



Universidade Federal de Campina Grande

Centro de Ciências e Tecnologia

Departamento de Engenharia Elétrica

Grupo de Sistemas Elétricos



Influência do Modelo de Linhas de Transmissão no Diagnóstico de Faltas

Trabalho de Conclusão de Curso

Aluno: Karcius M. C. Dantas

Orientadora: Núbia S. D. Brito

Campina Grande, Fevereiro de 2005.



Biblioteca Setorial do CDSA. Fevereiro de 2021.

Sumé - PB

Universidade Federal de Campina Grande
Centro de Ciências e Tecnologia
Departamento de Engenharia Elétrica
Grupo de Sistemas Elétricos

Influência do Modelo de Linhas de Transmissão no Diagnóstico de Faltas

Karcius M. C. Dantas

Karcius M. C. Dantas
Aluno

Núbia S. D. Brito

Núbia S. D. Brito
Orientadora

Campina Grande, fevereiro de 2005

Índice

1.	Apresentação	3
2.	Revisão Bibliográfica	3
2.1	Métodos de Simulação de Transitórios eletromagnéticos	4
2.2	Modelos de Linhas de Transmissão	6
2.3	RNA e o Problema de Classificação de Faltas	7
3.	O Neuranálise [©]	9
4.	Sensibilidade da RNA quanto ao Modelo de Linha	10
5.	Aplicação da RNA ao Sistema CHESE.....	14
6.	Conclusões	17
7.	Referências Bibliográficas	17
	Anexos.....	19

1. Apresentação

Este Trabalho de Conclusão de Curso (TCC) tem como objetivo avaliar a sensibilidade do software Neuranálise[©] em relação ao modelo adotado para as linhas de transmissão. O software Neuranálise[©] foi desenvolvido pelo Grupo de Sistemas Elétricos (GSE) do Departamento de Engenharia Elétrica (DEE) da Universidade Federal de Campina Grande (UFCG) e pela Companhia Hidrelétrica do São Francisco (CHESF), mediante um Projeto de Pesquisa e Desenvolvimento (P&D) intitulado Implantação de Técnicas de Inteligência Artificial para Identificação e Análise de Ocorrências no Sistema Elétrico.

O Neuranálise[©] é um software identificador e classificador de faltas em linhas de transmissão de energia elétrica. O software utiliza redes neurais artificiais (RNA) e transformada wavelet e tem como dados de entrada os valores de tensão e corrente provenientes dos canais analógicos dos Registradores Digitais de Perturbação (RDP).

A motivação deste TCC baseou-se no seguinte questionamento:

Como o Neuranálise[©] se comportará quando suas Bases de Dados forem construídas com modelos a parâmetros constantes na freqüência, se os dados amostrados pelos RDP contêm, inherentemente, os efeitos da dependência dos parâmetros das linhas com a freqüência?

O estudo realizado para avaliar esta questão é apresentado a seguir.

2. Revisão Bibliográfica

Apresenta-se a seguir uma breve revisão bibliográfica sobre:

- Modelos e métodos de simulação de linhas de transmissão.
- Redes neurais artificiais aplicadas ao problema de classificação de faltas.

2.1 Métodos de Simulação de Transitórios eletromagnéticos

O comportamento dinâmico de um sistema elétrico é descrito por equações diferenciais. No entanto, devido ao alto grau de complexidade dos sistemas reais, uma solução analítica torna-se praticamente impossível. Ao longo dos anos, várias ferramentas têm sido usadas para estudar o comportamento dinâmico do sistema elétrico, comumente denominado de transitórios eletromagnéticos.

No passado, modelos de sistemas elétricos em miniatura conhecidos como analisadores de rede, foram bastante utilizados. Devido ao aumento da capacidade de processamento e a disponibilidade de excelentes ferramentas computacionais, a simulação digital ganhou um espaço nunca antes imaginado e o uso de modelos matemáticos, um significado expressivo frente a este novo paradigma. A obtenção de modelos matemáticos precisos e eficientes tem crescido em importância, demandando investimentos cada vez mais significativos. Atualmente, o computador digital é a ferramenta mais difundida, embora os analisadores de rede ainda sejam utilizados.

Os programas desenvolvidos podem ser classificados em dois grandes grupos, de acordo com a técnica de solução utilizada: programas no domínio da freqüência e programas no domínio do tempo.

Programas no domínio da freqüência (FDTP)¹: com programas desta classe, a resposta transitória do sistema em análise é calculada no domínio da freqüência. A solução no domínio do tempo é determinada fazendo-se uso de transformações inversas, como a transformada rápida de Fourier, por exemplo. A incapacidade de simular mudanças súbitas na configuração do sistema ao longo da análise e a dificuldade em representar elementos não lineares, se constituem nas maiores limitações destes programas.

Programas no domínio do tempo (EMTP)²: com programas desta classe, a solução é determinada para cada passo de tempo Δt , em geral prefixado.

¹ FDTP – Frequency Domain Transients Program.

² EMTP – Electromagnetic Transients Program.

Partindo-se das condições iniciais em $t = t_0$, as tensões em cada nó do sistema em análise são determinadas em $t = (t_0 + \Delta t), (t_0 + 2\Delta t), (t_0 + 3\Delta t), \dots$, até o tempo máximo de simulação $t_{máx}$.

No processo de cálculo das tensões e correntes em cada terminal, se faz necessário conhecer as tensões e correntes em instantes de tempo anteriores, ou seja, a história do sistema. Mudanças súbitas na configuração do sistema (como defeitos, abertura e fechamento de disjuntores, etc.) e a presença de elementos não lineares, podem ser modelados sem muita dificuldade [1].

Os programas no domínio do tempo combinam modelos e técnicas de solução, representando diferentes componentes de um sistema elétrico e seus inter-relacionamentos. Um programa do tipo EMTP modela cada componente no domínio do tempo através de admitâncias (ou impedâncias) equivalentes e fontes de corrente ou tensão históricas, obtidas dos modelos matemáticos quando uma dada técnica de integração numérica é aplicada.

A grande maioria dos métodos de solução no domínio do tempo se baseia na aplicação da regra de integração trapezoidal para a representação de elementos a parâmetros concentrados e no método das características também conhecido como método de Bergeron, para a representação de elementos a parâmetros distribuídos [2].

Para estudos de transitórios eletromagnéticos, os programas que utilizam a técnica de resolução no domínio do tempo, são seguramente os mais difundidos e utilizados dada sua facilidade. Atualmente, existem diversos programas comerciais do tipo EMTP, a exemplo do MICROTRAN® [3] e do ATP® [4].

Esses programas disponibilizam modelos computacionais para os mais diversos componentes de sistemas elétricos de potência. As condições iniciais podem ser determinadas automaticamente pelo programa ou podem ser fornecidas pelo usuário.

Os programas do tipo EMTP também podem ser usados para obter soluções fasoriais de regime permanente, em uma certa freqüência ou em uma

faixa de freqüência desejada. Os usuários podem criar seus próprios modelos e fazer a interação com o programa principal.

2.2 Modelos de Linhas de Transmissão

Dentre todos os componentes dos sistemas elétricos de potência, as linhas de transmissão se destacam por duas particularidades: seus parâmetros são distribuídos ao longo de sua extensão e apresentam forte dependência da freqüência [5]. Além disso, estão presentes nos sistemas de potência mais simples.

A propagação de ondas em linhas de transmissão não é um fenômeno físico simples de ser representado matematicamente, pois é sujeita a atenuação, distorção e atraso entre tensões (e correntes) em terminais opostos, que por sua vez dependem das características da linha e das ondas que nela se propagam. Modelar de forma precisa o fenômeno físico da propagação de ondas em linhas de transmissão tem sido um desafio no desenvolvimento de ferramentas computacionais para estudos de transitórios eletromagnéticos. Ao longo dos anos este tema tem sido alvo de diversos estudos, dos quais resultaram valiosas contribuições. O objetivo comum desses estudos tem sido modelar o comportamento dinâmico da linha de forma precisa e eficiente.

Um aspecto importante em estudos de transitórios é o fato de um componente físico poder ter diferentes representações, de acordo com o contexto da análise. Ou seja, uma linha de transmissão pode ser representada por um circuito a parâmetros concentrados, como uma associação de resistores, indutores e capacitores, ou por um modelo matemático mais complexo que considere o atraso existente entre tensões (e correntes) em terminais opostos e a dependência de seus parâmetros com a freqüência. Devido às suas peculiaridades, as linhas de transmissão podem ser modeladas de diferentes formas, de acordo com a precisão e a eficiência necessárias.

Quanto à natureza distribuída de seus parâmetros, as linhas de transmissão podem ser representadas por:

Modelos a parâmetros concentrados: a linha de transmissão é representada por resistores, indutores e capacitores, usualmente em uma conexão cascata de seções π , cujos valores são calculados para uma determinada freqüência. A validade destes modelos para análise de transitórios, se restringe a linhas curtas, aproximadamente 15 km. É importante ressaltar que, em geral, apresentam respostas em freqüência precisas, unicamente nas vizinhanças da freqüência na qual seus parâmetros foram calculados [6].

Modelos a parâmetros distribuídos: nesse caso, a natureza distribuída dos parâmetros da linha é levada em consideração através do princípio da propagação de ondas. Um distúrbio se propaga sujeito a atenuações até ser refletido nos terminais da linha, existindo um atraso entre tensões (e correntes) em terminais opostos. É importante ressaltar que o passo de tempo da simulação deve ser inferior ao tempo de propagação da linha. Quanto à dependência de seus parâmetros com a freqüência, distinguem-se duas classes de modelos de linhas de transmissão:

Modelos a parâmetros constantes na freqüência: a dependência da freqüência dos parâmetros da linha de transmissão é desprezada. Os parâmetros da linha são calculados em uma única freqüência.

Modelos a parâmetros dependentes da freqüência: representam com maior precisão o fenômeno físico da propagação de ondas, pois consideram os efeitos da freqüência sobre seus parâmetros, que podem ser calculados para uma extensa faixa de freqüência.

Linhos de transmissão polifásicas podem ainda, serem modeladas no domínio modal ou no domínio de fases.

2.3 RNA 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 [7]. Alternativamente, métodos de inteligência artificial vêm sendo propostos para solucionar esse problema e dentre eles, destacam-se as RNA. Os métodos baseados em RNA têm apresentado desempenho superior aos métodos analíticos tradicionais, no que diz respeito à velocidade, precisão e robustez no diagnóstico [8]-[9].

Nas aplicações das RNA 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, o qual é comumente denominado de *Base de Dados*. Esse conjunto é dividido em três subconjuntos: treinamento, validação e teste. A partir da apresentação do subconjunto de treinamento, a RNA é capaz de extrair as características de cada classe a ser identificada, adquirindo *conhecimento* sobre o problema em questão [10]. A etapa de treinamento é interrompida periodicamente para apresentação do subconjunto de validação. O objetivo desta etapa é avaliar a *qualidade* do treinamento da RNA através da monitoração do erro médio quadrático do subconjunto de validação. Espera-se que a RNA adquira a capacidade de generalização, ou seja, a capacidade de classificar padrões similares aos já apresentados. Finalmente, para avaliar o *desempenho* da RNA, aplica-se o subconjunto de teste, que é constituído de padrões distintos dos apresentados à RNA até então, determinando-se a porcentagem de acerto alcançado na separação das classes desse conjunto.

Na aplicação em questão, a entrada da rede neural são os valores amostrados de tensão e corrente nas fases da linha, junto com as componentes de seqüência zero. A saída da RNA é a indicação do tipo de falta referente às amostras apresentadas como sinais de entrada [11]. A codificação adotada foi a binária positiva conforme apresentada na Tabela 1.

Tabela 1 - Respostas desejadas para a RNA.

tipo de falta	resposta esperada			
	S ₁	S ₂	S ₃	S ₄
Fase A - terra	1	0	0	1
Fase B - terra	0	1	0	1
Fase C - terra	0	0	1	1
Fases AB	1	1	0	0
Fases AC	1	0	1	0
Fases BC	0	1	1	0
Fases AB - terra	1	1	0	1
Fases AC - terra	1	0	1	1
Fases BC - terra	0	1	1	1
Fases ABC	1	1	1	0

3. O Neuranálise[©]

O Neuranálise[©] 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[©] baseou-se no uso da transformada wavelet e das redes neurais artificiais, sendo constituído por três módulos:

- Neurabase[©]: módulo de geração da Base de Dados a ser utilizada no aprendizado da rede neural. Possui uma interface gráfica e utiliza o software ATP para simulação dos diversos cenários de falta.
- Neuraredede[©]: módulo de construção e treinamento da rede neural. Possui uma interface gráfica e utiliza a Base de Dados construída pelo Neurabase[©].
- Neurareg[©]: módulo de análise e triagem de registros. Utiliza a transformada wavelet e uma rede neural, previamente treinada com o Neuraredede[©].

4. Sensibilidade da RNA quanto ao Modelo de Linha

Para avaliar a sensibilidade da RNA em relação ao modelo da linha de transmissão, adotou-se uma linha de transmissão trifásica fictícia, classe 440 kV, não transposta, com quatro condutores geminados por fase e dois cabos pára-raios, com extensão de 330 km, conforme esquematizada nas Figuras 1 e 2 [9].

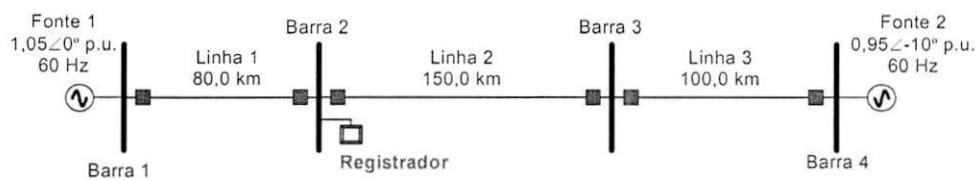


Figura 1 – Sistema fictício.

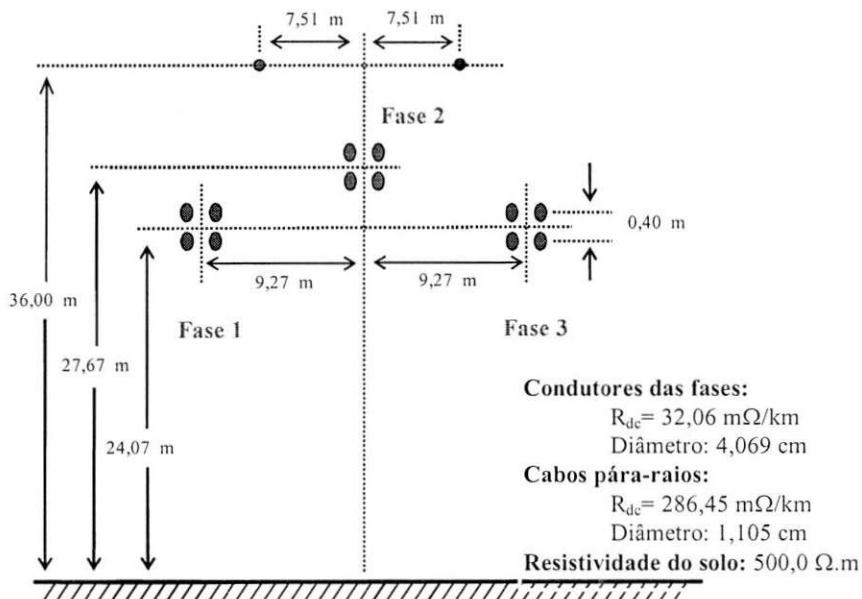


Figura 2 - Linha de transmissão trifásica do sistema-teste.

A linha de transmissão foi simulada empregando-se o software ATP e considerando dois modelos:

- Modelo a parâmetros distribuídos *dependentes* da freqüência (modelo DF).
- Modelo a parâmetros distribuídos *constantes* na freqüência (modelo CF).

Um esquema de faltas deslizantes, contemplando várias localizações de falta ao longo da linha de transmissão foi utilizado [12].

Além da localização da falta, outras variáveis também foram consideradas para a geração das Bases de Dados, como a resistência de falta e o ângulo de incidência. As diversas combinações dessas variáveis originam um conjunto de cenários de falta distintos, do qual a RNA extrai o conhecimento. Cada um desses cenários é representado por um conjunto de arquivos padronizados no formato COMTRADE [13], emulando os registros provenientes dos RDP.

Foram construídos 1.920 cenários, distribuídos nos conjuntos de treinamento, validação e teste, conforme apresentado a seguir:

- Tipos de falta: AT-BT-CT-AB-AC-BC-ABT-ACT-BCT-ABC e situação sem falta.
- Freqüência de amostragem: 1.200 Hz.
- Resistências de falta fase-terra: 50 Ω e 100 Ω .
- Resistências de falta fase-fase: 5 Ω e 10 Ω .
- Ângulos de incidência: 30°, 60° e 80°.
- Os locais de aplicação das faltas (em km) são de acordo com as etapas de:
 - Treinamento: 10, 40, 60, 90, 110, 140, 160, 190, 210, 240, 260, 290 e 310.
 - Validação: 30, 80, 130, 180, 230 e 280.
 - Teste: 20, 50, 70, 100, 120, 150, 170, 200, 220, 250, 270, 300 e 320.

O tempo de simulação considerado para a situação de falta correspondeu a meio período da senóide de 60 Hz, o que resultou em 10 amostras de tensão e corrente em cada uma das fases, para cada cenário considerado.

Dentre as diversas arquiteturas de RNA existentes, optou-se pela utilização das *redes perceptron de múltiplas camadas* (ou redes MLP), a exemplo do que já vem sendo usado em trabalhos similares ao que se refere este trabalho [7]-[9]. A escolha da rede MLP foi feita baseada nos seguintes pontos:

- Tipo de rede mais utilizada nos trabalhos envolvendo classificação de faltas.
- Arquitetura consolidada e difundida em aplicações envolvendo redes neurais.
- O Projeto de P&D, no qual este TCC está inserido, se configurou como sendo um dos primeiros trabalhos do GSE a usar redes neurais.
- A duração deste Projeto de P&D de apenas dois anos, além da sua dimensão, não permitia incursões em métodos ainda não consolidados ou de difícil implementação.

Para o processo de aprendizado da RNA, utilizou-se o algoritmo de treinamento *resilient propagation* (RPROP), que é derivado do algoritmo *backpropagation* tradicional [14].

Várias topologias de redes MLP foram testadas, sendo que aquela que apresentou os melhores resultados na separação das classes foi a que continha uma única camada oculta com 50 neurônios. A camada de entrada possui 40 unidades sensoriais, por causa do janelamento empregado, enquanto a camada de saída apresenta apenas 4 neurônios, por conta da codificação binária adotada.

A RNA foi implementada com o *Neural Network Toolbox* do programa MATLAB® [15].

Na modelagem de linhas de transmissão, os modelos a parâmetros dependentes da freqüência (DF) representam com maior precisão o fenômeno físico da propagação de ondas, pois incluem os efeitos da freqüência em seus parâmetros. Os modelos a parâmetros constantes na freqüência (CF) são mais simples, porém menos precisos.

Para a construção de um modelo DF ou CF, é necessário o conhecimento de vários dados referentes à linha de transmissão em questão: diâmetro e disposição geométrica dos condutores, resistividade do solo, dentre outros. No caso de um sistema extenso como o da CHESF, com cerca de 18.000 km de linhas, teria de se dispor de um volume considerável de informações, as quais

não estão disponíveis. Além do mais, já se dispõe na CHESF de um banco de dados das linhas no formato ATP e modelo CF, o que torna imperativo o uso deste modelo para a construção das Bases de Dados para o Neuranálise[©].

Desta forma, para avaliar a sensibilidade das RNA ao modelo de linha de transmissão, utilizou-se modelos de linhas a parâmetros constantes na freqüência e dependentes da freqüência para modelar o sistema elétrico apresentado acima. Diferentes combinações foram avaliadas, alternando o tipo de modelo considerado nos conjuntos de treinamento, validação e teste:

- **Caso CF:** modelo CF aplicado aos conjuntos de treinamento, validação e teste.
- **Caso DF:** modelo DF aplicado aos conjuntos de treinamento, validação e teste.
- **Caso CDF:** modelo CF aplicado aos conjuntos de treinamento e validação e modelo DF, ao de teste.

Dependendo do modelo adotado, os padrões de tensão e corrente, podem conter informações bem distintas para um mesmo tipo de falta, conforme apresentado na Figura 3. Observa-se que o modelo DF é mais amortecido para as componentes de altas freqüências que o modelo CF. Esse fato pode influenciar decisivamente o desempenho da RNA na classificação do tipo de falta.

São apresentadas na Tabela 2 as porcentagens totais de acerto obtidas para cada um dos casos citados acima. De onde se conclui:

- A Base de Dados constituída por conjuntos (treinamento, validação e teste) construídos com modelo CF resulta na menor taxa de acerto (caso CF).
- O caso DF resultou no melhor desempenho da RNA.
- O caso CDF resultou num desempenho satisfatório (taxa de acerto de 96,34%), apesar dos seus conjuntos de treinamento e validação terem

sido construídos utilizando modelos CF, os quais são menos realísticos que os modelos DF.

Tabela 2 – Desempenho da RNA

Caso Analisado	Acerto (%)
CF	93,32
DF	96,66
CDF	96,34

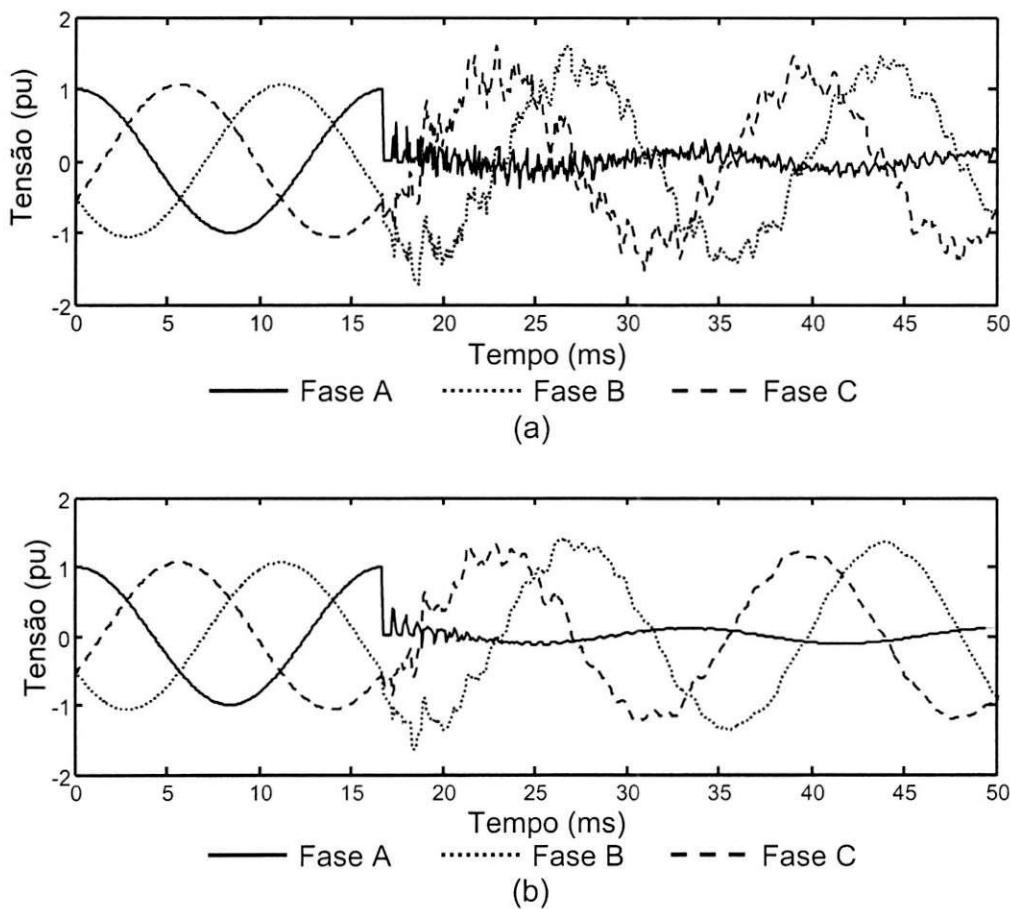


Figura 3 – Falta monofásica: (a) Modelo CF; (b) Modelo DF.

5. Aplicação da RNA ao Sistema CHESF

Para aplicação da RNA ao sistema CHESF, adotou-se a linha de transmissão trifásica 04V4, classe 230 kV com extensão de 188 km, situada entre as subestações de Campina Grande II e Natal II, conforme ilustrado nas Figuras 4 e 5.

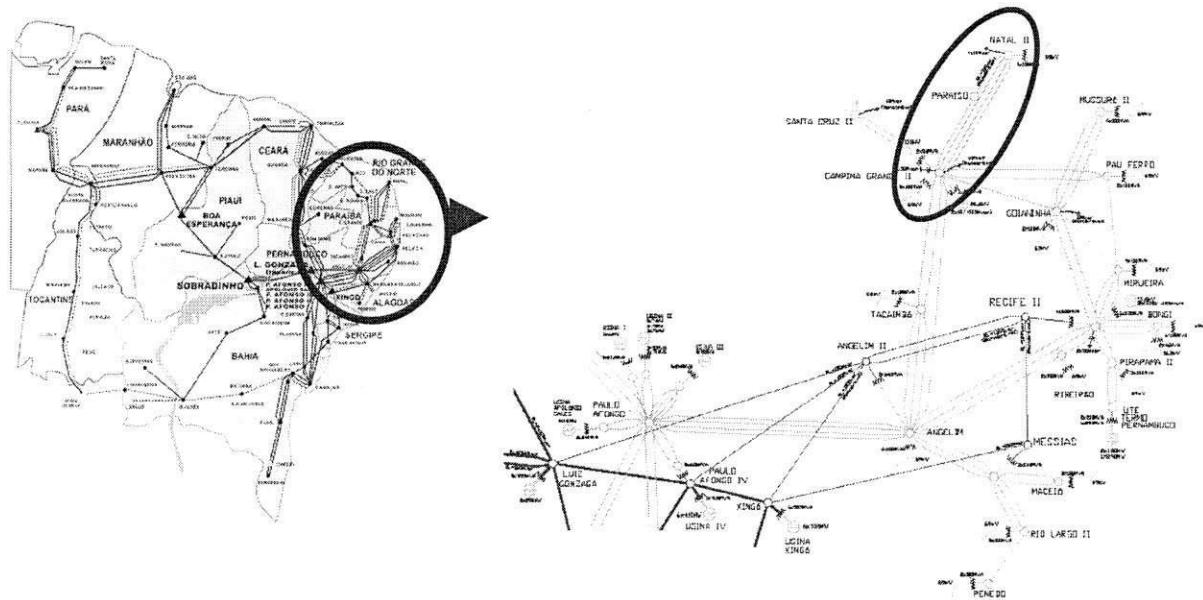


Figura 4 – Sistema leste da Chesf.

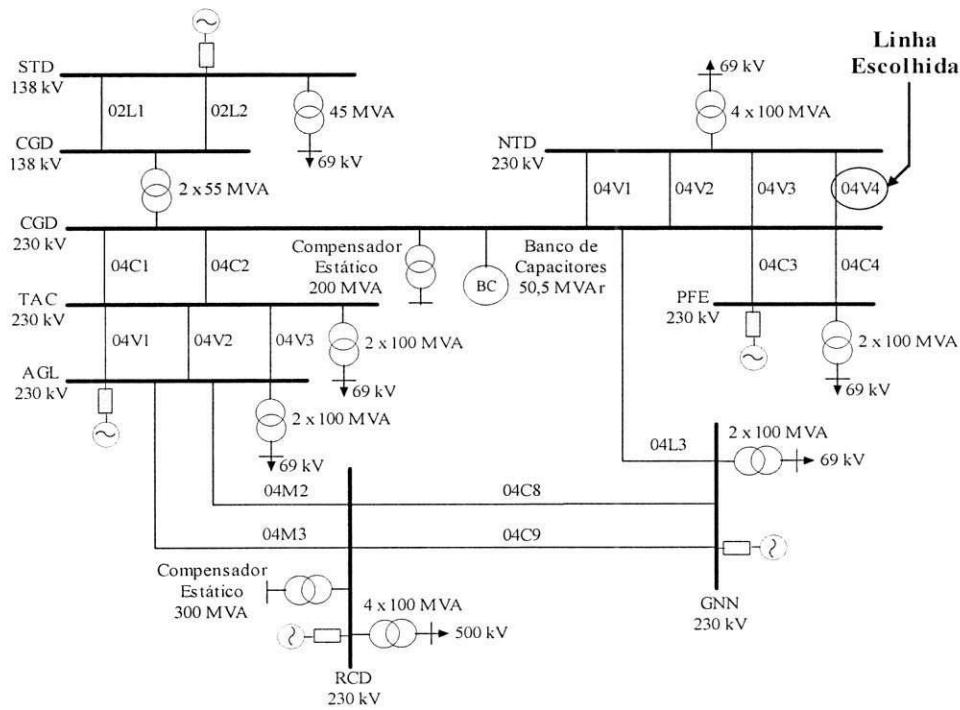


Figura 5 - Diagrama unifilar do sistema leste (reduzido) da CHESF.

A linha de transmissão foi modelada a parâmetros distribuídos constantes na freqüência.

A construção da Base de Dados para o sistema CHESF foi realizada utilizando o mesmo procedimento apresentado anteriormente. Os diversos cenários de falta foram criados conforme apresentado a seguir.

- Faltas: AT-BT-CT-AB-AC-BC-ABT-ACT-BCT-ABC.
- Freqüência de amostragem: 1.200 Hz.
- Resistências de falta fase-terra: 50 Ω e 100 Ω.
- Resistências de falta fase-fase: 5 Ω e 10 Ω.
- Ângulos de incidência: 30º e 60º.
- Os locais de aplicação das faltas (em km) são de acordo com as etapas de:
 - Treinamento: 20, 30, 50, 60, 80, 90, 110, 120, 140, 150.
 - Validação: 40, 100, 160, 180.
 - Teste: 10, 70, 130, 170.

Na avaliação do desempenho da RNA, foram simulados 160 cenários de falta para a criação do conjunto de teste, sendo cada um deles representado por um conjunto de arquivos que emula o registro real de um RDP.

Utilizando-se a mesma topologia da RNA apresentada, foram obtidas as porcentagens de acerto, apresentadas na Tabela 3. Considerando todas as faltas, o acerto foi de 99,74%.

Tabela 3 – Acerto na classificação dos registros do conjunto de teste

Tipo de Falta	Acerto (%)
AT	100,00
BT	100,00
CT	98,61
AB	98,61
AC	100,00
BC	100,00
ABT	100,00
ACT	100,00
BCT	100,00
ABC	100,00
sem falta	100,00
Média	99,74

6. Conclusões

Os resultados obtidos comprovam a eficiência das RNA, em particular das redes MLP, em resolver o problema de classificação de faltas. Obteve-se acerto médio de 99,74% na classificação dos tipos de falta contidas nos registros no conjunto de teste do sistema Chesf.

Com base nestes resultados, infere-se que ao se instalar o software Neuranálise[®] na rede oscilográfica do sistema Chesf, pode-se adotar sem perda de eficiência, modelos a parâmetros distribuídos constantes na freqüência para o processo de aprendizagem da RNA.

O algoritmo de treinamento RPROP apresentou bom desempenho quando aplicado ao problema em questão, alcançando erro admissível em poucas iterações.

O Neuranálise[®] já está incorporado, em escala piloto, ao sistema de oscilografia da CHESF, com resultados bastante promissores. Espera-se que o software seja incorporado, em breve, a todo o sistema de oscilografia da empresa.

Como fruto deste trabalho, foi publicado no congresso *Transmission and Distribution* (T&D - 2004), o qual foi suportado pelo IEEE, um artigo intitulado “*Transmission Line Model Influence on Fault Diagnosis*” (em anexo).

7. Referências Bibliográficas

- [1] NEVES, W. L. A., Transitórios Eletromagnéticos em Sistemas de Potência – Notas de Aula, Campina Grande: Departamento de Engenharia Elétrica - UFPB, Fevereiro de 2001.
- [2] DOMMEL, H. W., Electromagnetic Transients Program Reference Manual, Department of Electrical Engineering, The University of British Columbia, Vancouver, 1996.
- [3] MICROTRAN POWER SYSTEM ANALYSIS CORPORATION, Transients Analysis Program Reference Manual. Vancouver, 1992.

- [4] LEUVEN EMTP CENTER, ATP - Alternative Transient Program - Rule Book, Herverlee, Belgium, July 1987.
- [5] NAIDU, S. R., Transitórios Eletromagnéticos em Sistemas de Potência. Campina Grande: Editora Grafset, ELETROBRÁS/UFPB, 1985.
- [6] FERNANDES, A. B., Linhas de Transmissão: um Modelo Computacional no Domínio de Fases Preciso e Eficiente, Tese de Doutorado, Campina Grande: UFPB/COPELE, Outubro de 2001.
- [7] DALSTEIN, T., KULIEKE, B., Neural network approach to fault classification for high speed protective relaying. *IEEE Trans. on Power Delivery*, 10(2): 1002-1009, 1995.
- [8] MOHAMED E. A., RAO N. D., "Artificial neural network based fault diagnostic system for electric power distribution feeders", *Electric Power Systems Research*, vol. 35, pp. 1-10, Feb. 1995.
- [9] OLESKOVICZ M., COURY, D.V., AGGARWAL, R.K. 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.
- [10] HAYKIN, S., Redes Neurais, Princípios e Prática, 2^a. ed., Porto Alegre: Bookman, 2001.
- [11] COURY, D. V., GIOVANINI, R., Classificação rápida de faltas em sistemas elétricos utilizando redes neurais artificiais, *IV Brazilian Conference on Neural Networks*, pp. 281-286, 1999.
- [12] SOUZA B. A., BRITO N. S. D., NEVES W. L. A., FERNANDES A. B., SILVA S. S. B., SILVA K. M., DANTAS K. M. C., FONTES A. V., COSTA F. B. "Classificação de faltas via redes neurais artificiais", *V Seminário Brasileiro sobre Qualidade da Energia Elétrica*, 2003.
- [13] IEEE POWER SYSTEM RELAYING COMMITTEE, IEEE Standard Common Format for Transient Data Exchange (COMTRADE) for Power Systems, IEEE PES (C37.111-1991), New York, New York, October 1991.
- [14] SOUZA B. A., BRITO N. S. D., NEVES W. L. A., FERNANDES A. B., SILVA S. S. B., SILVA K. M., LIMA R. B. V. "Comparison between

- backpropagation and RPROP algorithms applied to fault classification in transmission lines", In *Proc. 2004 International Joint Conference on Neural Networks*, 2004.
- [15] MATHWORK, INC. Matlab: High-performance numeric computations and visualization software, Matlab user's guide, 1997.

ANEXOS

Transmission Line Model Influence on Fault Diagnosis

N. S. D. Brito, W. L. A. Neves, B. A. Souza

K. M. C. Dantas, A. V. Fontes, A. B. Fernandes, S. S. B. Silva

Abstract — Artificial neural networks have been used to develop software applied to fault identification and classification in transmission lines with satisfactory results. The input data to the neural network are the sampled values of voltage and current waveforms. The values proceed from the digital fault recorders, which monitor the transmission lines and make the data available in their analog channels. It is extremely important, for the learning process of the neural network, to build data bases that represent the fault scenarios properly. The aim of this paper is to evaluate the influence of transmission line models on fault diagnosis, using constant and frequency-dependent parameters.

Index Terms — Fault Diagnosis, Transmission Line, Artificial Neural Networks, Power Quality.

I. INTRODUCTION

Assuring the electric system efficiency and the quality of the offered service are the main purposes of the utility companies. In this context, the protection systems reach fundamental function, due to the fact that unexpected events may occur at electric systems and interfere in the power supply. Therefore, protecting the transmission lines and the equipments of the system is an important problem for the companies, what entails the need for monitoring. The monitoring process of the electric system consists of detecting, classifying and locating the faults. Digital Fault Recorders (DFR) are crucial for the process, since they acquire all the necessary data.

Modern technology has led to reliable, cheaper and easy-to-use Digital Fault Recorders, allowing networking these oscillographical devices and, as a result, making it possible to cover practically all the utilities systems. Furthermore, most of the recent digital relays have protection and monitoring functions integrated, so they are part of the oscillographical network as well.

The authors thank CHESF – Hydro Electric Company of San Francisco for the financial support.

N. S. D. Brito, W. L. A. Neves and B. A. Souza work as professors of DEE/UFCG, Aprigio Veloso Av., 882, Bodocongó, Campina Grande – PB, 58.109-970, Brazil. K. M. C. Dantas and A. V. Fontes are undergraduate students of Electrical Engineering at DEE/UFCG.
 ({benemar, nubia, waneyes}@dee.ufcg.edu.br, {karcius.dantas, alessandro.fontes}@grad.dee.ufcg.edu.br).

A. B. Fernandes is an ONS consultant, Rua Quinze de Março, 50, Bongi, Recife – PE, 58.761-901, Brazil. (alecio@ons.org.br).

S. S. B. Silva works as an engineer at CHESF, Rua Quinze de Março, 50, Bongi, Recife – PE, 58.761-901, Brazil. (sandras@chesf.gov.br).

In the case of the main utility company of the northeast of Brazil, Hydroelectric Company of San Francisco (CHESF), the oscillographical network monitors at about 350 events in transmission lines, capacitor banks, buses, etc.

By means of a research and development project, CHESF and the Federal University of Campina Grande (UFCG) developed software to assist the engineers of the oscillography sector of the company. The software was called NEURANÁLISE® and is based on artificial neural networks (ANN). NEURANÁLISE® uses sampled values of voltage and current, proceeding from the analog channels of the DFR, to identify and classify faults in transmission lines according to the artificial intelligence technique mentioned.

For the application of ANN to the problem that comprises faults diagnosis in transmission lines, it is extremely important that a pattern set which represents the fault scenarios be produced. That set is denominated *data base* and it's usually built by digital simulation, making use of an EMTP (*Electromagnetic Transients Program*).

The availability of information about the electric system configuration can determine which transmission line model will be used. In a complex system, such as the CHESF system, the transmission lines are generally modeled using distributed parameters with no dependence on the frequency. As NEURANÁLISE® will receive the data proceeding from the relays and DFR, the following question arises:

How will NEURANÁLISE® behave when the data bases are built using models with no dependence on the frequency, if the sampled data (input data) intrinsically contain the effects of the frequency-dependent transmission lines parameters?

It is presented at this article, the research accomplished to answer this question.

II. ANN AND THE FAULT CLASSIFICATION PROBLEM

During the last ten years, many analytical methodologies have been proposed with the objective of classifying faults in transmission lines. In most of the cases, the performance of the algorithms may be jeopardized by factors such as the influence of noise, the presence of harmonics and even by changes in the operation scenario of the electric system [1]. Artificial intelligence techniques have also been proposed to solve the fault classification problem. The methodology based on ANN performs better than traditional analytical ones, especially in terms of speed, precision and robustness in diagnosis [2]-[3].

In the applications of ANN for the fault classification problem, supervised training prevails. As a matter of fact, the performance of the ANN is directly related to what the initially presented patterns (*training set*) actually represent. The ANN learns from that training set [4], so if it does not give a good representation of the real patterns, the performance after the learning period might not be so good. As the ANN learns, a second pattern set, called *validation set*, is needed for the evaluation of the quality of the training. At this time, the mean-squared error is calculated to discover whether the ANN is able to generalize, i.e., if it is able to classify patterns that are similar to the ones in the training set. Finally, with the intention of evaluating the performance of the network after the training period, a third pattern set, the *test set*, is used and the percentage of achieved success on classifying the presented patterns is determined. Those three sets must be representative and distinct; altogether, they are called *data base*.

Samples of voltage and current waveforms for the three phases are used as input signals for the neural network. In the real situation, those sampled values are available in the DFR analog channels. The output of the network is the indication of the type of fault present in the analyzed data [5]

III. DATA BASE CONSTRUCTION

The performance of an ANN for classifying patterns is strongly dependent on the ones presented in the learning period, because the knowledge is extracted from them. Thus, the patterns must be as trustful as possible, i.e., they must be similar, if not equal, to the ones that will be presented in the real application. Also, but not less important, the amount of the different patterns presented must be equivalent. Those are the requirements for building a representational data base.

At first glance, the best option for fault classification using neural networks would be to use patterns collected directly from the electric system, but in the real situation there is a small number of fault records, e.g., faults that involve the three phases correspond only to approximately 5% of the ones that occur in the system [6]. This makes evident that, in this case, simulated situations must be used in order to train the ANN, otherwise its performance would not be satisfactory. But, above all, the simulation of the analyzed system must be done in close agreement to reality, so that a large number of fault situations are represented.

Among the computational models included at the EMTPs, the transmission lines are noticeable by two particularities: the parameters are distributed along its extension and present frequency dependence. Moreover, they can be found at the simplest power systems.

Because of their peculiarities, transmission lines can be modeled by different means, according to the speed and precision required. According to its distributed-parameter nature, models with lumped parameters or models with distributed parameters can represent a transmission line. Whereas, when it comes to its parameters dependence on frequency, models with constant parameters or models with frequency-dependent parameters can represent a transmission

line. Multi-phase transmission lines can also be modeled at the modal-domain or at the phase-domain.

The transmission line model influence on fault diagnosis was evaluated using a test system (Fig. 1). It comprises a 440kV untransposed three-phase transmission line with 4 conductors per phase and two ground wires [3]. The simulations were carried out using ATP [7], a type of EMTP, and considering two models:

- FC: consisting of distributed and frequency-constant parameters;
- FD: consisting of distributed and frequency-dependent parameters.

A sliding faults scheme was used with the purpose of simulating faults all along the line [8]. In the end, the simulated files were converted to IEEE COMTRADE [9] to solve a matter of compatibility, since the output files of the DFR follow this format.

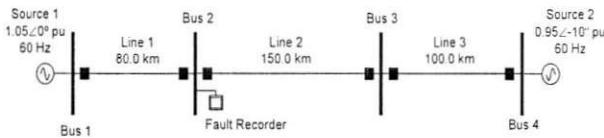


Fig. 1. Test system.

Besides the fault localization, other variables were also used in the construction of the data base, such as the incidence angle and the fault resistance. The ANN extracts the knowledge from the distinct fault scenarios present in the data base, which was originated from all the combinations of the simulation variables. Each scenario is represented by a set of files standardized at the COMTRADE format, emulating a record proceeding from the DFR.

To create a data base for this research, 1920 scenarios were built and distributed among training, validation and test sets. The variables utilized in the construction of the data base can be seen below:

- Faults AT-BT-CT-AB-AC-BC-ABT-ACT-BCT-ABC.
- Phase-Ground Resistances: 50 Ω and 100 Ω.
- Phase-Phase Resistances: 5 Ω and 10 Ω.
- Incidence Angles: 30°, 60° and 80°.
- The fault locations (in km) were distributed through the data base sets as follows:
 - Training: 10, 40, 60, 90, 110, 140, 160, 190, 210, 240, 260, 290 and 310.
 - Validation: 30, 80, 130, 180, 230 and 280.
 - Test: 20, 50, 70, 100, 120, 150, 170, 200, 220, 250, 270, 300 and 320.

There are DFR with many sampling rates at CHESF's oscillographical network. For this research, the sampling rate was chosen to be 1,200 Hz, which is a compatible rate for the DFR existent at the utility system. The simulation time for a fault situation corresponds with half a period of a 60-hertz

waveform. This time implies 10 samples of voltage and current in each phase for each fault scenario.

A windowing method was applied to the data obtained from the files simulated at the ATP, joining five consecutive voltage and current samples for the three phases and five consecutive voltage and current samples of zero-sequence, into a single input pattern for the network (Fig. 2). The window can be considered as a shifting window, as it goes all the way through each data file of the data base, shifting one sample at a time. It is important to state that the first window that is considered is the one that contains only post-fault samples [10].

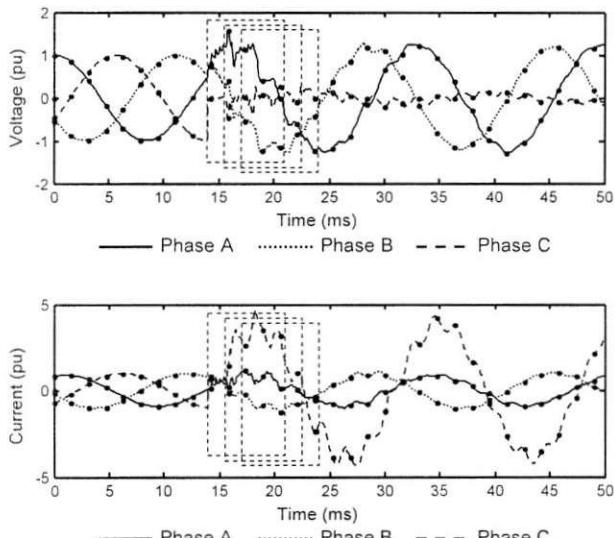


Fig. 2. Windowing Process of Current and Voltage Signals.

Due to the windowing method, each pattern in the base consists of an input and an output vector. The input vector comprises 40 values (5 samples of current and voltage for each phase, and 5 samples of current and voltage of zero-sequence) and is used as the input of the ANN. The output vector is formed by four binary digits that indicate the type of fault present in the input vector, i.e., the desired response for the input vector.

Besides being able to classify all the fault situations, the ANN must have the capability of identifying a non-fault situation. Thus, non-fault patterns are included in the data base as well. As a consequence of that, the problem can be summarized as the classification of 11 distinct classes.

There are two additional important procedures that were followed. The first one is the normalization of all the samples of current and voltage present in the data base files. Obviously, after that process, the sampled values range from -1 to 1. The second one is the random mix of the patterns in the data base with the intention of avoiding a tendency in adjusting synaptic weights of the ANN, what would cause a loss in its generalization capability [5].

IV. ANN FEATURES

As stated before, the output of the network is the indication of the fault type present in the analyzed data. To make that possible, binary codification was used for the output of the ANN in such a way that a fault situation is characterized by the indication of presence (1) or absence (0) of one or more phases and of the ground terminal [5], as shown in Table I.

TABLE I
DESIRED OUTPUTS FOR THE ANN

Fault Type	Desired Outputs			
	Phase A output	Phase B output	Phase C output	Ground output
	1	2	3	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
Non-Fault	0	0	0	0

Among the existing ANN architecture types, the option was to use multi-layer perceptron (MLP) networks, as it is done in projects similar to this one as well [1]-[3]. The learning period of the network was implemented using resilient propagation, RPROP [11], which is an evolution of traditional backpropagation.

In order to achieve a good performance for the MLP network, many network topologies were evaluated, seeking for the one that best suited the problem. A topology with 50 processing neurons in the hidden layer showed best fitness for the problem. Moreover, there are also 40 sensory units in the input layer, because of the windowing scheme utilized, and 4 neurons in the output layer, because of the binary codification adopted (Fig. 3).

The ANN was implemented using MATLAB® Neural Network Toolbox [12].

V. ANN SENSITIVITY TO THE TRANSMISSION LINE MODEL

Models with frequency-dependent parameters (FD) are more representational when compared with models with constant parameters (FC), because they describe the wave propagation phenomenon with more accuracy. But the FD model requires a lot of extra information, like ground resistivity, diameter and geometry of the cables etc. In the other hand, the constant-parameter model is simpler to simulate even though it is less accurate.

In the case of a large system, just like the CHESF system, with almost 18.000 km of transmission lines, a lot of additional information would be necessary in order to build an FD model. Moreover, a data set is already available at the

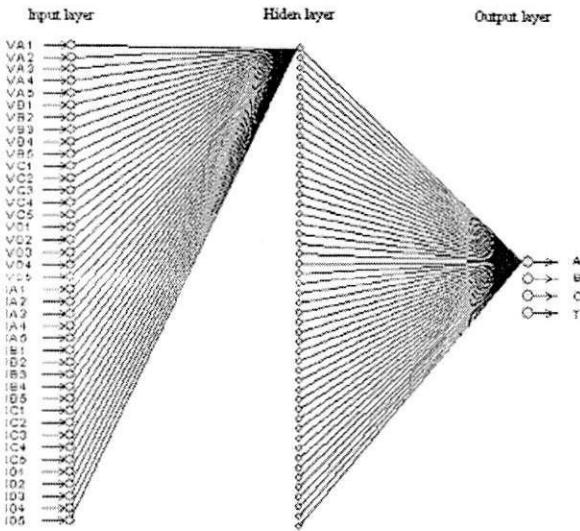


Fig. 3. ANN used in the research

company, with transmission lines in the ATP format, using the FC model.

The data base shown at section III was utilized with the purpose of evaluating the ANN sensitivity to the line model. Constant and frequency-dependent parameters models were used. Different combinations of models in the training, validation and test sets were studied:

- **FC case :** FC model applied to training, validation and test sets;
- **FD case:** FD model applied to training, validation and test sets;
- **CFD case:** FC model applied to training and validation sets and FD model applied to test set.

According to the adopted model, voltage and current signals may contain distinct information for the same type of fault. The FD model is more damped for high frequency components than the FC model (Fig. 4). This fact may have a great influence on the performance of the ANN.

At Table II, the influence of the transmission line model on fault diagnosis is evaluated. Some remarks are a consequence of Table II information:

- The worse overall success rate was obtained with the data base consisting of training, validation and test sets built with the FC model;
- The best performance of the ANN was obtained with the FD case;
- A satisfactory performance was achieved with the CFD case, even with its training and validation sets being built by means of the FC model, which is less realistic than the FD model used in the test set.

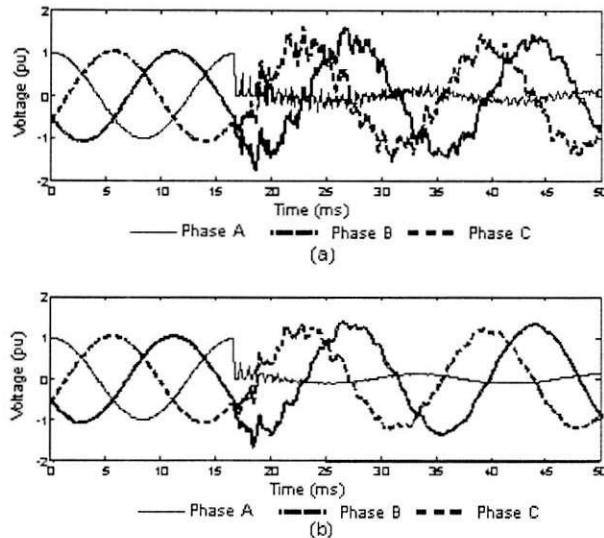


Fig. 4. Phase ground fault: (a) FC model; (b) FD model.

TABLE II
ANN PERFORMANCE

Analyzed Case	Total Success Rate (%)
FC	93,32
FD	96,66
CFD	96,34

VI. ANN APPLICATION TO CHESF ELECTRIC SYSTEM

The ANN-based methodology implemented was evaluated through a real three-phase transmission line. The line used was 04V4 – class 230 kV, 188 km long – that belongs to CHESF east subsystem (Fig. 5) and is located between Campina Grande II and Natal II substations. The transmission line was modeled with distributed and constant parameters.

The same procedure introduced in section III was used to build a knowledge base for the application. The fault scenarios were simulated according to the following variables:

- Faults: AT-BT-CT-AB-AC-BC-ABT-ACT-BCT-ABC.
- Sampling Rate: 1,200 Hz.
- Phase-ground resistances: 50 Ω and 100 Ω.
- Phase-phase resistances: 5 Ω and 10 Ω.
- Incidence Angles: 30° and 60°.
- The fault localizations (in km) were scattered through the data base as follows:
 - Training: 20, 30, 50, 60, 80, 90, 110, 120, 140, 150.
 - Validation: 40, 100, 160, 180.
 - Test: 10, 70, 130, 170.

The ANN topology used with the test system was applied to this case. The total success rate was 99,74%. Detailed results are shown in Table III.

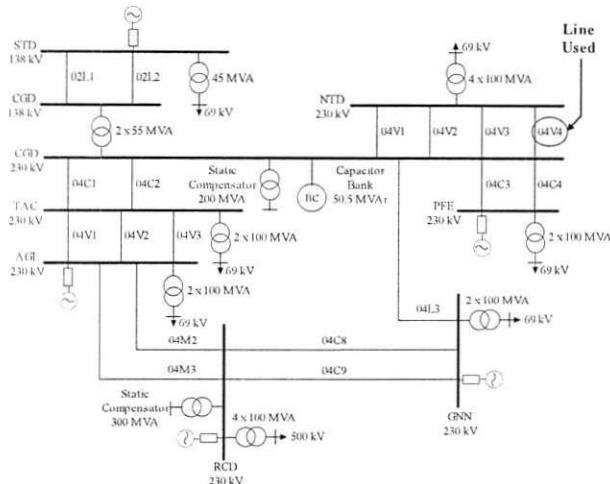


Fig. 5. Simplified CHESF east subsystem.

TABLE III
ANN SUCCESS RATE WHEN APPLIED TO CHESF EAST SUBSYSTEM

Type of Fault	Success Rate (%)
AT	100,00
BT	100,00
CT	98,61
AB	98,61
AC	100,00
BC	100,00
ABT	100,00
ACT	100,00
BCT	100,00
ABC	100,00
Non-fault	100,00
Total	99,74

VII. CONCLUSIONS

The results yielded in this paper attest the efficiency of ANN, in particular of MLP networks, to solve the fault classification problem. A total 99,74% success rate was obtained when the methodology was applied to the simulated CHESF system.

As a consequence of the results obtained, specially with the CFD case, the inference is that distributed and constant parameter models can be used, without loss of efficiency, in the learning period of the ANN applied to fault classification. As stated before, this ANN is the basis of software NEURANÁLISE®, so there is an expectation of good results when the software is installed in the substation for real tests, since in this situation the data will come from the DFR records which are intrinsically frequency-dependent.

Actually, NEURANÁLISE® has already been installed in the substation and is monitoring the transmission line described in section VI. The expectations were proven right, because the results with real fault scenarios are very promising.

Currently, the research and development project is nearly finished. The product developed, NEURANÁLISE®, is incorporated to CHESF oscillographical network as a primary test and has shown potential to be used in all the utility system in near future.

VIII. ACKNOWLEDGEMENTS

The authors would like to thank all the members of CHESF Department of Protection and Automation Operation. Special thanks are owed to Dr. José Júlio de Almeida Lins Leitão and Engineer Ricardo Ulisses Falcão Ferraz, because of their struggle to support this project.

IX. REFERENCES

- [1] 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.
- [2] 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.
- [3] M. Oleskovicz, D. V. Coury e R. K. Aggarwal, "Artificial Neural Networks Applied to Fast Classification of Faults on Power Systems" (In Portuguese), *SBA Controle & Automação*, v. 11, n. 3, December 2000.
- [4] S. Haykin, *Neural Networks: A Comprehensive Foundation*, New Jersey: Prentice Hall, 1999.
- [5] D. V. Coury e R. Giovanini, "Fast classification of Faults in Electric Systems Using Artificial Neural Networks" (In Portuguese), *IV Brazilian Conference on Neural Networks*, 1999, pp. 281-286.
- [6] J. J. Grainger and W. D. Stevenson, *Power System Analysis*, New York: McGraw-Hill Science/Engineering/Math, 1994.
- [7] LEUVEN EMTP CENTER. ATP - Alternative Transient Program - Rule Book. Herverlee, Belgium, 1987.
- [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, "Fault Classification Via Artificial Neural Networks" (In Portuguese), *V Brazilian Seminar on Power Quality*, 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, 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 (artigo aceito).
- [11] MATHWORK, INC. MATLAB: High-performance numeric computations and visualization software, MATLAB user's guide, 1997.

X. BIOGRAPHIES

Núbia Silva Dantas Brito was born at Antenor Navarro, Brazil, 1965. She received the titles of B.Sc. and Ph.D. in Electrical Engineering from Federal University of Paraíba (UFPB), Brazil, in 1988 and 2001 respectively. Her M.Sc. degree was received from Campinas State University (UNICAMP), SP, Brazil. Currently she works as a professor at the Department of Electrical Engineering (DEE) of Federal University of Campina Grande (UFCG), PB, Brazil. Her research activities are mainly focused on Power Quality, especially on applications that involve fault detection and classification in electric systems.

Washington Luiz Araújo Neves was born at Itaporanga, Brazil, 1954. He received the titles of B.Sc. and M.Sc. at Federal University of Paraíba (UFPB), in 1979 and 1982 respectively. He was honored Ph.D. by the University of British Columbia, Vancouver, Canada, in 1994. From 1982 to 1985 he worked as a professor at the Department of Electrical Engineering of Engineering School of Joinville, SC, Brazil. Currently he works as a professor at the Department of Electrical Engineering (DEE) of Federal University of

Campina Grande (UFCG), PB, Brazil. His research activities are mainly focused on electromagnetic transients.

Benemar Alencar de Souza was born at Crato, Brazil, 1954. He received the titles of B.Sc., M.Sc. and Ph.D in Electrical Engineering from Federal University of Paraiba, (UFPB), Brazil, in 1977, 1981 and 1995 respectively. Currently he works as a professor at the Department of Electrical Engineering (DEE) of Federal University of Campina Grande (UFCG), Brazil. His research activities are mainly focused on optimization methods applied to power systems, electromagnetic transients and power systems planning.

Karcius Marcelus Colaço Dantas was born at Campina Grande, Brazil, 1982. He is an undergraduate student of Electrical Engineering at Federal University of Campina Grande (UFCG). He is interested in electromagnetic transients, artificial intelligence techniques applied to power systems and planning and operation of power systems.

Alessandro Viana Fontes was born at Aracaju, Brazil, 1978. He is an undergraduate student of Electrical Engineering at Federal University of Campina Grande (UFCG). He is interested in electromagnetic transients and planning and operation of power systems.

Alécio Barreto Fernandes was born at Brasília, Brazil, 1971. He received B.Sc., M.Sc. and Ph.D. in Electrical Engineering from Federal University of Paraiba (UFPB), Brazil, in 1994, 1996 and 2001 respectively. From 1996 to 1998 he worked as an engineer at Aluminum Association of Maranhão (ALUMAR), at São Luís, Brazil. From 2001 to 2003 he worked as Research Director of NEPEN (Center of Studies and Research of the Northeast), at Aracaju, SE, Brazil. Since 2003, he is a consultant of Electric System National Operator (ONS), at Recife, PE, Brazil.

Sandra Sayonara Bispo da Silva was born at Recife, Brazil, 1960. She received her B.Sc. degree in Electrical Engineering from University of Pernambuco (UPE), Recife, Brazil in 1984. She was honored M.Sc. at Federal University of Pernambuco (UFPE) in 2002. Currently she works as an engineer at CHESF, Recife. At the company, she is specialized in occurrence analysis. Besides oscillographical networks and power systems protection, she is also interested in artificial intelligence techniques applied to power systems, which is the theme of her doctorate at Federal University of Campina Grande (UFCG), Brazil.