



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

GMI 19
14 a 17 Outubro de 2007
Rio de Janeiro - RJ

GRUPO XII

GRUPO DE ESTUDO DE ASPECTOS TÉCNICOS E GERENCIAIS DE MANUTENÇÃO EM INSTALAÇÕES ELÉTRICAS

APLICAÇÃO DE REDES NEURAIS PARA DIAGNÓSTICO DE POLUIÇÃO EM ISOLADORES DE ALTA TENSÃO

Ronaldo Ribeiro Barbosa de Aquino * José Maurício de Barros Bezerra Gabriela Seabra Melo e Santos Otoni Nóbrega Neto Milde Maria da Silva Lira Aida Araújo Ferreira Josinaldo Bezerra de Oliveira

DEPARTAMENTO DE ENGENHARIA ELÉTRICA E SISTEMAS DE POTÊNCIA – DEESP/UFPE

RESUMO

Propõe-se, neste artigo, uma metodologia para diagnosticar o estado de isolamentos de sistemas aéreos de transmissão através de técnicas de reconhecimento de padrões, utilizando redes neurais artificiais através da obtenção de sinais de ultra-som. Foram utilizadas no trabalho técnicas de extração de características nos sinais de entrada da rede neural, viabilizando a utilização deste modelo, haja vista que foram obtidos resultados satisfatórios, levando a uma análise comparativa entre modelos anteriormente aplicados para a referida técnica.

PALAVRAS-CHAVE

Inteligência artificial, poluição em isoladores, classificador de padrões, ultra-som, descargas superficiais.

1.0 - INTRODUÇÃO

A contaminação de isoladores utilizados em linhas de transmissão de alta tensão é responsável por grande parte das falhas em um sistema de potência. Preocupado com tais questões, analisam-se, neste artigo, sistemas de aquisição de dados que viabilizem a monitoração de sinais relacionados com o nível de contaminação de isoladores que possam ajudar na redução de falhas no sistema de potência.

O procedimento atualmente adotado, apesar dos resultados alcançados, pode incorrer em falhas no diagnóstico, uma vez que as condições que levam o fenômeno da poluição a apresentar efeitos visuais efetivamente detectáveis nem sempre estão presentes durante as inspeções noturnas, tais como a tensão elétrica mais elevada simultaneamente com alta umidade. As inspeções em si representam a obtenção de um “retrato” do sistema isolante naquele momento em que são realizadas, podendo não caracterizar o fenômeno monitorado corretamente.

A implementação de técnicas de diagnóstico que possam ser utilizadas em tempo real representa, portanto, uma ferramenta preditiva de grande importância no sentido de incorporar precisão e confiabilidade às decisões quanto à real necessidade de deflagrar ações preventivas ao sistema de isolamento utilizado.

Os isoladores foram ensaiados em laboratório de alta tensão para a obtenção de sinais de ultra-som. Os sinais foram gerados a partir de unidades isolantes poluídas artificialmente, as quais foram inseridas em câmara de névoa.. Subseqüentemente foi realizada uma extração de características nos sinais de ultra-som, visando obter uma entrada satisfatória para a rede neural.

Este trabalho avalia duas maneiras diferentes de representar os seis níveis de poluição dos isoladores, conforme serão vistas nos classificadores criados a partir dos *modelos 1 e 2*. Além disso, foram avaliados dois outros modelos, desenvolvido a partir de três especialistas.

(*) Rua Acadêmico Hélio Ramos s/n, Cidade Universitária, Centro de Tecnologia, CEP 50.740-530 – Recife, PE – Brasil. Tel: (+55 81) 2126 8256 – Fax: (+55 81) 2126 8739 – Email: rriba@ufpe.br

2.0 - TENSÃO DE DESCARGA NO ISOLADOR

Em 1981 foram consolidados modelos para avaliar a tensão de descarga em isoladores submetidos à tensão alternada, poluição e umidade (2). Esses modelos, em etapa posterior, foram implementados computacionalmente (3).

Com o intuito de inferir a tensão de ensaio a ser utilizada, de tal forma a assegurar que não haveria descargas completas (flashover) nos isoladores foram feitas avaliações do comportamento de um isolador imerso em ambiente poluído. A Figura 1 ilustra os resultados obtidos para o isolador padrão do tipo ST 254 V8 CB (4).

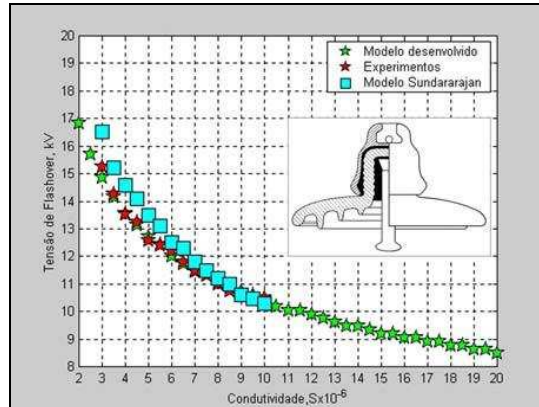


FIGURA 1 – Resultados obtidos a partir do modelo de Rizk para isolador padrão

Os valores constantes da Figura 1 foram considerados referenciais para o desenvolvimento das etapas experimentais descritas a seguir.

O nível da tensão, como pode ser verificado na Figura 1, representa um valor suportável para qualquer das amostras, independente do nível de poluição utilizado (ESDD). A Tabela 1 ilustra os níveis de poluição aplicados.

TABELA 1 – Caracterização das classes de poluição

Classe	Classificação	Faixa de ESDD (mg/cm ²)
A	Atmosfera sem poluição	0,00
B	Atmosfera limpa]0,000; 0,032]
B'	Contaminação muito leve]0,032; 0,038]
C	Contaminação leve]0,038; 0,056]
D	Contaminação pesada]0,056; 0,123]
E	Contaminação muito pesada	>0,123

3.0 - MONTAGENS EXPERIMENTAIS

3.1 Características dos Instrumentos Utilizados

- Sistema de detecção de ultra-som: consiste de um instrumento de fabricante Biddle o qual possui um indicador e um alto-falante, conectado a um sensor-transdutor de ultra-som sensível a uma faixa de frequência de 35 a 45kHz, tubo detector direcional, dispositivo de concentração do som e adaptador para transmissão do sinal. A Figura 2 ilustra o sensor utilizado (5).




FIGURA 2 – Sensor de ultra-som

- Sistema de digitalização: o sistema de digitalização consiste do "pacote" de medições TD2301 (6), com intervalo de captura de 600ns, o qual se compõe de instrumentações e programas computacionais.
- Fonte de tensão: A fonte de tensão utilizada para os ensaios permite a aplicação de tensão alternada na frequência de 60 Hz, podendo atingir tensões maiores do que 230 kV.

- Câmara de névoa: A câmara de névoa foi implementada, em conformidade com a IEC (7), para controle da umidade presente no ambiente sob teste, com o intuito de obter maior fidelidade na geração do efeito “corona”, em relação às condições reais de campo, ver (1).

4.0 - ESQUEMAS ELÉTRICOS IMPLEMENTADOS

No circuito ilustrado na Figura 3, pode-se observar a representação de um circuito de proteção implementado com o objetivo de minimizar o risco de danificação do digitalizador, na eventual descarga total do isolador, quando da aquisição dos sinais de corrente de fuga. Em sua concepção foi utilizado acoplamento óptico para isolar e proteger os equipamentos do sistema de digitalização, ver (1).




FIGURA 3 – Esquema elétrico dos ensaios

5.0 - MODELAGEM DA BASE DE DADOS

O desempenho dos sistemas inteligentes baseados em redes neurais artificiais (RNA) está correlacionado com os números de parâmetros livres das RNA e do número de exemplos usados no conjunto de treinamento, conforme (9) e (10).

Neste trabalho, a base de dados foi constituída de 100 padrões entrada-saída (sinal-classe) de cada uma das seis classes, separadas em três conjuntos distintos, são eles: 60% para o conjunto de treinamento, usado para o ajuste dos parâmetros livres das RNA; 20% para o conjunto de validação, usado apenas na monitoração dos treinamentos a fim de garantir a capacidade de generalização das redes; e 20% para o conjunto de teste, usado para testar a performance dos modelos criados.

Durante a fase de projeto dos classificadores foi necessário compactar drasticamente os sinais de ultra-som, os quais foram utilizados no ajuste dos parâmetros livres. Algumas técnicas foram testadas com este intuito, tais como: componentes principais, variáveis estatísticas e cálculo do centróide do sinal.

Dentre as técnicas testadas com propósito de extrair características dos sinais de ultra-som, a do cálculo do centróide demonstrou melhor desempenho na formação dos modelos neurais. Esta consiste em calcular os centróides e as áreas da parte superior, inferior e total do sinal, a partir das Equações 1 e 2, conforme ilustrado graficamente na Figura 4.

$$\bar{x} = \frac{\int_a^b x \cdot f(x) dx}{\int_a^b f(x) dx} \quad (1)$$

$$\bar{y} = \frac{\int_c^d y \cdot g(x) dx}{\int_c^d g(x) dx} \quad (2)$$

O uso da técnica do centróide possibilitou compactar a informação do sinal de ultra-som, que antes era formado por 32768 pontos, em 9, utilizados na formação dos padrões de entradas das RNA da seguinte maneira: 6 entradas formadas pelas coordenadas dos centróides superior, inferior e total do sinal; e 3 formadas pelos valores das áreas superior, inferior e total do sinal.

Além do cálculo dos centróides e das áreas, os dados foram normalizados através da Equação 3 para evitar que os neurônios das redes saturassem, dificultando o aprendizado durante os treinamentos.

$$\bar{x} = \frac{0,1 \cdot (x_{\max} - x) - 0,9 \cdot (x_{\min} - x)}{x_{\max} - x_{\min}} \quad (3)$$

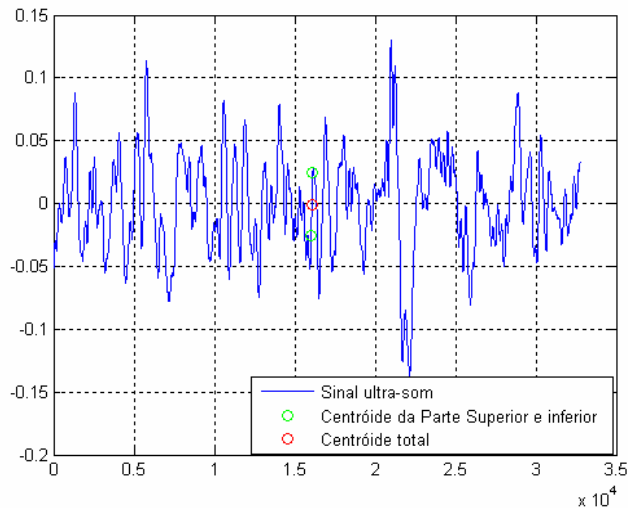


FIGURA 4 – Centróides de um dos sinais de ultra-som

6.0 - CLASSIFICADORES NEURAIS

Diversas aplicações de redes neurais dizem respeito à classificação de padrões. Nestas aplicações, a RNA aprende a identificar várias classes diferentes. Assim, ao deparar com um padrão desconhecido, a rede deverá classificá-lo. Alguns tipos de RNA têm sido aplicadas com sucesso no desenvolvimento dos classificadores inteligentes, são elas: Perceptron Multicamadas - MLP (*Multilayer Perceptron*), as redes de Funções Bases Radiais - RBF (*Radial Basis Function*), e as redes Mapas Auto-Organizáveis - SOM (*Self-Organizing Maps*) (9) e (10).

Entretanto as redes MLP têm maior capacidade de generalização, pois estas constroem aproximadores globais, enquanto as redes RBF e SOM constroem aproximações e estruturas locais respectivamente. Por isso, os classificadores aqui propostos são desenvolvidos a partir das redes MLP.

As soluções de problemas que envolvem RNA são fortemente influenciadas pela forma de modelar o problema tratado, ou seja, as variáveis escolhidas como entrada e a maneira de representar os padrões de saída do modelo.

No corrente trabalho foram avaliados quatro modelos neurais distintos, com o intuito de obter um classificador com melhor performance, e assim diagnosticar futuras falhas em isoladores com maior confiabilidade. No primeiro modelo analisado, foi utilizado 1 neurônio na camada de saída da rede. No modelo 2, as classes foram codificadas através de 6 neurônios na saída da rede, aplicando a regra *winner takes all*, cujo neurônio ativado indica a classe do sinal de entrada.

No terceiro modelo, assim como no primeiro, as classes são representadas por 1 neurônio na saída da rede, entretanto este modelo é constituído por três especialistas distintos, obtidos durante os treinamentos para determinar as melhores arquiteturas das redes, para fornecer a classificação, isto é, qual o nível de poluição dos isoladores. O quarto modelo, segue a mesma metodologia do terceiro, ou seja, é formado por três especialistas, diferindo apenas na maneira de codificar as classes, pois neste modelo as classes são representadas por 6 neurônios na saída das redes.

As entradas das RNA foram definidas conforme dito anteriormente através dos cálculos dos centróides e das áreas nos sinais de ultra-som.

6.1 Treinamentos

Na criação dos modelos neurais desenvolvidos com as redes MLP, a fase de treinamento é a mais importante. Nesta fase é definido o ajuste dos parâmetros livres da rede e a arquitetura que possibilitem uma boa capacidade de generalização dos modelos. O algoritmo de treinamento usado foi *Levenberg-Marquardt(LM)*, ver (11).

Para a definição dos modelos aqui propostos, são criadas e treinadas várias arquiteturas de rede, modificando apenas os números de neurônios ocultos e inicializações dos pesos, (13) e (8), já que as entradas e saídas dos modelos foram previamente definidas.

Durante os treinamentos, com as arquiteturas já definidas, também se buscou encontrar uma melhor distribuição dos padrões de entrada-saída dentro dos conjuntos de treinamento, validação e teste. Esta distribuição foi encontrada através da técnica de validação cruzada usando o método k-fold, com k=10, apresentado na Tabela 2,

conforme (13) e (8). Pretendendo encontrar o experimento que melhor represente as classes. E dentro deste experimento a melhor rede para cada modelo estudado.

TABELA 2 – Validação cruzada utilizando K-fold

Experimento	Conjunto de Treinamento	Conjunto de Validação	Conjunto de Teste
1	[5, 6, 7, 8, 9, 10]	[1, 2]	[3, 4]
2	[1, 6, 7, 8, 9, 10]	[2, 3]	[4, 5]
3	[1, 2, 7, 8, 9, 10]	[3, 4]	[5, 6]
4	[1, 2, 3, 8, 9, 10]	[4, 5]	[6, 7]
5	[1, 2, 3, 4, 9, 10]	[5, 6]	[7, 8]
6	[1, 2, 3, 4, 5, 10]	[6, 7]	[8, 9]
7	[1, 2, 3, 4, 5, 6]	[7, 8]	[9, 10]
8	[2, 3, 4, 5, 6, 7]	[8, 9]	[10, 1]
9	[3, 4, 5, 6, 7, 8]	[9, 10]	[1, 2]
10	[4, 5, 6, 7, 8, 9]	[10, 1]	[2, 3]

6.2 Modelo 1

Neste modelo, os seis níveis de poluição, que definem as classes, são representados na RNA com um único neurônio na saída da rede. Estas classes são apresentadas de acordo com a Tabela 3 obtida aplicando a Equação 3.

TABELA 3 – Codificação de classificação para saída com seis neurônios

Classes	Distúrbios	Codificação
A	Atmosfera sem poluição	0.1
B	Contaminação muito leve	0.26
B'	Contaminação leve	0.42
C	Contaminação pesada	0.58
D	Contaminação muito pesada	0.74
E	Atmosfera limpa	0.9

A função de ativação usada no neurônio de saída da RNA é do tipo sigmóide logística, que pode assumir qualquer valor no intervalo [0,1]. Portanto, para classificar corretamente, é necessário comparar a saída da RNA com os valores que identifica cada uma das seis classes.

6.2.1 Treinamento para seleção da arquitetura

Nesta fase buscou-se encontrar uma arquitetura de rede que melhor se adeque ao problema, conforme dito na seção anterior. Portanto, foram realizados diversos treinamentos com 11 arquiteturas distintas e 10 inicializações de pesos para cada, selecionando aquela que obteve menor erro MSE médio, das 10 inicializações sobre o conjunto de validação, ver (13). A Tabela 3 apresenta os resultados médios dos treinamentos para cada arquitetura testada.

TABELA 4 – Resultados médios dos treinamentos para seleção da arquitetura

Neurônios na camada oculta	5	6	7	8	9	10	11	12	13	14	15
Mse de Validação	1,635	1,636	1,641	1,659	1,555	1,979	1,904	2,048	2,269	1,943	2,038

Com base na Tabela 4 observa-se que a arquitetura com 9 neurônios ocultos obteve melhor desempenho durante os treinamentos. Assim, a arquitetura final da RNA do classificador do *modelo 1* ficou constituída de 9 entradas, 9 neurônios ocultos e 1 neurônio na saída.

6.2.2 Resultado – Teste

Uma vez definida a arquitetura, foram realizados os treinamentos com a técnica de validação cruzada com método k-fold, conforme dito anteriormente. A melhor rede encontrada dentre os experimentos criados com esta técnica foi quem definiu o ajuste final do classificador criado por este modelo. Este apresentou durante os testes um erro de classificação igual 22,5 %, isto é, dentre os 120 exemplos usados no teste o classificador errou 27.

6.3 Modelo 2

Neste modelo as classes de saídas são codificadas a partir da codificação *1 de m*, ou seja, para cada classe um único elemento do vetor pertencente ao R^6 é diferente de 0 e igual a 1, conforme apresentado na Tabela 5.

Quanto ao problema de classificar corretamente, haja vista, que as funções de ativações da saída deste modelo, também são do tipo sigmóide logística, é resolvido aplicando a regra do vencedor leva tudo (*Winner- takes- all*), isto é, o neurônio da saída com maior magnitude definirá a classe.

TABELA 5 – Codificação de classificação para saída com seis neurônios

Classes	Distúrbios	Codificação					
		1	0	0	0	0	0
A	Atmosfera sem poluição	1	0	0	0	0	0
B	Contaminação muito leve	0	1	0	0	0	0
B'	Contaminação leve	0	0	1	0	0	0
C	Contaminação pesada	0	0	0	1	0	0
D	Contaminação muito pesada	0	0	0	0	1	0
E	Atmosfera limpa	0	0	0	0	0	1

6.3.1 Treinamento para seleção da arquitetura

Assim como o modelo 1, neste modelo também são testadas várias arquiteturas com números de neurônios ocultos distintos, variando de 5 a 15. Para este modelo a arquitetura com 10 neurônios ocultos obteve melhor performance, conforme apresentado na Tabela 6. Logo a arquitetura final da RNA ajustada para este modelo ficou com 9 entradas, 10 neurônios ocultos e 6 saídas.

TABELA 6 – Resultados médios dos treinamentos para seleção da arquitetura

Neurônios na camada oculta	5	6	7	8	9	10	11	12	13	14	15
Mse de Validação	3,951	4,672	4,747	3,441	4,495	2,291	2,447	3,604	2,360	3,408	3,004

6.3.2 Resultado – Teste

Ao utilizar o método validação cruzada k-fold para melhor arquitetura selecionada neste modelo, encontrou-se para a melhor rede uma performance nos testes de 5,0 % de erro de classificação, ou seja, classificou incorretamente 6 exemplos dentro de um universo 120 exemplos do conjunto de teste.

6.4 Modelo 3

Neste modelo, ao invés de classificar um dado padrão de entrada com base em apenas um especialista, a classificação foi realizada a partir de três especialistas diferentes. Estes especialistas, três RNA, são treinados e projetados igual ao *modelo 1*, item 6.2.

Como este modelo é composto por três especialistas, é necessário definir como combiná-los a fim de determinar a resposta final, ou seja, a classificação para um determinado padrão. Neste trabalho as redes foram combinadas através do valor médio das saídas das redes, conforme (12).

6.4.1 Treinamento para seleção de arquitetura

Neste modelo as arquiteturas dos três especialistas, foram definidas através das três melhores arquiteturas de redes do *modelo 1*, isto é, as que obtiveram menor erro de validação durante os treinamentos, conforme a Tabela 4. Portanto as redes especialistas, selecionadas para constituir este modelo tiveram 9, 5 e 6 neurônios na camada oculta.

6.4.2 Resultado – Teste

Cada especialista deste modelo pode ser usado na formulação de um classificador independente. Neste caso, durante os testes cada especialista teve o seguinte desempenho: 1º especialista(9 neurônios na camada oculta) teve o erro de classificação igual 22,5%; 2º especialista(5 neurônios na camada oculta) o erro de classificação foi igual 20,8%; e o 3º especialista(6 neurônios na camada oculta) o erro de classificação foi igual 24,2% . Contudo, o desempenho da combinação dos três especialistas forneceu um erro de classificação igual a 17,5%, o que representa errar 21 exemplos numa população de 120 do conjunto de teste.

6.5 Modelo 4

Aqui o modelo também é estruturado na informação de três especialistas. Entretanto a diferença entre este modelo e o modelo anterior está na maneira de codificar as classes de saídas, pois neste, as classes são representadas através da codificação *1 de m*, exatamente como o *modelo 2*.

A classificação deste modelo é calculada através da média, no entanto, a média aqui é calculada para cada um dos seis neurônios de saídas das três RNA que formam este modelo. Quanto à definição final da classe do modelo é realizado através da regra o vencedor leva tudo, conforme o *modelo 2*.

6.5.1 Treinamento para seleção de arquitetura

Neste modelo as arquiteturas dos três especialistas, foram definidas através das três melhores arquiteturas de redes do *modelo 2* a partir da Tabela 6. Portanto as redes especialistas, selecionadas para constituir este modelo tiveram 10, 13 e 11 neurônios na camada oculta.

6.5.2 Resultado - Teste

O desempenho individual de todas as RNA, que compõe os especialistas, deste modelo foi o seguinte: 1º Especialista(10 neurônios na camada oculta) teve erro de classificação igual 5,0%; o 2º Especialista(13 neurônios na camada oculta) o erro de classificação foi igual 5,8%; e o 3º Especialista(11 neurônios na camada oculta) o erro de classificação foi igual 5,0%. Contudo, o desempenho da combinação dos três especialistas forneceu um erro de classificação igual a 3,3%, o que equivale a errar 4 exemplos numa população de 120 do conjunto de teste.

7.0 - CONCLUSÕES

Este artigo apresentou o desenvolvimento de quatro modelos de classificadores inteligentes baseados no uso de RNA do tipo MLP treinadas com algoritmo *LM*, com a finalidade de diagnosticar vários níveis de poluição nos isoladores de linhas de transmissão a partir de sinais de ultra-som.

Os resultados aqui encontrados mostram a superioridade da codificação *1 de m* para classes de saídas, usado no *modelo 2*, que obteve erro de classificação de 5%, enquanto na codificação simples, que utiliza apenas uma saída para codificar as classes, *modelo 1*, o erro foi de 22,5%.

Outro resultado importante obtido neste do trabalho foi à observação da superioridade dos modelos formados por combinação de especialistas, ver (12), *modelos 3 e 4*. Para estes modelos os erros de classificação obtidos foram iguais a 17,5% e 3,33% respectivamente.

Além disso, quando se compara os resultados encontrados neste trabalho com outras pesquisas desenvolvidas neste âmbito (1), demonstra a potencialidade do uso de RNA. Não só por sua performance, mais também pela sua simplicidade de utilização.

8.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) BEZERRA, J.M.B., LIMA, A.M.N., DEEP, G.S., COSTA, E.G., FREIRE, R.C.S., Técnicas de Diagnóstico de Poluição em Isoladores Aéreos de Alta Tensão. XVII-SNPTEE, 2003.
- (2) RIZK, F.A.M., Mathematical Models for Pollution Flashover, *Electra*, Vol. 78, pp. 71-103, 1981.
- (3) SUNDARARAJAN, R., SADHUREDDY, N.R., GORUR, R.S., Computer-aided Design of Porcelain Insulators under Polluted Conditions, *IEEE Transactions on Electrical Insulation*, Vol. 2, No. 1, pp. 121-127, 1993.
- (4) VIFOSA, Catálogo de Isoladores de Vidro, Brasil, 1962.
- (5) BIDDLE, Leak and Corona Detection. Bulletin 56- 1a, 1990.
- (6) TEKTRONIX, Getting Started with the TD2301/S45D010. Measurement Software, Product Group 45, 1992.
- (7) IEC, Artificial Pollution Tests on High-Voltage Insulators to be Used on a.c. Systems, segunda edição, IEC 507, 1991.
- (8) FERREIRA, AIDA A. Comparação de arquiteturas de redes neurais para sistemas de reconhecimento de padrões em narizes artificiais. Dissertação de mestrado, UFPE, Recife-PE, 2004.
- (9) HAYKIN, S. Redes Neurais: Princípios e Prática. BOOKMAN Editora S.A, 2001.
- (10) BRAGA, A.P., LUDERMIR, T.B., CARVALHO, A.C.P.L.F., Redes Neurais Artificiais: Teoria e aplicações. LTC Editora, 2000.
- (11) HAGAN, M. T., MENHAJ, M. B., Training Feedforward Networks with Marquardt Algorithm . *IEEE Transactions on Neural Networks*, Vol 5, NO. 6, November 1994, p. 989-993.
- (12) HAGAN, M. T., MENHAJ, M. B., Training Feedforward Networks with Marquardt Algorithm . *IEEE Transactions on Neural Networks*, Vol 5, NO. 6, November 1994, p. 989-993.

- (13) LIRA, M. M. S., AQUINO, R. R. B., FERREIRA A. A., CARVALHO Jr., M. A., LIRA, C. A. B. O. "Improving Disturbance Classification by Combining Multiple Artificial Neural Networks". IEEE World Congress on Computational Intelligence/ IJCNN, Vancouver-Canada. IEEE Xplore, p. 3436-3442, 2006.
- (14) AQUINO, R. R. B. ; FERREIRA, A. A.; LIRA, M. M. S., SILVA, G. B. DA, NÓBREGA NETO, O., OLIVEIRA, J. B., DINIZ, C. F. D., FIDELIS, J., A Hybrid Intelligent System for Short and Mid-term Forecasting for the CELPE Distribution Utility. In: IEEE World Congress on Computational Intelligent / IJCNN 2006, 2006, Vancouver, BC, Canada. IEEE Xplore, 2006. p. 2556-2661.

9.0 - DADOS BIOGRÁFICOS

Ronaldo Ribeiro Barbosa de Aquino

Nascido em Recife, PE em 06 de janeiro de 1962.

Doutorado (2001) em Engenharia Elétrica pela Universidade Federal de Campina Grande e Mestrado (1995) e Graduação (1983) em Engenharia Elétrica pela Universidade Federal de Pernambuco.

Atualmente é Professor Adjunto II da Universidade Federal de Pernambuco.

Área de atuação: Sistemas Elétricos de Potência. Atuando principalmente nos seguintes temas: Redes neurais artificiais e outras técnicas de inteligência artificial e suas aplicações em despacho hidrotérmico, previsão de carga elétrica e ventos, classificação de distúrbios, detecção falhas em isoladores e transformadores de potência.

José Maurício de Barros Bezerra

Nascido em 02 de Janeiro de 1953

Graduação em Engenharia Elétrica pela Universidade Federal de Pernambuco (1975) , Especialização em Sistemas de Potência pela Escola de Engenharia de Itajubá / MG (1982), mestrado em Engenharia de Sistemas pela Universidade Federal de Pernambuco (1995) e doutorado em Engenharia Elétrica pela Universidade Federal de Campina Grande (2004).

Atualmente é professor do Departamento de Engenharia Elétrica e Sistemas de Potência da Universidade Federal de Pernambuco.

Áreas de atuação: monitoração e recapacitação de sistemas de transmissão de energia elétrica

Gabriela Seabra Melo e Santos

Nascida em Recife, PE em 22 de Agosto de 1982

Graduação (2006) em Engenharia Elétrica pela Universidade Federal de Pernambuco.

Atualmente é mestranda em Engenharia Elétrica pela Universidade Federal de Pernambuco.

Área de atuação: Sistemas Elétricos de Potência, Redes neurais artificiais e outras técnicas de inteligência artificial e suas aplicações detecção falhas em isoladores, previsão de carga elétrica e ventos, classificação de distúrbios.

Otoni Nóbrega Neto

Nascido em Recife, PE, em 14 de setembro de 1980.

Mestrado em Engenharia Elétrica pela Universidade Federal de Pernambuco (2006). Graduação em Engenharia Elétrica pela Universidade Federal de Pernambuco (2004).

Atualmente é doutorando em Engenharia Elétrica pela Universidade Federal de Pernambuco. Tem experiência na área de Sistemas Elétricos de Potência. Atuando principalmente nos seguintes temas: Redes neurais artificiais e outras técnicas de inteligência artificial e suas aplicações em despacho hidrotérmico, previsão de carga elétrica.

Milde Maria da Silva Lira

Nascida em Recife, PE em 20 de abril de 1961.

Doutorado (2004), Mestrado (1999) e Graduação (1989) em Engenharia Elétrica: UFPE.

Atualmente é professora da UFPE através da bolsa do PRODOC/ CAPES.

Áreas de Atuação: Sistemas Elétricos de Potência. Atuando principalmente em qualidade da energia elétrica, redes neurais artificiais, lógica fuzzy e transformadas wavelets.

Aida Araújo Ferreira,

Nascida em Recife, PE em 12 de fevereiro de 1967.

Mestrado (2004) em Ciência da Computação pela Universidade Federal de Pernambuco e Graduação (1989) em Ciência da Computação pela Universidade Católica de Pernambuco.

Atualmente é doutoranda em Ciência da Computação pela Universidade Federal de Pernambuco e professora do Centro Federal de Educação Tecnológica de Pernambuco.

Área de atuação: Ciência da Computação, com ênfase em Sistemas de Computação. Atuando principalmente nos seguintes temas: redes neurais artificiais, sistemas híbridos e sistemas de previsão.

Josinaldo Bezerra de Oliveira

Nascido em Goiana, PE em 06 de Junho de 1981

Graduação em Engenharia Elétrica pela Universidade Federal de Pernambuco (2006).

Atualmente é mestrando em Engenharia Elétrica pela Universidade Federal de Pernambuco.

Área de atuação: Inteligência artificial, Redes neurais artificiais e suas aplicações em despacho hidrotérmico, previsão de carga elétrica e ventos, classificação de distúrbios, detecção falhas em isoladores.