



**GRUPO IX
OPERAÇÃO DE SISTEMAS ELÉTRICOS (GOP)**

**LOCALIZAÇÃO DE DEFEITOS EM SISTEMAS DE ENERGIA ELÉTRICA
UTILIZANDO SISTEMAS INTELIGENTES**

M.B. Do Coutto Filho
CAA-UFF

M.A.P. Rodrigues
LIGHT/CAA-UFF

* J.C.S. Souza
CAA-UFF

M.Th. Schilling
CAA-UFF/ELETRORÁS

RESUMO

Este trabalho apresenta um método para processamento de alarmes e localização de defeitos em sistemas de potência. O método utiliza classificadores neurais, cujas entradas são os alarmes recebidos sobre a operação de relés de proteção e disjuntores e as saídas identificam o componente do sistema no qual ocorreu o defeito. O método é capaz de localizar corretamente os componentes defeituosos, mesmo na presença de ruídos ou falhas do sistema de proteção. A metodologia empregada é ilustrada para um sistema teste, sendo também apresentados resultados para o sistema da LIGHT.

PALAVRAS-CHAVE

Proteção de sistemas elétricos; Processamento de alarmes; Reconhecimento de padrões; Redes neurais.

1.0 – INTRODUÇÃO

Em sistemas elétricos de potência um grande número de mensagens e alarmes são transmitidos ao centro de controle após a ocorrência de distúrbios. Estes distúrbios são, em geral, provocados por faltas que podem ser de diferentes tipos e ocorrer em qualquer parte do sistema. Os equipamentos de proteção são responsáveis por detectar a ocorrência de uma falta e isolar somente a parte defeituosa do sistema. É também muito importante que o restabelecimento do sistema ocorra o mais rapidamente possível. Portanto, é essencial que a localização do defeito também seja feita de forma precisa e rápida. No centro de controle o operador geralmente necessita tirar conclusões a partir da análise de um conjunto muito grande de informações recebidas, o que pode levar um tempo bastante grande. Outros problemas tais como: falhas no sistema de proteção, problemas nos canais de comunicação, aquisição de dados corrompidos, etc. podem tornar a localização de faltas uma tarefa bastante complicada.

A aplicação de sistemas inteligentes para o diagnóstico de faltas tem sido proposta na literatura. Muitas aplicações são baseadas na utilização de sistemas especialistas [1-3]. A maior limitação destas aplicações reside na dificuldade de tratar padrões de alarmes novos ou corrompidos. Redes neurais artificiais (RNs) têm sido eficientemente aplicadas

para a solução de problemas de planejamento e operação de sistemas de potência nos últimos anos [4-7]. Alguns métodos baseados na aplicação de RNs foram propostos para o problema de diagnóstico de faltas. Em [8] a utilização de apenas uma única rede neural (RN) para todo o sistema torna a aplicação bastante difícil para sistemas reais, já que a dimensão do vetor de entrada seria extremamente grande. Além disso, este método considera uma topologia fixa para o sistema e a RN deve ser re-treinada após cada mudança de topologia. A aplicação de diferentes RNs para diferentes configurações do sistema foi proposta em [9-11]. Estes métodos assumem que o sistema de proteção nunca falha e que um conjunto bastante amplo de mensagens e alarmes está sempre disponível no centro de controle. Esta situação nem sempre é verdadeira para sistemas reais.

Este trabalho propõe uma metodologia baseada na aplicação de RNs para a localização de defeitos em sistemas de potência. É adotada uma estratégia local, onde diferentes classificadores neurais são construídos, sendo cada um deles responsável por localizar defeitos envolvendo elementos em uma área específica do sistema. As RNs são capazes de fornecer diagnósticos mesmo em situações difíceis, tais como na presença de ruídos ou falhas no sistema de proteção. Testes realizados com um sistema exemplo e com o sistema da LIGHT são apresentados para ilustrar o algoritmo proposto.

2.0 – PROTEÇÃO DE SISTEMAS DE POTÊNCIA

Os sistemas de proteção são projetados de forma a isolar componentes defeituosos no sistema após a ocorrência de um distúrbio. Entre as características mais desejáveis de um sistema de proteção destacam-se: rapidez, seletividade e coordenação. Após a ocorrência de um defeito, os componentes defeituosos devem ser isolados o mais rapidamente possível de modo a evitar danos aos equipamentos do sistema durante a condição de defeito. Além disso, deve-se levar em consideração que a interrupção no fornecimento de energia elétrica deve ser minimizada ou, se possível, evitada. Logo, equipamentos de proteção como relés e disjuntores devem ser seletivos, ou seja, devem garantir que apenas os componentes sob defeito sejam desligados do sistema. Os relés de proteção devem ainda

operar de forma coordenada, de modo a oferecer proteção de retaguarda ao sistema. Assim, se o equipamento de proteção responsável por isolar um certo componente que se encontra sob defeito não operar corretamente, outros equipamentos de proteção devem atuar de forma a eliminar o defeito. Quando isto ocorre, o número de componentes desligados é em geral maior, o que pode dificultar a localização do defeito.

Os relés diferenciais e relés de distância estão entre os mais utilizados para a proteção de barramentos e linhas de transmissão. A característica principal de um relé diferencial é a sua seletividade. Ele é projetado para operar somente quando ocorrem defeitos dentro da zona protegida por ele. É em geral utilizado para a proteção de barramentos, transformadores, geradores e linhas de transmissão curtas. Os relés de distância são largamente utilizados para a proteção de linhas de transmissão e geralmente consistem de três zonas de proteção: a proteção principal (responsável por detectar e eliminar faltas em 100% da linha de transmissão, devendo operar de forma instantânea, utiliza esquemas de teleproteção), a proteção de primeira zona (responsável por proteger cerca de 80% da linha, serve como proteção de retaguarda instantânea para a proteção principal) e a proteção de segunda zona (geralmente ajustada para proteger 120-150% do comprimento da linha, serve como proteção de retaguarda para linhas de transmissão adjacentes). Outros relés de proteção, tais como relés de sobrecorrente, relés de proteção contra faltas para a terra, etc. também são utilizados para a proteção de sistemas de potência [12].

Após a operação de um relé de proteção, um comando de disparo é enviado aos disjuntores, que abrirão de forma a isolar a parte defeituosa do sistema. Em geral, um esquema de proteção contra falha de disjuntor é também empregada e opera sempre que uma falha de abertura de disjuntor é detectada. Neste caso, um comando de disparo é instantaneamente enviado para a abertura de disjuntores remotos. Isto reduz o risco de danos a equipamentos do sistema que ficariam submetidos a uma condição de falta por um longo período de tempo. Alarmes e mensagens são transmitidos ao centro de controle após a operação de relés e disjuntores. As informações sobre alarmes consideradas neste trabalho estão relacionadas a operação dos equipamentos de proteção listados na Tabela 1.

TABELA 1 – EQUIPAMENTOS DE PROTEÇÃO

Disjuntores (DJ)
Proteção contra falha de disjuntor (BF)
Relés diferenciais (PD)
Relés de distância – proteção principal (PP)
Relés de distância – proteção de 1ª zona (Z1)
Relés de distância – proteção de 2ª zona (Z2)

No centro de controle os alarmes são analisados pelos operadores, que devem então tirar conclusões e tomar decisões sobre a manutenção e o restabelecimento do sistema. O grande volume de informações a serem analisadas e outros problemas tais como: perda de informação importante, falhas no sistema de proteção, etc.

pode tornar a análise bastante complicada, especialmente se decisões em tempo-real são necessárias.

Redes neurais são capazes de processar um grande volume de informações em um tempo computacional compatível com os requisitos de tempo-real. Além disso, RNs são tolerantes a falhas e apresentam excelente capacidade de generalização, sendo capazes de responder bem para padrões inéditos.

3.0 – REDES NEURAIS ARTIFICIAIS

Uma rede neural artificial é uma estrutura de processamento massivamente paralelizada, não algorítmica, capaz de aprender e armazenar conhecimento sobre um dado problema, a partir de casos históricos ou simulados. Vários modelos de redes neurais têm sido propostos na literatura [13], diferindo basicamente quanto à arquitetura, modelo dos neurônios, tipo de treinamento e regra de aprendizagem. Neste trabalho é utilizada uma rede neural de treinamento supervisionado, descrita a seguir.

Rede Perceptron de Múltiplas Camadas

As redes neurais do tipo Perceptron de Múltiplas Camadas (MLP - *Multi-Layer Perceptron*) têm sido as mais utilizadas em problemas de reconhecimento de padrões. A rede MLP, ilustrada na Figura 1 com apenas uma camada escondida, é não-realimentada e utiliza treinamento supervisionado, sendo capaz de aproximar qualquer região de decisão. O modelo de neurônio mais empregado utiliza uma função de ativação do tipo sigmóide [13].

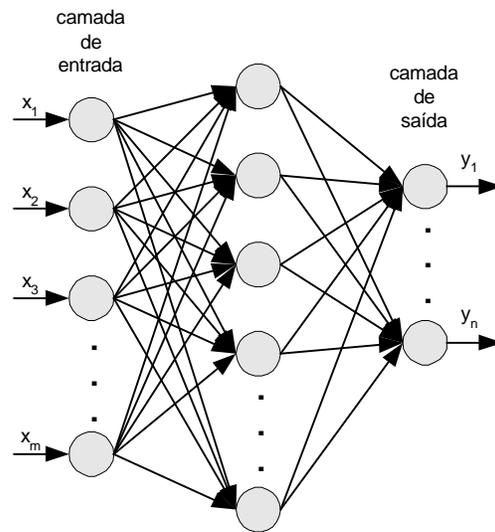


FIGURA 1 - REDE PERCEPTRON DE MÚLTIPLAS CAMADAS

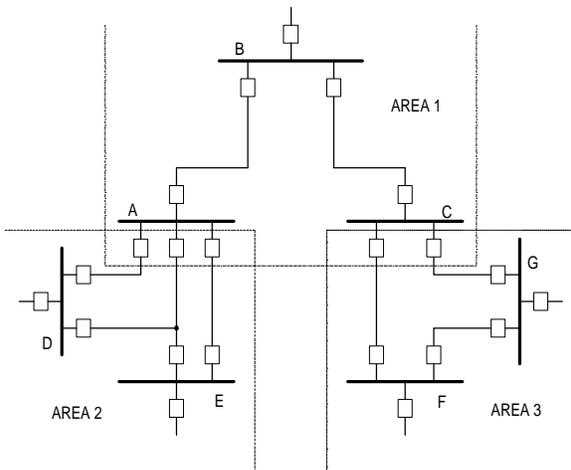
Na fase de aprendizado, os padrões de entrada são apresentados à rede e propagados para a frente (através das camadas intermediárias) até que as saídas dos neurônios da última camada sejam obtidas (saídas da rede). Os erros entre as saídas obtidas e as saídas desejadas (previamente conhecidas) são então utilizados para ajustar os pesos das conexões entre neurônios de modo a melhorar o desempenho computacional da rede. Neste processo, a regra de aprendizagem usualmente

empregada é a da retropropagação de erros (*Backpropagation*). Detalhes sobre a rede MLP e sobre o método da retropropagação de erros podem ser encontrados na literatura técnica sobre redes neurais [13].

4.0 – METODOLOGIA PROPOSTA

Neste trabalho uma metodologia baseada na aplicação de RNs é proposta para a localização de defeitos em sistemas de potência. É explorado o fato de que a identificação de um dado componente defeituoso requer informação apenas de uma área limitada do sistema e uma estratégia local é empregada de modo a reduzir a dimensão do problema. Isto é feito através do emprego de várias RNs, cada uma delas responsável por detectar defeitos envolvendo um número limitado de componentes do sistema. Isto pode ser ilustrado utilizando o sistema de 7 barras apresentado na Figura 2. Este sistema é subdividido em três áreas diferentes, que englobam componentes diferentes. Neste caso, três diferentes RNs são empregadas, cada uma delas responsável por supervisionar componentes do sistema em uma área específica.

FIGURA 2 – SISTEMA ELÉTRICO DE 7 BARRAS



As variáveis de entrada para cada RN correspondem às informações sobre a operação de relés e disjuntores, necessárias para a identificação de componentes com defeito na área supervisionada. Isto em geral envolve alarmes gerados pela operação de relés e disjuntores na área supervisionada e também alguma informação externa. O número de neurônios na camada de saída de cada RN corresponde ao número de componentes sendo supervisionados. Cada neurônio de saída detecta ou rejeita a ocorrência de um defeito em um dado componente. Esta estratégia leva a construção de diversos classificadores neurais com um número reduzido de variáveis de entrada. Cada RN é treinada *off-line*, considerando no conjunto de treinamento diversos padrões de alarme associados à ocorrência de defeitos envolvendo os componentes supervisionados. Estes padrões de alarme incluem ainda situações nas quais o sistema de proteção não opera adequadamente.

Uma vez treinadas, as RNs podem ser utilizadas para fornecer diagnósticos em tempo-real. Quando um conjunto

de alarmes é transmitido ao centro de controle, as etapas básicas podem ser resumidas através dos seguintes passos:

- (i) Seleção das RNs para as quais *ao menos um* dos alarmes recebidos é uma variável de entrada;
- (ii) Teste das RNs selecionadas; e
- (iii) Produção um diagnóstico, baseado na análise das saídas das RNs testadas.

No caso de falhas do sistema de proteção uma área mais extensa do sistema deverá ser desligada, sendo esperado que mais RNs necessitem ser testadas.

5.0 – TESTES E RESULTADOS

A metodologia proposta foi testada para o sistema teste de 7 barras e para parte do sistema da LIGHT. Para o sistema de 7 barras da Figura 2, três diferentes RNs (RN1, RN2 e RN3 para as áreas 1, 2 e 3, respectivamente) são treinadas de modo a aprender a realizar o mapeamento entre os padrões de alarme recebidos e os eventos correspondentes. Cada RN é responsável por identificar componentes com defeito em uma área específica. As variáveis de entrada para uma dada RN consistem dos alarmes sobre a operação de relés e disjuntores dentro da área supervisionada e também uma informação adicional sobre a operação de relés e disjuntores nas áreas externas. As informações consideradas são aquelas descritas na Tabela 1. Por exemplo, para a área 1 tem-se que as variáveis de entrada para a RN1 correspondem aos alarmes gerados pela operação dos seguintes dispositivos:

- Disjuntores (DJ) localizados na área 1;
- Proteção contra falha de disjuntor (BF) para cada disjuntor dentro da área supervisionada;
- Proteção principal (PP), de primeira zona (Z1) e de segunda zona (Z2) dos relés de distância em cada terminal das linhas de transmissão da área supervisionada;
- Relés diferenciais (PD) para proteção de barra (barras A, B e C);
- Operação de qualquer relé de proteção na área 2 (uma única entrada);
- Operação de qualquer relé de proteção na área 3 (uma única entrada);
- Operação de qualquer disjuntor na área 2 (uma única entrada), exceto aqueles conectados à barra A (já considerados acima);
- Operação de qualquer disjuntor na área 3 (uma única entrada), exceto aqueles conectados à barra C (já considerados acima);

As variáveis de entrada para as outras áreas são obtidas utilizando a mesma filosofia. Note que somente duas entradas de cada área externa são consideradas. Estas entradas sinalizam a operação de qualquer relé e/ou disjuntor na área externa. É importante ressaltar que as variáveis de entrada utilizadas possuem uma representação binária e sob condições normais de operação todas essas variáveis são iguais a zero (nenhum alarme recebido). Quando um defeito ocorre, alguns alarmes são recebidos e as variáveis de entrada a eles associadas são feitas iguais a 1.

O número de neurônios de saída para cada RN corresponde ao número de componentes sendo monitorados. Então, para a

RN1 existem cinco neurônios de saída, sendo cada um deles responsável por classificar um componente específico em defeituoso ou não defeituoso.

5.1 Treinamento das RNs

A fase de treinamento das RNs é realizada *offline* e uma única vez. O conjunto de treinamento contém exemplares que representam diversos padrões de alarme, incluindo situações nas quais o sistema de proteção não operou corretamente. Estes padrões de treinamento podem ser obtidos com a ajuda de especialistas e/ou extraídos diretamente de dados históricos sobre a operação do sistema.

Conforme mencionado anteriormente, cada neurônio de saída classifica um dado componente como defeituoso ou não defeituoso. As seguintes saídas desejadas foram utilizadas para cada neurônio de saída durante a fase de treinamento:

- $yd_k = 0,1$, se o componente k não está defeituoso; ou
- $yd_k = 0,9$, se o componente k está defeituoso.

Os valores 0,1 e 0,9 foram utilizados para representar as saídas binárias ao invés de 0,0 e 1,0 visando evitar a região de saturação da função de ativação sigmóide, empregada para modelar os neurônios da rede [13].

5.2 Classificação em Tempo-Real

As RNs treinadas podem então ser testadas para um conjunto de alarmes que incluem padrões inéditos contendo dados com ruído e representando situações nas quais ocorreram falhas do sistema de proteção. Estes padrões de alarme são então apresentados à RN e as saídas obtidas classificam cada componente de acordo com o seguinte critério:

- $0,0 \leq y_k \leq 0,3 \rightarrow$ o componente k não está com defeito
- $0,7 \leq y_k \leq 1,0 \rightarrow$ o componente k está com defeito
- $0,3 < y_k < 0,7 \rightarrow$ classificação indeterminada

As faixas acima foram definidas com base nos resultados obtidos com as simulações utilizando o sistema 7 barras e o sistema Light.

5.3 Avaliação do Desempenho Global

O desempenho do método proposto pode ser avaliado através dos seguintes índices de desempenho:

% de diagnósticos corretos – casos nos quais os componentes defeituosos foram identificados corretamente.

% de diagnósticos incorretos – casos nos quais existe erro na identificação do componente defeituoso.

% de diagnósticos indeterminados – casos nos quais o algoritmo utilizado não foi capaz de produzir um diagnóstico.

Diagnósticos indeterminados podem ocorrer de duas formas: quando existe um ou mais componentes com classificação

indeterminada ou quando mais de um componente é classificado como defeituoso. Diagnósticos indeterminados não são prejudiciais, pois nestas situações o componente defeituoso certamente estará entre aqueles que foram classificados como defeituosos ou apresentaram classificação indeterminada. Dessa maneira é possível fornecer ao operador uma lista de componentes suspeitos para uma posterior análise. Deve-se ressaltar que a ocorrência de defeitos múltiplos não correlacionados não foi considerada neste trabalho.

5.4 Testes com o Sistema 7 barras

Durante a fase de treinamento (*offline*) diversas arquiteturas de redes neurais foram investigadas. Entre estas, as RNs com uma única camada escondida contendo 10 neurônios apresentaram o melhor desempenho.

O algoritmo proposto foi testado para 140 padrões de alarme simulados com o sistema 7 barras da Figura 2. Alguns destes testes são apresentados a seguir de modo a ilustrar a metodologia empregada.

Teste 1: Defeito na barra A

Alarmes recebidos:

- Barra A: PD
- Linha A-B – terminal A: DJ
- Linha A-D – terminal A: DJ
- Linha A-D-E – terminal A: DJ

Note que a informação sobre a abertura do disjuntor da linha A-E não foi recebida. Dentre os alarmes recebidos existem aqueles que são variáveis de entrada para RN1 e RN2, responsáveis por localizar defeitos nas áreas 1 e 2, respectivamente. De acordo com a metodologia proposta estas RNs são executadas e os resultados obtidos são apresentados nas Tabelas 2 e 3.

TABELA 2 – CLASSIFICAÇÕES COM RN1

Neurônios de saída	(1) linha A-B	(2) linha B-C	(3) barra A	(4) barra B	(5) barra C
Saídas obtidas	0,10	0,09	0,89	0,09	0,09

TABELA 3 – CLASSIFICAÇÕES COM RN2

Neurônios de saída	(1) linha A-D	(2) linha A-D-E	(3) linha A-E	(4) barra D	(5) barra E
Saídas obtidas	0,06	0,09	0,11	0,09	0,09

Os resultados apresentados nas Tabelas 2 e 3 mostram que a RN1 identificou corretamente a barra A como defeituosa. Pode-se também notar que a RN2 rejeitou a ocorrência de defeitos envolvendo algum dos componentes por ela supervisionados. A classificação correta foi obtida mesmo na

ausência de informação sobre a abertura do disjuntor da linha A-E. É importante ressaltar que esta situação pode refletir dois cenários diferentes: a informação sobre a abertura do disjuntor não está disponível devido a problemas de comunicação ou devido a linha A-E estar fora de operação. Este último caso ilustra uma capacidade de tratar o problema em diferentes cenários topológicos.

Teste 2: Defeito na linha A-B

Alarmes recebidos:

- Linha A-B – terminal A: Z1, BF
- Linha A-B – terminal B: Z2, DJ
- Linha A-D – terminal A: DJ
- Linha A-D-E – terminal A: DJ
- Linha A-E – terminal A: DJ

Neste caso, nenhuma informação foi recebida sobre a proteção principal dos relés de distância e o disjuntor do terminal A da linha A-B não abriu, apesar de um comando de disparo ter sido enviado. De acordo com a metodologia proposta, RN1 e RN2 são selecionadas. Os resultados obtidos após a execução destas RNs são apresentados nas Tabelas 4 e 5.

TABELA 4 – CLASSIFICAÇÕES COM RN1

Neurônios de saída	(1) linha A-B	(2) linha B-C	(3) barra A	(4) barra B	(5) barra C
Saídas obtidas	0,90	0,09	0,09	0,09	0,09

TABELA 5 – CLASSIFICAÇÕES COM RN2

Neurônios de saída	(1) linha A-D	(2) linha A-D-E	(3) linha A-E	(4) barra D	(5) barra E
Saídas obtidas	0,11	0,09	0,09	0,11	0,09

Os resultados apresentados nas Tabelas 4 e 5 mostram que RN1 identificou corretamente o defeito na linha A-B, enquanto RN2 rejeitou a ocorrência de defeitos envolvendo algum elemento supervisionado por ela.

Teste 3: Defeito na linha B-C

Alarmes recebidos:

- Linha B-C – terminal B: Z1, DJ
- Linha B-C – terminal C: Z2, DJ
- Linha C-G – terminal G: Z2, DJ

Neste caso a proteção principal (PP) não operou, tendo sido recebida a informação sobre a operação da proteção de primeira zona no terminal B da linha B-C e das proteções de segunda zona nos terminais C e G das linhas B-C e C-G, respectivamente. Foi também recebida a informação sobre os disjuntores que abriram. De acordo com a metodologia

proposta, RN1 e RN3 são selecionadas e executadas. As Tabelas 6 e 7 apresentam os resultados obtidos.

TABELA 6 – CLASSIFICAÇÕES COM RN1

Neurônios de saída	(1) linha A-B	(2) linha B-C	(3) barra A	(4) barra B	(5) barra C
Saídas obtidas	0,10	0,85	0,08	0,11	0,07

TABELA 7 – CLASSIFICAÇÕES COM RN3

Neurônios de saída	(1) linha C-F	(2) linha C-G	(3) linha F-G	(4) Barra F	(5) Barra G
Saídas obtidas	0,10	0,30	0,12	0,10	0,08

Os resultados nas Tabelas 6 e 7 mostram que RN1 identificou corretamente a ocorrência do defeito na linha B-C, enquanto RN3 rejeitou a ocorrência de defeitos em um de seus componentes supervisionados.

A Tabela 8 apresenta o desempenho global do método para diversos padrões de alarme correspondentes a defeitos no sistema 7 barras. Como pode ser visto, o método proposto apresentou excelente desempenho. Diagnósticos incorretos e indeterminados ocorrem principalmente para padrões de alarme inéditos e bastante corrompidos. Estes padrões são de difícil ocorrência e estão associados a falhas múltiplas do sistema de proteção e perdas de informação sobre alarmes importantes.

TABELA 8 – DESEMPENHO GLOBAL PARA O SISTEMA 7 BARRAS

Número de padrões testados	140
Diagnósticos corretos	90 %
Diagnósticos incorretos	1,43 %
Diagnósticos indeterminados	8,57 %

O desempenho do método pode ainda ser melhorado se alguns padrões com diagnóstico indeterminado forem incluídos no conjunto de treinamento. É importante ressaltar que o esforço computacional para obter classificações através das redes treinadas pode ser considerado desprezível.

5.5 Testes com o Sistema Light

O método também foi testado para parte do sistema da Light, ilustrado na Figura 3. Testes foram realizados considerando defeitos nas áreas 1,2, 3 e 4. Estas áreas foram definidas arbitrariamente. Os alarmes considerados são gerados pelos dispositivos apresentados na Tabela 1. A seleção das variáveis de entrada e saída das RNs seguiu o mesmo critério adotado para o sistema 7 barras. O treinamento das RNs e a estratégia para classificação em tempo-real são conforme descrito nas Seções 5.1 e 5.2.

A Tabela 9 apresenta os resultados globais obtidos para o sistema Light, baseados no desempenho das RNs

responsáveis por supervisionar os componentes das áreas 1, 2, 3 e 4. Os casos testados consistem de diversos padrões de alarme, incluindo falhas do sistema de proteção, perda de dados, dados corrompidos, etc.

TABELA 9 – DESEMPENHO GLOBAL PARA O SISTEMA LIGHT

Número de padrões testados	93
Diagnósticos corretos	94,62 %
Diagnósticos incorretos	1,08 %
Diagnósticos indeterminados	4,30 %

Os resultados da Tabela 9 mostram que o método apresentou excelente desempenho para o sistema Light. Assim como para o sistema 7 barras, diagnósticos indeterminados ocorreram para a apresentação de padrões de alarme bastante difíceis, que causariam dúvidas até mesmo aos mais experientes especialistas. Diagnósticos incorretos foram devidos a padrões de alarme bastante corrompidos.

6.0 CONCLUSÕES

Este trabalho apresentou um método para processamento de alarmes e localização de defeitos em sistemas de energia elétrica. É adotada uma estratégia local, onde diversas redes neurais são empregadas, cada uma delas sendo responsável por detectar defeitos envolvendo um número limitado de componentes do sistema. As redes neurais são treinadas *offline* para vários padrões de alarme diferentes. Após

treinadas, as RNs são utilizadas para a produção de diagnósticos em tempo-real. Os resultados apresentados para um sistema teste de 7 barras e para o sistema Light confirmaram a excelente capacidade de generalização e discriminação oferecida pelas RNs. Classificações corretas são obtidas mesmo em situações difíceis, que envolvem falhas do sistema de proteção, perda de dados, dados corrompidos e outros padrões não considerados na fase de treinamento. Devido a estratégia local adotada, a metodologia proposta pode ser facilmente implementada para sistemas de grande porte.

AGRADECIMENTOS

Os autores agradecem o apoio recebido do CNPq, FAPERJ, LIGHT e FINEP/RECOPE (Projeto SAGE 0626/96) para a execução deste trabalho.

REFERÊNCIAS

- [1] Pfau-Wagenbauer, M., Brugger, H., "Model and rule based intelligent alarm processing", *Proceedings of the Third Symposium on Expert Systems Application to Power Systems*, April 1-5, 1991, Tokyo-Kobe, Japan, pp. 27-32.
- [2] Kirschen, D.S., Wollenberg, B.F., "Intelligent alarm processing in power systems" *Proceedings of IEEE*, Vol. 80, No. 5, May 1992, pp 663-672.
- [3] CIGRE TF 38-06-02, Convenor – T. Dillon, "Survey on expert systems in alarm handling", *Electra*, No. 139, pp. 133-147, 1991.
- [4] CIGRE TF 38-06-06 on Artificial Neural Networks Applications for Power Systems, Dagmar Niebur (convenor), "Neural network applications in power systems", *Int. Journal of Engineering Intelligent Systems*,

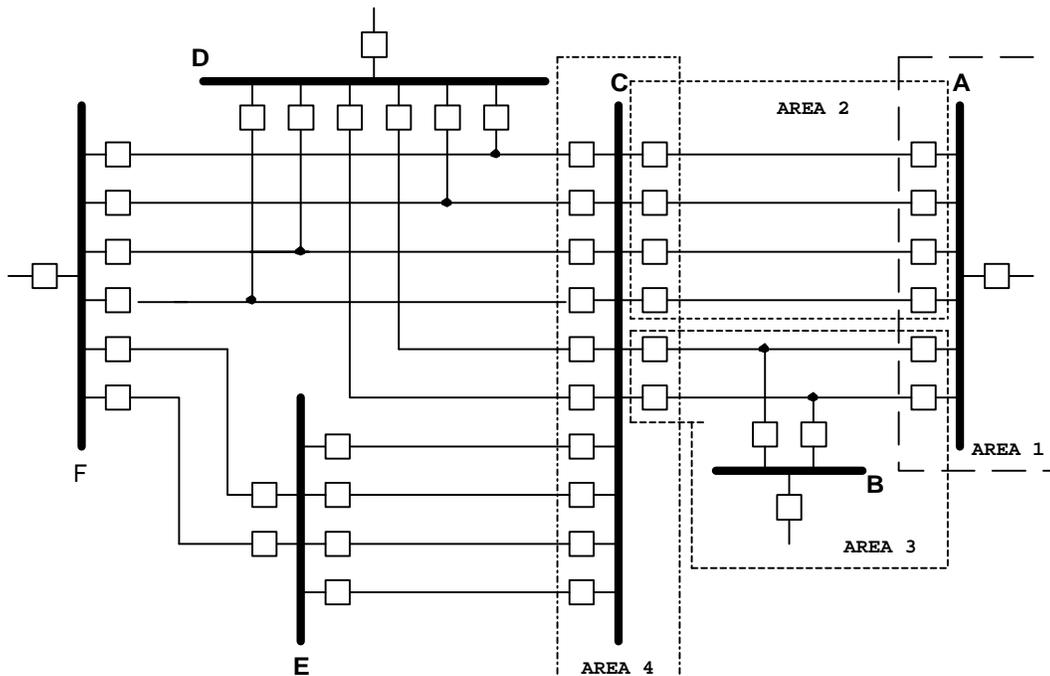


FIGURA 3 – PARTE DO SISTEMA LIGHT

- Vol.1, No.3, pp.133-158, Dec. 1993.
- [5] Souza, J.C.S., Leite da Silva, A.M., Alves da Silva, A.P., "Data debugging for real-time power system monitoring based on pattern analysis", *IEEE Trans. on Power - Systems*, Vol.11, No.3, pp.1592-1599, Aug. 1996.
 - [6] Souza, J.C.S., Leite da Silva, A.M., Alves da Silva, A.P., "Online Topology Determination and Bad Data Suppression in Power System Operation Using Artificial Neural Networks", Proceedings of the XX *International Conference on Power Industry Computer Applications (PICA'97)*, pp. 46-53, Columbus, Ohio, maio de 1997.
 - [7] Falcão, D.M. (Convener), Souza, J.C.S. et alli, "Intelligent Systems Applications to Power Systems in Brazil: Present status and Perspectives", a report prepared by the Working Group 05 of the Study Committee 38 of CIGRÉ Brazil, Proceedings of the VI *Symposium of Specialists in Electric Operational and Expansion Planning*, (VI SEPOPE), Salvador, Bahia, Maio de 1998.
 - [8] Jongepier, A.G., Dijk, H.E., van der Sluis, L., "Neural networks applied to alarm processing", *Proceedings of the Third Symposium on Expert Systems application to Power Systems*, 1991, Tokyo-Kobe, Japan, pp. 615-621.
 - [9] Kim, K., Park, J., "Application of hierarchical neural network to fault diagnosis of power systems", *Proceedings of the Third Symposium on Expert Systems application to Power Systems*, 1991, Tokyo-Kobe, Japan, pp. 323-327.
 - [10] Rementeria, S., Rodriguez, C., Pérez, J., Martín, J.I., Lafuente, A., Muguera, J., "Expert systems & neural networks in power grid fault diagnosis: an empirical comparison", *Engineering Intelligent system*, vol. 3, No. 1, March 1995, pp. 33-44.
 - [11] Handschin, E., Kuhlmann, D., Hoffmann, W., "Fault diagnosis in electrical energy systems using device-specific artificial neural networks", *Engineering Intelligent Systems*, Vol. 2, December, 1994, pp. 255-262.
 - [12] T. S. Dillon, D. Niebur (Editors), "*Neural Network Applications in Power Systems*", CRL Pub. Ltd., London, UK, (Chap. 2), 1996.
 - [13] S.Haykin, *Neural Networks: A Comprehensive Foundation*, Macmillan College Publishing Company, 1994.