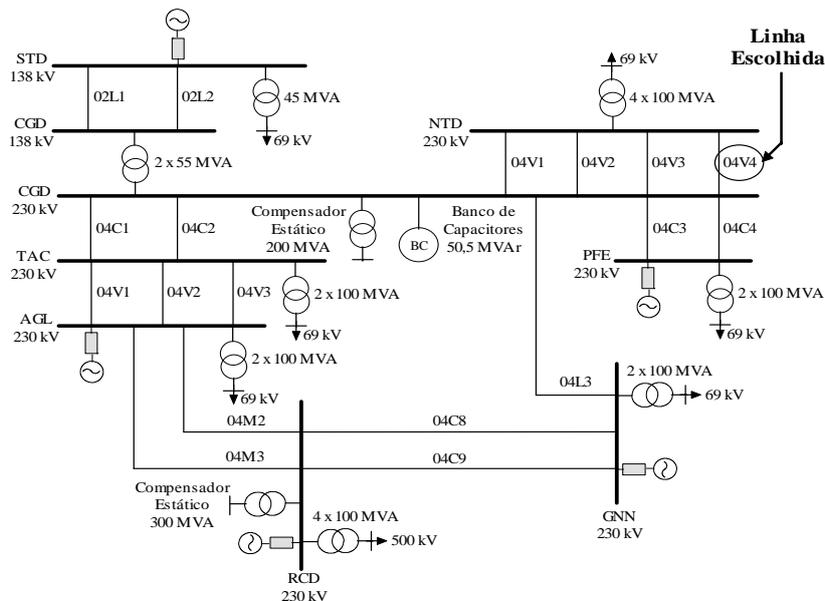


FIGURA 1 - Diagrama unifilar do sistema leste da CHESF.

A etapa seguinte é a modelagem do sistema elétrico. O passo inicial consiste na escolha do software para simulação do sistema elétrico. No caso deste Projeto de P&D escolheu-se o software ATP devido a sua potencialidade e por ser amplamente utilizado pelas empresas do setor elétrico, em particular, a CHESF. No ATP o sistema de transmissão é modelado fazendo-se uso da rotina LINE CONSTANTS. Estudos realizados mostraram que o uso de modelos a parâmetros distribuídos constantes na frequência para as linhas de transmissão pode ser adotado sem perda de eficiência para o processo de aprendizagem da rede neural (7). Sendo assim, esse foi o modelo adotado.

O passo seguinte é a escolha das variáveis de simulação. O Neurabase<sup>®</sup> considera as seguintes variáveis: distância da ocorrência da falta, resistência de falta, ângulo de incidência da falta e tipo de falta. Para o sistema elétrico escolhido, considerou-se:

- Falhas: AT-BT-CT-AB-AC-BC-ABT-ACT-BCT-ABC.
- Resistências de falta fase-terra: 50  $\Omega$  e 100  $\Omega$ .
- Resistências de falta fase-fase: 5  $\Omega$  e 10  $\Omega$ .
- Ângulos de incidência: 30° e 60°.

- Os locais de ocorrência das faltas (em km, a partir da subestação CGD) são de acordo com as etapas de:
  - a) Treinamento: 20, 30, 50, 60, 80, 90, 110, 120, 140, 150;
  - b) Validação: 40, 100, 160, 180;
  - c) Teste: 10, 70, 130, 170.

Na notação adotada, uma falta tipo AT, por exemplo, significa uma falta envolvendo a fase A e a terra.

As diversas combinações dessas variáveis originam um conjunto de cenários de faltas distintos, do qual a rede neural extrai o conhecimento. Para simular cada um dos cenários de falta, considerou-se um esquema de faltas deslizantes, contemplando várias localizações de falta ao longo da linha de transmissão (8). A linha de transmissão foi subdividida em trechos de 10 km, totalizando 19 trechos entre as subestações CGD e NTD. Esta divisão em trechos de mesmo comprimento teve como objetivo facilitar a automatização do processo de construção das Bases de Dados, tornando possível aplicar faltas em vários pontos da linha. Tendo em vista esta subdivisão da linha de transmissão, alguns parâmetros para simulação digital, como passo de tempo e o tempo máximo de simulação, têm de ser definidos levando-se em conta: o tempo de trânsito das linhas de transmissão (cerca de 33,0  $\mu$ s para um trecho de 10,0 km), o tamanho dos arquivos de dados, e o número de arquivos a compor a Base de Dados. No caso do sistema escolhido, são 720 cenários, distribuídos nos conjuntos de treinamento, validação e teste.

Cada um dos cenários é representado por um conjunto de arquivos no formato COMTRADE (9). Esse procedimento é feito para manter a compatibilidade com o formato dos arquivos de registros gerados pelos RDP. Os registros de ocorrências padronizados neste formato são armazenados em arquivos de três tipos, com extensões *.cfg*, *.hdr* e *.dat*. Esses arquivos contêm informações sobre os canais analógicos e digitais dos RDP, nome da subestação onde o registrador está instalado e informações referentes ao equipamento que está sendo monitorado. Os valores registrados de tensão e corrente do sistema (informações dos canais analógicos) estão disponíveis no arquivo com extensão *.dat*.

Além das variáveis já citadas, é necessário definir a taxa de amostragem do RDP. Atualmente, existem na rede de oscilografia da CHESF, RDP com várias taxas de amostragem. Estudos realizados mostraram que uma taxa de amostragem de 1.200 Hz (taxa compatível com um tipo de registrador existente no sistema da empresa) é suficiente para preservar as principais características dos sinais de tensões e correntes analisados (10).

Uma etapa importante em aplicações envolvendo redes neurais é a etapa de normalização dos dados. Neste caso, a normalização foi feita nas amostras de tensão e corrente, de modo que estas permaneçam no intervalo [-1,1]. Realizou-se também uma mistura aleatória dos padrões da Base de Dados. Esse procedimento é importante, visto que pode ocorrer uma tendência no reajuste dos pesos durante a fase de treinamento da rede, ocasionando uma perda da capacidade de generalização da mesma (6).

Para que a Base de Dados possa ser apresentada à rede neural é necessária a sua conversão para um arquivo de dados com formato entendido pela rede, o qual foi adotado com extensão *.net*. Essa conversão foi denominada de *janelamento*: um conjunto de linhas do arquivo *.dat* no formato COMTRADE, denominado de *janela*, é agrupado em apenas uma linha no formato do arquivo *.net*. O tamanho adotado para a janela é de 5 (cinco) linhas, ou seja, cinco amostras consecutivas de tensão e corrente das três fases e da componente de seqüência zero. Esse processo é ilustrado na Figura 2. A janela de dados é tida como móvel, já que percorre todo o arquivo, deslocando-se ao passo de uma amostra. Nesse processo, uma janela corresponde a um tipo de falta se todas suas amostras também corresponderem ao mesmo tipo (11).

O janelamento se aplica a todos os arquivos *.dat* gerados na construção da Base de Dados. Cada padrão da Base é constituído de dois vetores:

- O primeiro com 40 elementos (5 amostras de tensão e corrente para cada fase e 5 amostras para as tensões e correntes de seqüência zero) é referente ao vetor de entrada para a rede.
- O segundo, referente ao vetor de saída da rede, indica o tipo de falta correspondente ao vetor de entrada, conforme Tabela 1.

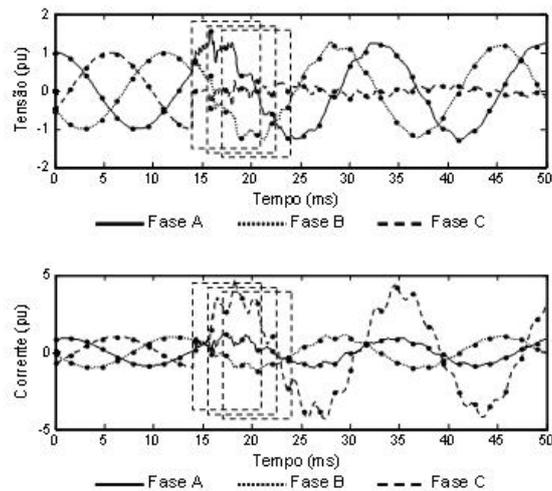


FIGURA 2 – Processo de janelamento dos sinais de tensão e corrente.

#### 4.0 - AUTOMATIZAÇÃO DO PROCESSO DE CONSTRUÇÃO DE BASES DE DADOS

Na metodologia desenvolvida para construção das Bases de Dados, o software ATP é utilizado para simular os diversos cenários de falta desde a condição de operação normal do sistema, até alguns ciclos após a ocorrência da falta. Para gerar os diversos cenários de falta, as variáveis de simulação são ajustadas no corpo do arquivo de entrada do programa ATP (com extensão **.atp**).

Como os dados gerados pelo ATP não obedecem à formatação IEEE COMTRADE, desenvolveu-se uma rotina no formato MODELS do programa ATP. A metodologia adotada foi a seguinte:

- Extração dos valores de tensão e corrente gerados pelo ATP na frequência de amostragem desejada.
- Criação de um arquivo, para cada cenário de falta, com os dados convertidos para um formato similar ao formato COMTRADE.

Apesar de estarem em um formato similar ao COMTRADE, os dados que devem ser inteiros são escritos pela rotina MODELS como variáveis reais.

A automatização propriamente dita, iniciou-se com a implementação de um *conversor*: uma rotina escrita em C++ que lê os dados em números reais, converte-os em números inteiros e escreve-os em um novo arquivo, agora no formato COMTRADE.

Mediante a criação de um arquivo para processamento em *lote (batch file)*, a simulação de todos os casos definidos nos arquivos *.atp* passou a ser realizada automaticamente. Este arquivo em lote visa:

- Ordenar as tarefas a serem executadas pelo ATP e conversor.
- Nomear de forma sistemática cada arquivo de saída, de acordo com os cenários de falta.

Após diversos estudos, verificou-se a possibilidade de tornar o processo de construção das Bases ainda mais prático. Optou-se então, por concentrar as variáveis de simulação de cada caso no *início* do arquivo *.atp* fazendo-se uso da função \$PARAMETER do ATP. Com esta rotina foi possível transformar as *constantes* de cada caso (resistências de falta, ângulo de incidência, etc) em *variáveis*.

Na Figura 3 é apresentado o esquema de faltas deslizantes com a notação adotada para uso da função \$PARAMETER, sendo:

- A, B, e C: condutores das fases do sistema de transmissão analisado.
- LOC\_\_A, LOC\_\_B e LOC\_\_C: locais de ocorrência da falta.
- TERMA, TERMB, TERMC e COMUM: nós de conexão das chaves e resistências.
- RFASES\_AB, RFASES\_BC, RFASES\_AC e RTERRA: valores de resistência de falta.
- T\_FASE\_A, T\_FASE\_B, T\_FASE\_C e T\_TERRA: instante de tempo em que cada chave deve ser fechada.

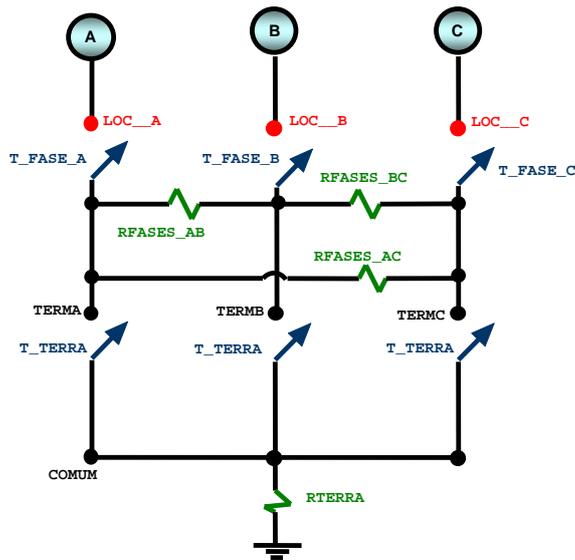


FIGURA 3 - Representação esquemática das variáveis de simulação.

Para as várias situações de falta:

- Os locais de ocorrência da falta devem variar ao longo da linha de transmissão e serem definidos nas extremidades de cada um dos trechos de 10 km, os quais compõem a linha.
- Os valores das variáveis referentes às resistências de falta devem ser alterados de acordo com o desejado. Para o caso de circuito aberto deve-se assumir valor bastante elevado (1000 G $\Omega$ , por exemplo).

O instante de tempo no qual cada chave envolvida com a falta é fechada concorda com o ângulo de incidência escolhido, tendo como referência a fase A. Para as fases não envolvidas, atribui-se o instante de fechamento superior ao tempo de simulação. Neste caso, as chaves permanecem abertas durante a execução do programa.

A modelagem do sistema elétrico resulta num arquivo *modelo.atp* (12) que serve de *molde* para a construção dos demais arquivos. Com a metodologia desenvolvida, os arquivos que representam os diversos cenários de falta diferem do arquivo *modelo* apenas nas variáveis de simulação, as quais são definidas dentro da função \$PARAMETER. Este procedimento foi decisivo no processo de simplificação da construção das Bases. Apesar da simplificação obtida, esse processo ainda demandava esforço manual considerável, sendo repetitivo e sujeito a erros.

A automatização do processo de construção dos arquivos *.atp*, para cada cenário de falta, representou um ponto crucial para a formação das Bases de Dados. Até então, esses arquivos eram gerados *manualmente*, de acordo com a combinação das variáveis de simulação adotadas para a construção das Bases. De forma análoga, o arquivo em lote também era gerado manualmente. Como consequência, tais tarefas demandavam tempo significativo. Eram necessários vários dias, ou até mesmo semanas, para construção de apenas uma Base de Dados, além de muito esforço manual.

A automatização implementada através do software Neurabase<sup>®</sup> resultou numa redução drástica do tempo e dos esforços despendidos. Atualmente, o processo de construção das Bases de Dados pode ser resumido no fluxograma apresentado na Figura 4.

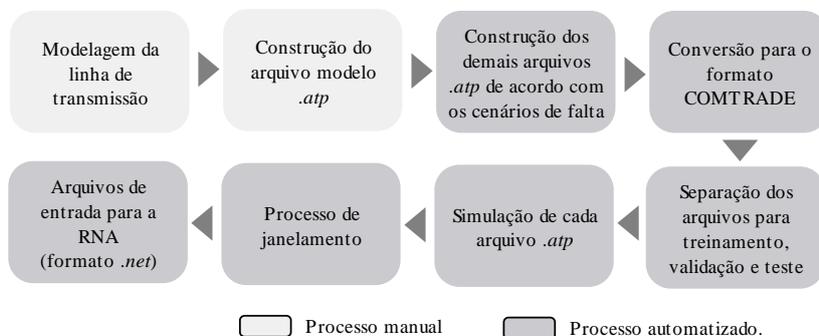


FIGURA 4 – Processo de construção de Bases de Dados.

## 5.0 - O SOFTWARE NEURABASE<sup>®</sup>

Os estudos relacionados ao software ATP, em particular às rotinas \$PARAMETER e MODELS, conduziram a construção do software Neurabase<sup>®</sup>, utilizando a linguagem de programação C++ com programação orientada a objetos (POO) e a plataforma de desenvolvimento MFC (*Microsoft<sup>®</sup> Foundation Class*). O Neurabase<sup>®</sup> disponibiliza interfaces gráficas amigáveis para o usuário, sendo uma delas apresentada na Figura 5.

O princípio de funcionamento do software baseia-se no fornecimento das variáveis de simulação para construção das Bases de Dados e de um arquivo modelo .atp. De posse dessas informações, o software gera um arquivo .atp para cada cenário de falta, faz uso indireto do ATP para simular cada um destes cenários e fornece como resultado final, os arquivos (para treinamento, validação e teste da rede) no formato .net.



FIGURA 5 – Interface para separação dos conjuntos de treinamento, validação e teste.

## 6.0 - CONCLUSÃO

Os estudos realizados no Projeto de P&D desenvolvido mostraram a viabilidade do uso das redes neurais artificiais ao problema de diagnóstico de faltas em linhas de transmissão. No entanto, a necessidade de uma Base de Dados para o treinamento da rede neural dificulta sua utilização, visto que é necessário um grande volume de dados para contemplar um treinamento adequado.

No caso de diagnóstico de faltas em sistemas elétricos de potência, é possível se obter Bases de Dados por meio de simulação computacional. Entretanto, o processo de construção manual é trabalhoso e demorado, além de estar sujeito a erros. Com o Neurabase<sup>®</sup>, a geração das Bases de Dados é feita de forma rápida, eficiente e sem erros. Por conta da sua versatilidade, o Neurabase<sup>®</sup> pode ser aplicado a qualquer sistema elétrico de potência.

Após o término do Projeto de P&D, algumas contribuições do Neurabase<sup>®</sup> já foram obtidas, como por exemplo o uso do Neurabase<sup>®</sup> para:

- Avaliar a influência do modelo de linhas de transmissão no diagnóstico de faltas.
- Avaliar a influência da frequência de amostragem dos RDP no diagnóstico de faltas
- Treinar redes neurais artificiais utilizadas para localizarem faltas em linhas de transmissão.

Além das aplicações relacionadas à pesquisa referente ao Projeto de P&D desenvolvido, o Neurabase<sup>®</sup> pode ser utilizado na aferição de equipamentos, tais como relés e RDP, dentre outras aplicações.

## 7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) Manual do Neuranálise<sup>®</sup>, ATECEL/UFMG – CHESF, julho de 2004.
- (2) J. J. Grainger and W. D. Stevenson, Power System Analysis, New York: McGraw-Hill Science/Engineering/Math, 1994.

- (3) T. Dalstein and B. Kulieke, "Neural network approach to fault classification for high speed protective relaying", IEEE Trans. On Power Delivery, vol. 10, pp. 1002-1009, Apr. 1995.
- (4) E. A. Mohamed and N. D. Rao, "Artificial neural network based fault diagnostic system for electric power distribution feeders", Electric Power Systems Research, vol. 35, pp. 1-10, Feb. 1995.
- (5) M. Oleskovicz, D. V. Coury e R. K. Aggarwal, "Redes neurais artificiais aplicadas à classificação de faltas em sistemas de elétricos de potência", Revista SBA Controle & Automação, v. 11, n. 3, dezembro de 2000.
- (6) D. V. Coury e R. Giovanini, "Classificação rápida de faltas em sistemas elétricos utilizando redes neurais artificiais", IV Brazilian Conference on Neural Networks, 1999, pp. 281-286.
- (7) B. A. Souza, Influência do Modelo de Linhas de Transmissão no Diagnóstico de Faltas, IEEE/PES T&D 2004 Latin America, São Paulo.
- (8) B. A. Souza, N. S. D. Brito, W. L. A. Neves, A. B. Fernandes, S. S. B. Silva, K. M. Silva, K. M. C. Dantas, A. V. Fontes e F. B. Costa, "Classificação de faltas via redes neurais artificiais", V Seminário Brasileiro sobre Qualidade da Energia Elétrica, 2003.
- (9) IEEE Standard Common Format for Transient Data exchange (COMTRADE) for Power Systems, IEEE PES (C37.111-1991), Oct. 1991.
- (10) B. A. Souza, Influência da Frequência de Amostragem dos Registradores Digitais de Perturbação no Diagnóstico de Faltas, IEEE/PES T&D 2004 Latin America, São Paulo.
- (11) B. A. Souza, N. S. D. Brito, W. L. A. Neves, K. M. Silva, R. B. V. Lima and S. S. B. Silva, "Comparison between backpropagation and RPROP algorithms applied to fault classification in transmission lines", In Proc. 2004 International Joint Conference on Neural Networks.
- (12) Guia para Construção de Bases de Dados, ATECEL/UFCG – CHESF, julho de 2004.

## 8.0 - GRUPO DE TRABALHO

### Grupo de Sistemas Elétricos – Departamento de Engenharia Elétrica – Universidade Federal de Campina Grande:

- Benemar Alencar de Souza.
- Núbia Silva Dantas Brito.
- Washington Luis Araújo Neves.
- Karcus Marcelus Colaço Dantas.
- Alessandro Viana Fontes

### Companhia Hidro-Elétrica do São Francisco – CHESF:

- Sandra Sayonara Bispo da Silva

### Operador Nacional do Sistema – ONS:

- Alécio Barreto Fernandes