

---

# UTILIZAÇÃO DE UM MODELO NEURO-FUZZY PARA A LOCALIZAÇÃO DE DEFEITOS EM SISTEMAS DE POTÊNCIA

**E. B. M. Meza\***  
emitacc@ic.uff.br

**M. Th. Schilling†**  
schilling@ic.uff.br

**J. C. Stacchini de Souza†**  
julio@ic.uff.br

**M. B. Do Coutto Filho\***  
mbrown@ic.uff.br

\*Instituto de Computação, Universidade Federal Fluminense

†Departamento de Engenharia Elétrica, Universidade Federal Fluminense  
Rua Passo da Pátria, 156, Bloco E, sala 350 - Niterói -Rio de Janeiro

---

## ABSTRACT

This work presents the application of a neuro-fuzzy model for alarm processing and fault location in power systems. Different techniques to establish the fuzzy relations among alarm patterns and fault occurrences in power systems are examined. Fuzzy relations are constructed and form a database that is employed to train artificial neural networks. The artificial neural networks have alarm patterns as inputs and each output neuron is responsible for estimating the degree of membership of a specific system component into the class of faulted components. Tests are performed with a 7-bus test system and with part of a real brazilian system.

**KEYWORDS:** Power system protection; Alarm processing; Fuzzy logic; Artificial neural networks.

## RESUMO

Este trabalho apresenta a aplicação de um modelo neuro-fuzzy para o processamento de alarmes e localização de defeitos em sistemas de potência. Diferentes técnicas são investigadas para o estabelecimento de relações fuzzy entre padrões de alarme e defeitos no sistema. Uma base de dados contendo as relações fuzzy é empregada para o treinamento de redes neurais artificiais. Os vetores de entrada das redes neurais são constituídos por padrões de alarmes associados a diferentes eventos e cada neurônio de saída é responsável por

estimar o grau de pertinência de um componente específico na classe de componentes defeituosos. Testes são realizados utilizando um sistema de 7 barras e também um sistema real.

**PALAVRAS-CHAVE:** Proteção de sistemas de potência, Processamento de alarmes, Lógica fuzzy, Redes neurais.

## 1 INTRODUÇÃO

Em sistemas elétricos de potência, muitas mensagens e alarmes são transmitidos ao centro de controle após a ocorrência de distúrbios. Estes distúrbios são, em geral, provocados por defeitos que podem ser de diferentes tipos e ocorrer em qualquer parte do sistema. Os equipamentos de proteção são responsáveis por detectar a ocorrência de um defeito e isolar somente a parte defeituosa do sistema. É também muito importante restaurar as condições normais de operação do sistema o mais rapidamente possível. Portanto, é fundamental que a localização do defeito seja determinada de forma rápida e precisa. No centro de controle o operador geralmente necessita tirar conclusões e tomar decisões a partir da análise de um conjunto muito grande de informações, o que pode levar um tempo demasiadamente grande. Além do grande volume de informações a serem processadas, outros problemas como: falhas no sistema de proteção, problemas de comunicação, aquisição de dados corrompidos, etc. podem tornar a localização de defeitos uma tarefa bastante complicada.

A aplicação de sistemas inteligentes para o diagnóstico de defeitos tem sido proposta na literatura. Como tentativas iniciais, sistemas especialistas baseados em regras foram propostos (CIGRE, 1991; Handschin & Hoffmann, 1992; Kirschen & Wollenberg, 1992; Liu & Tomsovic, 1987; Pfau-Wagenbauer & Brugger, 1991). Nestas aplicações, o conhecimento e a experiência do especialista humano são explorados para a construção de uma base de conhecimento e formulação de um conjunto de regras que formarão o mecanismo de inferência a ser utilizado para a obtenção de diagnósticos. Quando um defeito ocorre, um padrão de alarmes é transmitido ao centro de controle, regras são disparadas e um diagnóstico é produzido. Contudo, os sistemas especialistas são capazes de produzir resultados satisfatórios apenas para as situações previstas durante o desenvolvimento da base de conhecimento. A maior limitação destas aplicações reside na dificuldade de tratar padrões de alarmes novos ou corrompidos.

Alguns métodos baseados na aplicação de Redes Neurais Artificiais (RNAs) também foram propostos para o processamento de alarmes (CIGRE, 1993; Handschin et al., 1994; Mazon et al., 2003; Rodrigues et al., 2001; Silva et al., 1995; Souza et al., 2001). As RNAs apresentam capacidade de generalização e respondem bem para padrões inéditos. Entretanto, na ocorrência de certos padrões de alarme, pode ser difícil interpretar as respostas obtidas pelas saídas da rede neural. Isto ocorre porque os classificadores neurais são treinados para fornecer saídas binárias, o que faz com que certos resultados (saídas com valores intermediários, na faixa entre 0 e 1) não permitam uma interpretação adequada para posterior diagnóstico. Métodos baseados na aplicação de lógica fuzzy também foram propostos (Chow & Park, 1997; Meza et al., 2002; Chin, 2003; Sun, 2004). No entanto, estes métodos não apresentam bom desempenho na presença de dados corrompidos ou no caso de falhas na comunicação de dados (informação não recebida).

Este trabalho investiga a utilização de um modelo Neuro-Fuzzy para o processamento de alarmes e localização de defeitos em sistemas de potência. É proposto um procedimento para a construção de redes neurais, as quais são capazes de realizar o mapeamento fuzzy de alarmes recebidos após um defeito para saídas (respostas) que refletem o grau de incerteza da inferência realizada, fornecendo subsídios realistas para a identificação do defeito. O modelo utilizado contempla a introdução de conhecimento qualitativo sobre o problema tratado (lógica fuzzy) e apresenta características como robustez, tolerância a falhas e generalização (redes neurais). A metodologia proposta pode ser aplicada a sistemas de transmissão ou distribuição. No desenvolvimento deste trabalho foi enfocada a aplicação a sistemas de transmissão, sendo apresentados resultados de simulações com um sistema teste e com parte de um sistema real.

## 2 PROTEÇÃO DE SISTEMAS ELÉTRICOS DE POTÊNCIA

Os sistemas de proteção são projetados de forma a isolar componentes defeituosos na rede elétrica. Entre as características mais desejáveis de um sistema de proteção destacam-se: velocidade de atuação, seletividade e coordenação. Após a ocorrência de um defeito, os componentes defeituosos devem ser isolados o mais rapidamente possível para evitar o risco de 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. Portanto, os equipamentos de proteção como relés e disjuntores devem ser seletivos, ou seja, devem garantir que apenas os componentes sob defeito sejam desligados do sistema elétrico. 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 deverão atuar de forma a eliminar o defeito. Neste caso, o número de componentes que são desligados é em geral maior, o que pode dificultar a localização do defeito.

Os relés diferenciais e relés de distância são os equipamentos mais utilizados para a proteção de barramentos e linhas de transmissão em sistemas de potência. 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 defeitos em 100% da linha de transmissão, devendo operar de forma instantânea), a proteção de primeira zona (responsável por proteger cerca de 80% da linha de transmissão, 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 de transmissão, serve como proteção de retaguarda para linhas de transmissão adjacentes). Um esquema de proteção contra falha de disjuntor pode também ser utilizado. Quando a falha de operação de um disjuntor é detectada, um comando é enviado instantaneamente para a abertura dos disjuntores associados ao barramento do disjuntor sob falha. Este esquema reduz o risco de danos aos equipamentos do sistema que ficariam submetidos a uma condição de defeito por um longo período de tempo. Os alarmes considerados neste trabalho são provenientes da operação dos dispositivos de proteção ilustrados na Figura 1.

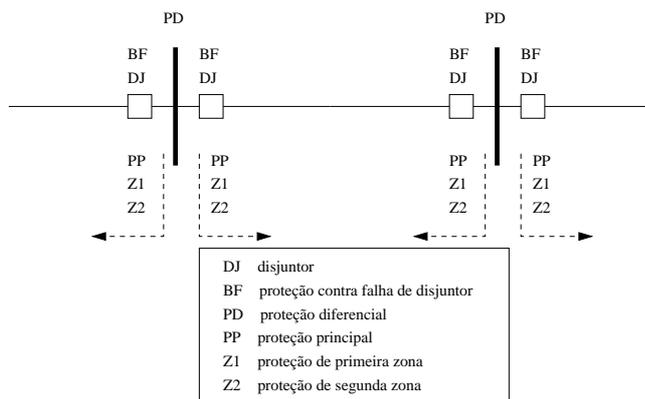


Figura 1: Dispositivos de proteção

### 3 INFERÊNCIA FUZZY

Imprecisão e incerteza são duas características que podem estar presentes nas informações a serem processadas durante a solução de uma grande variedade de problemas. A teoria da probabilidade tem sido largamente empregada para a representação de incertezas. A incerteza nos dados tem sido representada e tratada utilizando modelos estatísticos, a teoria da probabilidade e processos estocásticos. Apesar de bastante útil, estas teorias e modelos podem não ser capazes de perceber e representar adequadamente diversos aspectos das informações fornecidas por especialistas humanos.

A teoria dos conjuntos fuzzy (Zadeh, 1965) foi desenvolvida para tratar imprecisões, ambigüidades e incertezas nas informações, sendo adequada para tratar problemas que apresentam uma ou mais das seguintes características (El-Hawary et al, 1998):

- a interação com especialistas humanos é exigida;
- um especialista está disponível para especificar as regras que regem o comportamento do sistema e as representações fuzzy;
- um modelo matemático para o problema não existe ou é difícil de ser implementado;
- dados imprecisos e com ruído estão presentes.

Através do emprego da lógica fuzzy é possível, em muitos casos, representar de forma adequada complexas fronteiras de decisão, ou seja, é possível mapear transições graduais entre estados de decisão. Assim, um elemento de um conjunto fuzzy pode ao mesmo tempo pertencer a outros conjuntos fuzzy. O grau de ambigüidade ou imprecisão da associação deste elemento a cada conjunto fuzzy pode ser descrito pelos

correspondentes graus de pertinência. Em problemas que envolvem classificação de padrões é possível, ao invés de tentar associar cada padrão a uma única classe, calcular o grau de pertinência associado a cada classe do problema. Isto permite tratar problemas com fronteiras de decisão complexas, onde a classificação pode ser obtida a partir da análise dos graus de pertinência calculados. Os fundamentos matemáticos dos conjuntos fuzzy estão largamente cobertos pela literatura técnica (Zimmermann, 1985).

### 3.1 Agregação – Famílias de Operadores

Os operadores *min* e *max* têm sido usualmente adotados para representar a interseção e a união de conjuntos fuzzy, respectivamente. Outros operadores foram também propostos, variando no que diz respeito a generalidade e adaptabilidade, assim como nas situações onde sua utilização é justificada (El-Hawary et al, 1998). A adaptabilidade pode ser obtida através do emprego de famílias de operadores paramétricos, as quais podem ser bastante úteis para a obtenção de graus de pertinência em uma grande variedade de problemas. Esta seção apresenta os operadores paramétricos que serão investigados neste trabalho para a construção de associações fuzzy no problema de processamento de alarmes.

#### 3.1.1 Modelo Hamacher

Este modelo utiliza operadores paramétricos, propostos por Hamacher (El-Hawary et al, 1998). A interseção (norma-t) e união (norma-s) de dois conjuntos difusos A e B são definidas em função de um parâmetro  $\gamma$ , como:

$$\mu_{A \cap B}(x) = t_H(a; b) = \frac{ab}{\gamma + (1 - \gamma)(a + b - ab)} \quad (1)$$

$$\mu_{A \cup B}(x) = s_H(a; b) = \frac{a + b + (\gamma' - 1)ab}{1 + \gamma' ab} \quad (2)$$

onde  $a = \mu_A(x)$ ,  $b = \mu_B(x)$ ,  $\gamma \geq 0$ ,  $\gamma' \geq -1$  e  $\gamma' = \gamma - 1$ , sendo  $\mu_A(x)$  e  $\mu_B(x)$  os graus de pertinência de  $x$  nas classes A e B, respectivamente.

#### 3.1.2 Modelo Yager

Este modelo utiliza operadores paramétricos, propostos por Yager (Yager, 1980). A interseção e união de dois conjuntos difusos A e B são definidas em função de um parâmetro  $p$  como:

$$\mu_{A \cap B}(x) = t_Y(a; b) = 1 - \min \left\{ 1, [(1-a)^p + (1-b)^p]^{1/p} \right\} \quad (3)$$

$$\mu_{A \cup B}(x) = s_Y(a; b) = 1 - \min \left\{ 1, [a^p + b^p]^{1/p} \right\} \quad (4)$$

onde  $a = \mu_A(x)$ ,  $b = \mu_B(x)$  e  $p \geq 1$ .

### 3.1.3 Modelo Dubois & Prade

Este modelo utiliza operadores paramétricos, propostos por Dubois e Prade (Dubois & Prade, 1980). A interseção e união de dois conjuntos difusos A e B são definidas em função de um parâmetro  $\alpha$ , como:

$$\mu_{A \cap B}(x) = t_{DP}(a; b) = \frac{ab}{\max(a, b, \alpha)} \quad (5)$$

$$\mu_{A \cup B}(x) = s_{DP}(a; b) = \frac{a + b - ab - \min\{a, b, (1-\alpha)\}}{\max\{(1-a), (1-b), \alpha\}} \quad (6)$$

onde  $a = \mu_A(x)$ ,  $b = \mu_B(x)$  e  $0 \leq \alpha \leq 1$ .

### 3.1.4 Modelo Dombi

Este modelo utiliza operadores paramétricos, propostos por Dombi (Dombi & Vas, 1983). A interseção e união de dois conjuntos difusos A e B são definidas em função de um parâmetro  $\lambda$ , como:

$$\mu_{A \cap B}(x) = t_D(a; b) = \frac{1}{1 + [(1/a - 1)^\lambda + (1/b - 1)^\lambda]^{1/\lambda}} \quad (7)$$

$$\mu_{A \cup B}(x) = s_D(a; b) = \frac{1}{1 + [(1/a - 1)^{-\lambda} + (1/b - 1)^{-\lambda}]^{-1/\lambda}} \quad (8)$$

onde  $a = \mu_A(x)$ ,  $b = \mu_B(x)$  e  $\lambda \in (0, \infty)$ .

## 4 RELAÇÕES FUZZY PARA O PROCESSAMENTO DE ALARMES

O processamento de alarmes para a localização de defeitos em sistemas de potência envolve incertezas que podem ser ocasionadas por diversos fatores, tais como: operação inadequada do sistema de proteção, perda de informação, falha nos dispositivos de proteção, etc. Estas incertezas podem ser levadas em consideração através da obtenção de relações fuzzy capazes de representar o grau de associação entre padrões de alarmes e os componentes do sistema.

Neste trabalho, as relações fuzzy são representadas por diagramas sagitais. Três conjuntos de nós são considerados para representar os componentes do sistema, relés de proteção e disjuntores. Os diagramas sagitais são construídos considerando as relações causais entre a operação de relés e disjuntores na ocorrência de um defeito, sendo a causalidade denotada por setas. Considerando o sistema teste representado na Figura 2, um diagrama sagital pode ser construído para cada componente da rede. A Figura 3 ilustra o diagrama sagital para o ramo de transmissão A-B.

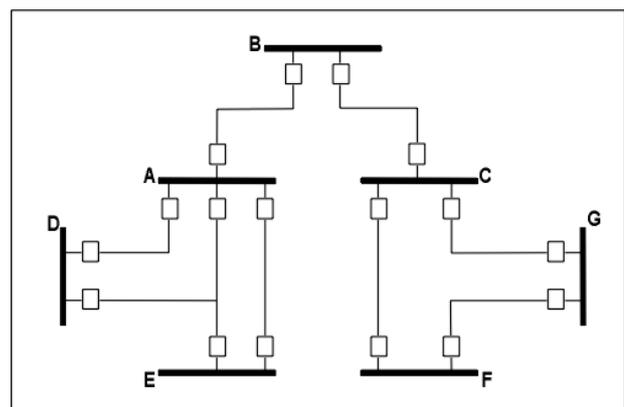


Figura 2: Sistema teste de 7 barras

Os valores sobre cada linha conectando dois nós são determinados com o auxílio de especialistas em proteção de sistemas de potência e representam os graus de associação entre componentes do sistema, relés de proteção e disjuntores. Tais valores devem ser definidos em função do conhecimento sobre os esquemas de proteção sendo utilizados e da experiência extraída do seu histórico de operação. Os dispositivos de proteção considerados são aqueles previamente apresentados na Figura 1. Para cada componente, as designações sobre as setas refletem o grau de pertinência de cada relé que pode atuar em caso de defeito envolvendo o componente. Por exemplo, a associação entre o defeito em uma linha de transmissão e a atuação da proteção de 2ª zona é mais fraca do que a associação com a atuação da proteção de 1ª zona, já que a primeira possui menor seletividade, podendo atuar também

em casos de defeitos em linhas adjacentes. As associações entre relés e disjuntores são estabelecidas utilizando um procedimento análogo. A qualidade dos valores atribuídos pode ser verificada e ajustada em função dos resultados obtidos após a realização das operações fuzzy para diversos padrões de alarme. A certeza de que um padrão de alarme indica a ocorrência de defeito em um dado equipamento deve se refletir na obtenção de um grau de pertinência alto deste equipamento na classe dos equipamentos defeituosos, enquanto os demais componentes devem apresentar graus de pertinência baixos. Padrões de alarme mais difíceis (por exemplo, quando ocorrem falhas no sistema de proteção) se traduzem em uma proximidade em maior ou menor grau (dependendo do padrão) entre os graus de pertinência associados ao equipamento defeituoso e aos demais equipamentos. Uma escolha inadequada dos valores da Figura 3 seria detectada pela ocorrência de mapeamentos incorretos para certos padrões de alarme, ou seja, pela obtenção de graus de pertinência elevados para equipamentos considerados claramente não defeituosos pelos especialistas e/ou graus de pertinência muito baixos para os equipamentos que, segundo os especialistas, estariam defeituosos.

O mapeamento fuzzy entre padrões de alarme e cada componente do sistema pode ser obtido, com o auxílio dos diagramas sagitais, em duas etapas:

- (i). Interseção das designações sobre as linhas que formam um caminho entre o componente, relés e disjuntores (cujos alarmes foram recebidos); e
- (ii). União dos resultados obtidos no passo (i).

Os resultados do passo (ii) determinam o grau de pertinência do padrão de alarme com relação aos componentes do sistema.

Existem diversas classes de operadores para a realização da interseção e união de conjuntos fuzzy. Nesta seção será investigada a aplicação das famílias de operadores paramétricos descritas na Seção 3. É importante observar que a escolha de valores para os parâmetros em cada modelo pode ser crucial para a obtenção de graus de pertinência que reflitam adequadamente as relações fuzzy entre padrões de alarme e os componentes sob suspeita de estarem defeituosos.

#### 4.1 Exemplo do Mapeamento Fuzzy

De modo a exemplificar o mapeamento fuzzy, considere que o seguinte padrão de alarmes foi recebido após da ocorrência de um defeito na linha A-B do sistema da Figura 2:

- Linha A-B terminal A: **Z1** e **DJ**.

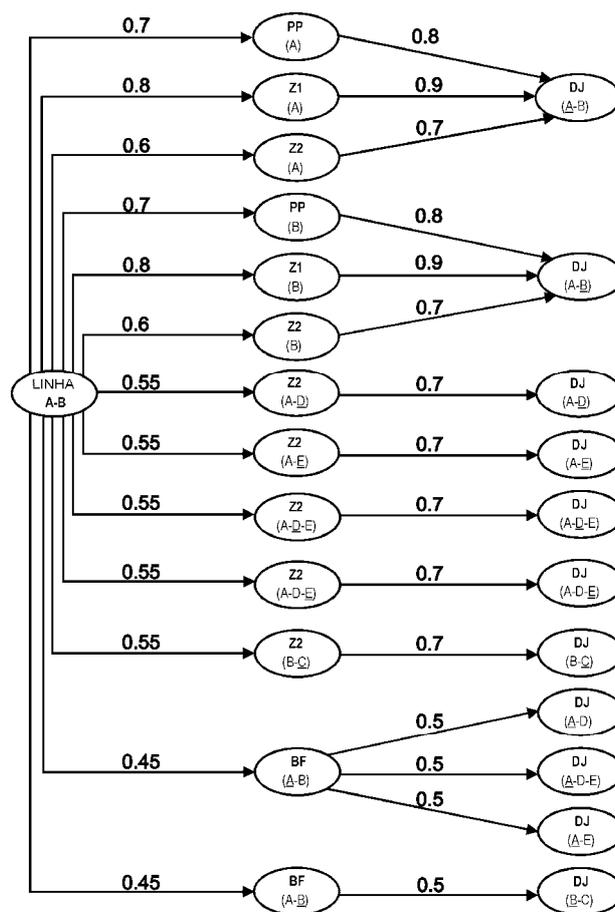


Figura 3: Diagrama sagital para a linha de transmissão A-B

- Linha A-B terminal B: **Z2** e **DJ**.

A Figura 4 ilustra o diagrama sagital da linha A-B, onde estão representados os caminhos através dos nós que representam os alarmes recebidos após o defeito.

Conforme foi descrito anteriormente, o mapeamento fuzzy é obtido em duas etapas, necessárias para a determinação do grau de pertinência do componente na classe de componentes defeituosos. A Tabela 1 ilustra a aplicação dos operadores paramétricos descritos na Seção 3 para a obtenção do mapeamento fuzzy para a linha A-B, a partir do padrão de alarmes representado na Figura 4.

Os resultados da Etapa (ii) indicam os graus de pertinência da linha A-B na classe de componentes defeituosos. Os resultados foram obtidos quando se utilizou, em cada modelo, os parâmetros indicados na tabela, os quais foram arbitrariamente escolhidos para esta ilustração. De modo análogo é possível também obter os graus de pertinência associados a outros componentes da rede, utilizando os respectivos diagramas sagitais.

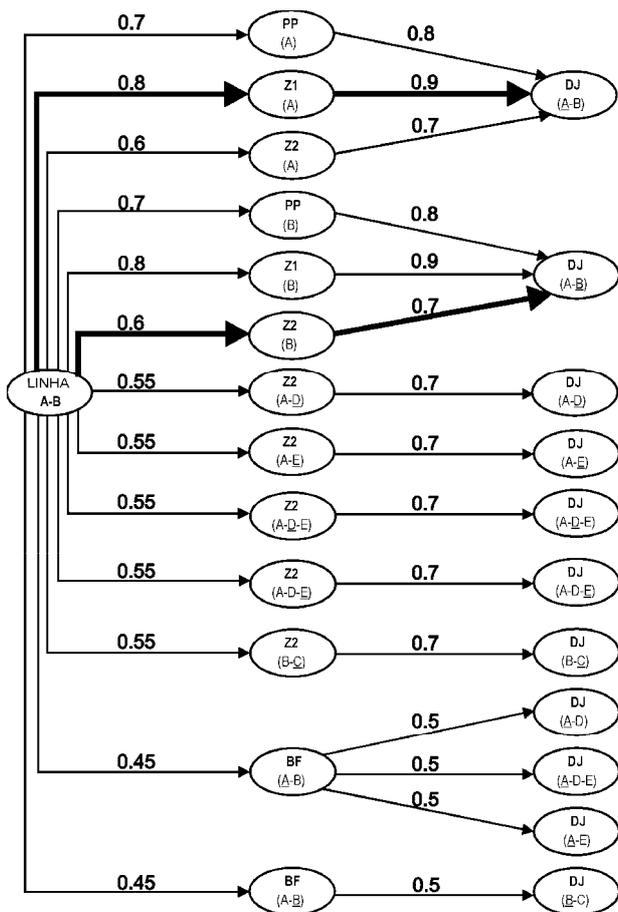


Figura 4: Diagrama sagital - ocorrência de um defeito

Modelo	Etapa (i)	Etapa (ii)
Harnacher ( $\gamma = 3$ e $\gamma' = 2$ )	$t_H(0,8;0,9) = 0,69$	$s_H(0,69;0,34) = 0,86$
	$t_H(0,6;0,7) = 0,34$	
Yager ( $p = 3$ )	$t_Y(0,8;0,9) = 0,79$	$s_Y(0,79;0,55) = 0,87$
	$t_Y(0,6;0,7) = 0,55$	
Dubois & Prade ( $\alpha = 0,8$ )	$t_{DP}(0,8;0,9) = 0,80$	$s_{DP}(0,8;0,53) = 0,88$
	$t_{DP}(0,6;0,7) = 0,53$	
Dombi ( $\lambda = 0,6$ )	$t_D(0,8;0,9) = 0,64$	$s_D(0,64;0,37) = 0,78$
	$t_D(0,6;0,7) = 0,37$	

Tabela 1: Exemplo de mapeamento fuzzy

## 4.2 Avaliação dos Operadores

Diversos testes foram realizados de modo a avaliar o desempenho dos operadores paramétricos na obtenção das relações fuzzy entre padrões de alarme e componentes do sistema. Os casos utilizados para teste consistiram de padrões de alarme relativos a várias condições de defeito, incluindo situações de falha no sistema de proteção. Simulações foram realizadas

utilizando o sistema teste representado na Figura 2 e o sistema da Light Serviços de Eletricidade S.A., ilustrado na Figura 5. Os modelos de operadores foram testados utilizando-se diferentes valores para os respectivos parâmetros. Após os parâmetros de cada modelo terem sido ajustados, os mesmos foram comparados.

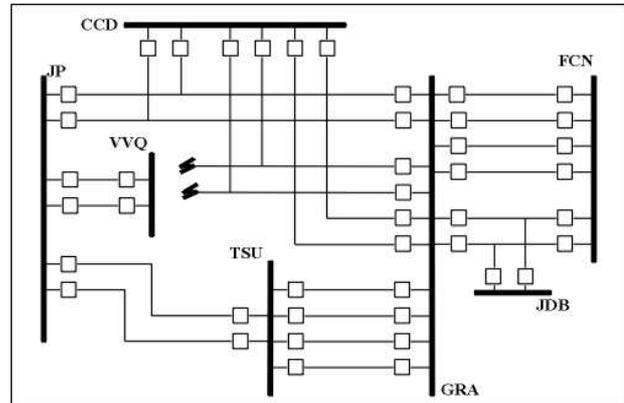


Figura 5: Sistema da Light

O grau de pertinência de cada padrão de alarme é calculado utilizando cada modelo, de acordo com as equações e procedimentos descritos nas seções anteriores. Após calcular o grau de pertinência associado a todos os padrões de alarme testados, pode-se realizar uma análise qualitativa para a identificação do melhor parâmetro de cada modelo, assim como do modelo mais adequado ao problema de processamento de alarmes.

Por exemplo, componentes sob defeito podem ser facilmente identificados se suas proteções primárias atuarem corretamente. Nesses casos, é esperado e desejável que os graus de pertinência associados aos componentes com defeito apresentem valores elevados, enquanto aqueles associados a componentes não defeituosos devem apresentar valores baixos. Entretanto, na ocorrência de falhas no sistema de proteção, pode ser difícil associar os padrões de alarme obtidos ao componente com defeito. Nessas situações, é esperado que os graus de pertinência do componente com defeito e de outros componentes não defeituosos (geralmente vizinhos) sejam mais próximos. Contudo, é desejável que o grau de pertinência do componente sob defeito ainda apresente o maior valor, evitando a superposição com os componentes não defeituosos, para os quais é interessante, por outro lado, associar os menores valores possíveis dos graus de pertinência. Tais características foram consideradas na análise dos resultados obtidos. Diversos valores para os parâmetros de cada modelo foram testados e aqueles identificados como os mais adequados em cada caso são apresentados na Tabela 2.

A comparação entre os modelos apresentados na Tabela 2

indicou ainda que o modelo Hamacher com parâmetro  $\gamma = 5$  apresentou os melhores resultados.

Modelo	Valor do parâmetro
Hamacher	$\gamma = 5$
Yager	$p=2$
Dubois & Prade	$\alpha = 0,95$
Dombi	$\lambda = 0,4$

Tabela 2: Escolha dos parâmetros

Os resultados da Tabela 2 foram obtidos através de uma análise qualitativa. Porém, é possível também estabelecer uma métrica para a comparação entre as diferentes escolhas de parâmetros e modelos. Tal métrica deve ser capaz de medir a capacidade de discriminação de cada modelo, devendo ser baseada no afastamento entre os valores dos graus de pertinência associados aos componentes defeituosos e aos componentes não defeituosos. Pode-se citar, como exemplo, o cálculo da distância média entre o grau de pertinência associado aos componentes defeituosos e os graus de pertinência associados aos demais componentes. Tal distância pode ser obtida calculando-se a diferença média entre os graus de pertinência associados ao componente defeituoso e aos demais componentes para cada padrão de alarme que forma a base de treinamento e, em seguida, a média das distâncias calculadas para cada padrão. Outras formas diferentes de obter tal métrica podem também ser propostas, como, por exemplo, realizar o cálculo apenas para os padrões correspondentes a situações de falhas no sistema de proteção, os quais podem levar a graus de pertinência mais próximos ou superpostos, dificultando o processo de classificação. Não está no escopo deste trabalho investigar e propor tais métricas. Na aplicação realizada, a análise baseada na inspeção dos resultados obtidos foi suficiente para decidir quanto a escolha do modelo e parâmetro mais adequados.

## 5 MODELO NEURO-FUZZY

Os modelos fuzzy permitem levar em consideração informações qualitativas fornecidas por especialistas humanos, tais como operadores com experiência em proteção de sistemas de potência. Por outro lado, os modelos de redes neurais, que podem ter dificuldades para representar alguma informação qualitativa, apresentam características como capacidade de generalização e tolerância a falhas, os quais são altamente desejáveis para a execução de um mapeamento complexo, particularmente quando o domínio do problema não pode ser completamente coberto e representado pela perícia humana.

Nesta seção, um modelo neuro-fuzzy é proposto para o processamento de alarmes e localização de defeitos em sistemas de potência. Em uma primeira etapa, as associações fuzzy entre padrões de alarme e componentes do sistema são obti-

das conforme o processo descrito na Seção 4. Em uma segunda etapa, a base de dados contendo as associações fuzzy é utilizada como conjunto de treinamento para redes neurais artificiais. Finalmente, estas são treinadas para estimar os graus de pertinência de cada componente do sistema na classe de componentes com defeito.

### 5.1 Conjunto de Treinamento Fuzzy

Na Seção 4.2, diferentes simulações foram executadas para comparar as quatro famílias de operadores com respeito ao seu desempenho na obtenção de relações fuzzy entre padrões de alarme e componentes do sistema. Dentre as famílias testadas, o modelo Hamacher com  $\gamma = 5$  foi identificado como o mais adequado para o problema de localização de defeitos aqui tratado. Assim, a base de dados obtida com a aplicação do modelo Hamacher para vários diferentes padrões de alarmes será utilizada para a construção do conjunto de treinamento para redes neurais artificiais.

### 5.2 Classificadores Neurais

A construção das RNAs explora o fato de que é possível identificar o componente defeituoso baseando-se unicamente nos alarmes que chegam de uma área restrita do sistema. Assim, uma estratégia local é adotada para reduzir a dimensão do problema. Esta estratégia utiliza várias RNAs, onde cada uma delas é responsável por estimar o grau de pertinência dos componentes de uma dada área. Na Figura 6, o sistema de 7 barras é arbitrariamente dividido em três áreas diferentes, as quais englobam diferentes componentes. Neste caso, três RNAs são utilizadas, cada uma responsável pela monitoração dos componentes em uma área específica. A escolha do tamanho de cada área deve levar em consideração a dimensão desejada para o vetor de entrada das RNAs. A Figura 7 apresenta a divisão adotada para o sistema LIGHT.

Os conjuntos de treinamento são construídos considerando os padrões de alarme associados a diferentes condições de defeito envolvendo diferentes componentes do sistema. Para cada RNA as variáveis de entrada consistem de alarmes de relés e disjuntores que podem operar em caso de defeitos envolvendo os componentes da área monitorada. Cada variável de entrada é binária, sendo igual a 1 se representa um alarme que foi recebido e igual a 0 em caso contrário. O número de variáveis de saída corresponde ao número de componentes sendo monitorados. Cada padrão de treinamento corresponde então a um par entrada/saída, onde as entradas definem um padrão de alarme para uma determinada percepção de defeito e cada saída desejada contém o grau de pertinência de cada componente monitorado na classe de componentes com defeito. A construção do conjunto de treinamento é definida na Seção 5.1.

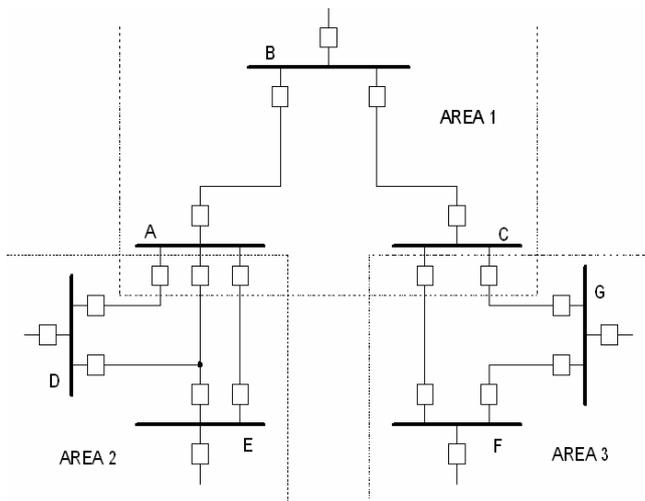


Figura 6: Divisão do sistema de 7 barras

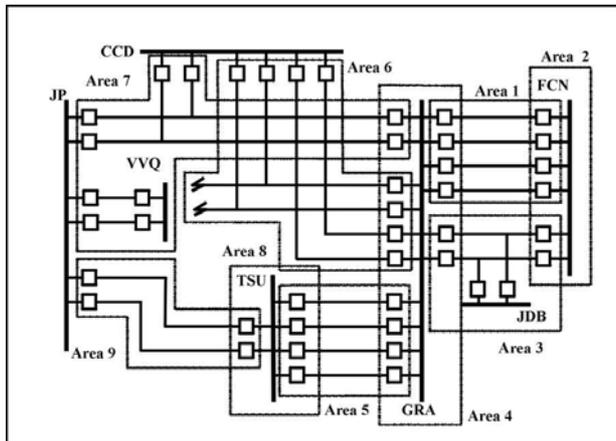


Figura 7: Divisão do sistema LIGHT

O modelo de RNA adotado é o Perceptron de Múltiplas Camadas (MLP - *MultiLayer Perceptron*) (Haykin, 1994), o qual é ilustrado na Figura 8 para  $n$  variáveis de entrada e  $k$  saídas (componentes monitorados).

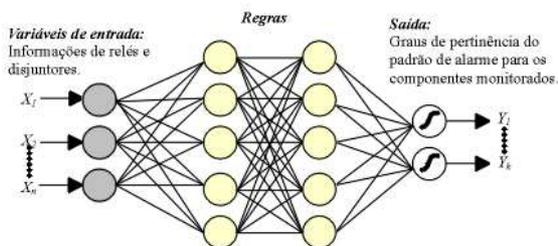


Figura 8: Modelo de RNA adotado

### 5.3 Diagnóstico em Tempo Real

Em tempo real, o padrão de alarme recebido no centro de controle após a ocorrência de um defeito pode ser avaliado utilizando as RNAs treinadas *offline*, de acordo com os seguintes passos:

- (i). Selecionar as RNAs para o qual ao menos um dos alarmes é uma variável de entrada;
- (ii). Apresentar o padrão de entrada para cada RNA selecionada e estimar, nos neurônios de saída, os graus de pertinência associados aos componentes monitorados; e
- (iii). Produzir um diagnóstico final baseado na análise dos graus de pertinência estimados.

No passo (iii), o diagnóstico final é determinado pela observação de todas as saídas estimadas e assumindo como defeituoso o componente que apresenta o maior grau de pertinência. Esta estratégia permite uma boa interpretação das saídas estimadas para a produção de diagnósticos até em situações difíceis, onde padrões de alarme incompletos ou corrompidos são observados. Este poderia não ser o caso se, ao invés das associações fuzzy, associações binárias fossem utilizadas na construção do conjunto de treinamento, quando as saídas das RNAs poderiam simplesmente classificar os componentes do sistema como defeituosos ou não defeituosos (saídas desejadas iguais a 1 ou 0, respectivamente). Para padrões de alarme incompletos ou corrompidos, podem-se obter saídas com valores intermediários (entre 0 e 1). Tais saídas não podem ser interpretadas para fins de diagnóstico quando as RNAs forem treinadas para realizar um mapeamento binário.

### 5.4 Avaliação de Desempenho

O método proposto pode ser avaliado através dos índices de desempenho apresentados a seguir:

- **Diagnósticos Corretos (%)** - casos no qual o componente defeituoso foi identificado corretamente.

$$DC(\%) = \frac{NDC}{NC} \times 100 \quad (9)$$

onde:

$DC(\%)$  - percentual de diagnósticos corretos.

$NDC$  - número total de diagnósticos corretos.

$NC$  - número total de casos testados.

- **Diagnósticos Incorretos (%)** - casos nos quais o componente defeituoso não foi identificado.

$$DI(\%) = \frac{NDI}{NC} \times 100 \quad (10)$$

onde:

$DI(\%)$  - percentual de diagnósticos incorretos.

$NDI$  - número total de diagnósticos incorretos.

## 6 TESTES E RESULTADOS

Diversos testes foram realizados para avaliar a metodologia proposta. Os padrões de alarme utilizados para treinar os classificadores neurais correspondem a diferentes situações de defeito. As saídas desejadas para cada padrão de treinamento são graus de pertinência obtidos utilizando as relações fuzzy apresentadas na Seção 4, onde diagramas sagittais são construídos para os componentes do sistema e uma inferência fuzzy é executada utilizando o modelo Hamacher com o parâmetro  $\gamma = 5$ . Uma vez treinadas, as RNAs são testadas utilizando novos padrões de alarme não observados (incluindo casos nos quais existem falhas nos dispositivos de proteção, dados corrompidos, etc.). As simulações foram realizadas para o sistema de 7 barras e para parte do sistema da LIGHT. O modelo de RNA adotado foi o MLP, treinado com o algoritmo da retropropagação de erros (*backpropagation*). As melhores arquiteturas obtidas são apresentadas nas Tabelas 3 e 4 para os dois sistemas testados. O número de padrões de treinamento (PT) é também apresentado. É importante ressaltar que a escolha das variáveis de entrada e saída para cada RNA seguiu a estratégia descrita na Seção 5.2.

RNA	Número de PT	Camada de entrada	Camada escondida	Camada de Saída
RNA <sub>1</sub>	82	34	20	5
RNA <sub>2</sub>	137	40	20	5
RNA <sub>3</sub>	111	35	20	5

Tabela 3: Dados de treinamento (Sistema de 7 barras)

RNA	Número de PT	Camada de entrada	Camada escondida	Camada de Saída
RNA <sub>1</sub>	176	48	24	4
RNA <sub>2</sub>	15	8	4	1
RNA <sub>3</sub>	152	38	20	2
RNA <sub>4</sub>	152	18	10	1
RNA <sub>5</sub>	33	48	25	4
RNA <sub>6</sub>	182	48	25	4
RNA <sub>7</sub>	175	62	30	4
RNA <sub>8</sub>	14	8	4	1
RNA <sub>9</sub>	84	28	15	2

Tabela 4: Dados de treinamento (Sistema Light)

Nas seções seguintes são apresentadas algumas simulações para ilustrar a metodologia proposta.

### 6.1 Testes com o Sistema de 7 Barras

A Tabela 5 ilustra alguns dos casos utilizados para testar o sistema de 7 barras. Note-se que estes casos não foram apresentados durante a fase de treinamento das RNAs e correspondem a situações onde falhas nos dispositivos de proteção e perdas de dados estão presentes. As RNAs testadas durante a fase de classificação, selecionadas automaticamente pelo processo descrito na Seção 5.3, são também apresentadas.

Componentes Defeituosos	Alarmes recebidos	RNAs
1- linha A-B	Terminal A: Z1, DJ Terminal B: Z2, DJ	RNA1 RNA2
2- barra A, ausência de informação sobre a operação do disjuntor na linha A-E, terminal A	Barra A: PD, DJs associados a barra A (exceto o associado à linha A-E)	RNA1 RNA2
3- barra C, falha no disjuntor da linha C-F, terminal C	Barra C: PD, DJs (exceto C-F) Terminal F: Z2, DJ (Linha C-F)	RNA1 RNA3
4- linha B-C, falha de proteção no terminal C	Terminal B: PP, DJ (Linha B-C) Terminal F: Z2, DJ (Linha C-F) Terminal G: Z2, DJ (Linha C-G)	RNA1 RNA3
5- linha C-F, ausência de informação sobre a operação do disjuntor no terminal C	Terminal C: PP Terminal F: Z1, DJ	RNA3

Tabela 5: Testes com o sistema de 7 barras

A Tabela 6 apresenta em suas colunas os resultados obtidos para cada caso testado. As saídas dos classificadores neurais são estimativas do grau de pertinência de cada componente do sistema na classe de componentes defeituosos. O maior grau de pertinência obtido em cada teste é destacado na Tabela 6. De acordo com a metodologia proposta, o componente do sistema associado com o maior grau de pertinência é classificado como defeituoso. Pode-se notar que em todos os casos o componente com defeito foi corretamente identificado.

	Componentes	Graus de Pertinência				
		1	2	3	4	5
RNA <sub>1</sub>	A-B	<b>0,8732</b>	0,1195	0,0704	0,0000	-
	B-C	0,0000	0,0327	0,0789	<b>0,8734</b>	-
	A	0,2349	<b>0,9713</b>	0,0000	0,0000	-
	B	0,0000	0,0161	0,0000	0,0000	-
	C	0,0000	0,0000	<b>0,9637</b>	0,4232	-
RNA <sub>2</sub>	A-D	0,2137	0,0807	-	-	-
	A-E	0,2169	0,2224	-	-	-
	A-D-E	0,2016	0,0212	-	-	-
	D	0,0000	0,2132	-	-	-
	E	0,0000	0,0000	-	-	-
RNA <sub>3</sub>	C-F	-	-	0,1358	0,4273	<b>0,6986</b>
	C-G	-	-	0,1700	0,4923	0,0000
	F-G	-	-	0,0000	0,0000	0,0000
	F	-	-	0,0000	0,0000	0,1404
	G	-	-	0,0000	0,0045	0,0561

Tabela 6: Resultados obtidos (sistema de 7 barras)

## 6.2 Testes com o Sistema LIGHT

A Tabela 7 ilustra alguns dos casos testados com o sistema LIGHT, onde o número de cada RNA indica a área supervisionada por ela conforme ilustrado na Figura 7. Novamente, os casos ilustrados não foram apresentados durante a fase de treinamento das RNAs e correspondem a situações onde falhas nos dispositivos de proteção e/ou ausência de informação estão presentes. As RNAs testadas durante a fase de classificação são também apresentadas. De acordo com os procedimentos para o diagnóstico em tempo-real apresentados na Seção 5.3, somente as RNAs associadas com as áreas 1, 2, 3 e 4 são selecionadas e testadas para os casos ilustrados na Tabela 7. A tabela 8 apresenta em suas colunas os resultados obtidos.

Mais uma vez, o maior grau de pertinência estimado para cada caso está associado com o componente defeituoso.

## 6.3 Resultados Globais

Além dos casos apresentados nas Tabelas 5 e 7, diversos outros foram testados utilizando a metodologia proposta. Estes testes correspondem a situações onde falhas nos dispositivos de proteção e/ou perdas de informações estão presentes. A Tabela 9 ilustra os resultados globais obtidos para o sistema de 7 barras e para o sistema LIGHT.

Os resultados da Tabela 9 ilustram o excelente desempenho do método proposto, fornecendo boas interpretações de pa-

Componentes Defeituosos	Alarmes recebidos	RNAs
1- linha FCN-GRA-2	Terminal GRA: Z2, DJ Terminal FCN: PP, DJ	RNA1 RNA2 RNA3 RNA4
2- barra FCN, falha no disjuntor da linha FCN-GRA-2, terminal FCN	Barra FCN: PD, DJs associados com a barra FCN Terminal GRA: Z2, DJ (Linha FCN-GRA-2)	RNA1 RNA2 RNA3 RNA4
3- linha FCN-GRA-JDB-1, falha de proteção no terminal FCN	Terminal GRA: PP, DJ (Linha FCN-GRA-JDB-1) Terminal JDB: Z1, DJ (Linha FCN-GRA-JDB-1) Terminal GRA: Z2, DJ (Linhas FCN-GRA-1,2,3 e 4) Terminal GRA: Z2, DJ (Linha FCN-GRA-JDB-2)	RNA1 RNA2 RNA3 RNA4
4- linha FCN-GRA-4, ausência da informação sobre a operação do relé no terminal GRA	Terminal FCN: Z1, DJ Terminal GRA: DJ	RNA1 RNA2 RNA3 RNA4
5- linha FCN-GRA-1, operação indevida do relé de proteção da linha FCN-GRA-2	Terminal FCN: PP, DJ Terminal GRA: Z1, DJ Terminal GRA: PP, DJ (Linha FCN-GRA-2)	RNA1 RNA2 RNA3 RNA4

Tabela 7: Testes com o sistema LIGHT

	Componentes	Graus de Pertinência				
		1	2	3	4	5
RNA <sub>1</sub>	FCN-GRA-1	0,0027	0,3038	0,7962	0,0000	<b>0,8536</b>
	FCN-GRA-2	<b>0,7485</b>	0,3388	0,8463	0,0000	0,3525
	FCN-GRA-3	0,0002	0,3021	0,6049	0,1081	0,0000
	FCN-GRA-4	0,0051	0,3052	0,7489	<b>0,8942</b>	0,0000
RNA <sub>2</sub>	FCN	0,3747	<b>0,9750</b>	0,3263	0,3664	0,4476
RNA <sub>3</sub>	FCN-GRA-JDB-1	0,0240	0,0577	<b>0,9765</b>	0,1024	0,0435
	FCN-GRA-JDB-2	0,0523	0,0766	0,7533	0,0000	0,0284
RNA <sub>4</sub>	GRA	0,0583	0,0583	0,4467	0,5724	0,2915

Tabela 8: Resultados obtidos (sistema LIGHT)

	Sistema 7 barras	Sistema LIGHT
Casos testados	92	140
DC (%)	96,8	95,0
DI (%)	3,2	5,0

Tabela 9: Resultados globais

drões de alarme corrompidos. Além disso, foi observado que diagnósticos corretos são sempre obtidos quando o sistema de proteção opera corretamente. Tais situações não foram consideradas para a obtenção dos índices apresentados na Tabela 8. O esforço computacional envolvido nos testes das RNAs pode ser considerado desprezível. A estratégia local adotada para o problema levou a tempos de treinamento bastante reduzidos. Dentre as RNAs treinadas, o maior tempo computacional observado foi de 5 minutos, tendo sido utilizado um microcomputador Pentium IV 2,2 GHz.

É importante enfatizar que diagnósticos incorretos foram obtidos para padrões de alarme muito corrompidos, geralmente devido à combinação de múltiplas falhas não correlacionadas nos dispositivos de proteção e/ou a perda de muitas informações. Embora tenham sido utilizados para testar o método proposto, muitos destes padrões de alarme têm baixa probabilidade de ocorrência.

Neste trabalho, as RNAs foram treinadas considerando uma dada topologia da rede elétrica. A ocorrência de uma alteração topológica na rede elétrica pode prejudicar o desempenho de uma RN que não foi treinada considerando tal topologia. Entretanto, é importante observar que as RNAs apresentam boa capacidade de generalização e podem responder

satisfatoriamente mesmo para topologias da rede elétrica não consideradas durante o treinamento. Padrões de alarme observados para mais de uma topologia de interesse para a operação do sistema podem ser acrescentados no conjunto de treinamento de uma RN quando necessário para melhorar o desempenho desta para certas situações de defeito. Porém, é importante ressaltar que, no caso da alteração do estado de um componente específico da rede elétrica, o re-treinamento de apenas uma ou poucas RNAs pode se tornar necessário, dada a natureza local do problema tratado.

## 7 CONCLUSÕES

Este trabalho apresentou uma abordagem neuro-fuzzy para o processamento de alarmes e identificação de componentes defeituosos em sistemas de potência. Relações fuzzy entre padrões de alarme e possíveis componentes com defeito do sistema foram estabelecidas e utilizadas como conjuntos de treinamento para redes neurais artificiais. As RNAs foram treinadas para produzir estimativas dos graus de pertinência dos componentes do sistema no conjunto de componentes defeituosos. A metodologia foi testada utilizando um sistema de 7 barras e parte de um sistema real. Diagnósticos corretos foram obtidos mesmo em situações onde existem falhas nos sistemas de proteção e comunicação (ausência de certas informações). Este desempenho se deve a capacidade do método proposto combinar a introdução de conhecimento qualitativo, através da lógica fuzzy, com a capacidade que as redes neurais possuem de generalizar sobre o conhecimento adquirido. Diagnósticos incorretos foram observados apenas quando foram simuladas situações de ocorrência pouco provável, envolvendo a combinações de falhas nos sistemas de proteção e comunicação.

## 8 AGRADECIMENTOS

Os autores agradecem a Marco Aurélio P. Rodrigues, engenheiro da LIGHT, e também ao CNPq e Faperj pelo apoio financeiro para a realização desta pesquisa.

## REFERÊNCIAS

- Chin, Hong-Chan (2003). Fault Section Diagnosis of Power System Using Fuzzy Logic. *IEEE Transactions on Power Systems*, Vol. 18, No. 1, February, pp. 245-250.
- Chow, H. & Park, J.K. (1997). An Expert System for Fault Section Diagnosis of Power Systems Using Fuzzy Relations. *IEEE Transactions on Power Systems*, vol. 12, N° 1, February.
- CIGRE TF 38-06-02, Convener - Dillon, T. (1991). Survey on expert systems in alarm handling. *Electra*, N° 139, pp. 133-147.

- CIGRE TF 38-06-06, on Artificial Neural Networks Applications for Power Systems, Convener - Niebur, D. (1993). Neural network applications in power systems. *Int. Journal of Engineering Intelligent Systems*, Vol. 1, N° 3, December, pp. 133-158.
- Dombi, J. & Vas, A. (1983). Basic theoretical treatment of fuzzy connectives. *Acta Cybernet*, Vol. 14, pp. 191-201.
- Dubois, D. & Prade, H. (1980). *Fuzzy Sets and Systems: Theory and Applications*. Academic Press, New York, 1980.
- El-Hawary, M.E. & editor (1998). *Fuzzy System Theory in Electrical Power Engineering*. IEEE press.
- Handschin, E. & Hoffmann, W. (1992). Integration of an expert system for security assessment into a energy management system. *Electrical Power & Energy Systems*, Vol. 14, N°2/3, April-June.
- Handschin, E., Kuhlmann, D. & Hoffmann, W. (1994). Fault diagnosis in electrical energy systems using device-specific artificial neural networks. *Engineering Intelligent Systems*, Vol. 2, December, pp. 255-262.
- Haykin, S. (1994). *Neural Networks – A Comprehensive Foundation*. Prentice-Hall, 1994.
- Kirschen, D.S. & Wollenberg, B.F. (1992). Intelligent alarm processing in power systems. *Proceedings of IEEE*, vol. 80, N° 5, May, pp. 663-672.
- Liu, C.C. & Tomsovic, K.L. (1987). An expert system as a dispatchers aid for the isolation of line section faults. *IEEE Transactions on Power Delivery*, Vol. PWRD-2, N° 3, July.
- Mazon, A.J., Zamora, I., Gracia, J. and Sagastabeitia, K.J. (2003). Analysis of Fault Classification Methods in Transmission Lines Using ANNs". 12<sup>th</sup> Intelligent Systems Applications to Power Systems Conference, Lemnos, Greece, September, paper ISAP03/019.
- Meza, E.B.M., Souza, J.C.S., Schilling, M.Th., Do Coutto Filho, M.B. (2002). Utilização de Relações Fuzzy para o Processamento de Alarmes em Sistemas de Potência. *Anais do XIV Congresso Brasileiro de Automática (XIV CBA)*, pp. 2325-2330, Natal, RN.
- Pfau-Wagenbauer, M. & Brugger, H. (1991). Model and rule based intelligent alarm processing. *Proceedings of the Third Symposium on Expert Systems Application to Power Systems*, April 1-5, Tokyo-Kobe, Japan, pp. 27-32.
- Rodrigues, M.A.P., Souza, J.C.S. & Schilling, M.Th. (2001). Building local neural classifiers for alarm handling and fault location in electrical power systems. *Proceeding of the ISAP'99*, April, Rio de Janeiro, Brazil, pp. 157-161.
- Silva, A.P.A., Insfran, A.H.F., Silveira, P.M. & Lambert-Torres, G. (1995). Neural networks for fault location on substations. *1995 IEEE PES Summer Meeting*, July 23-27, Portland, OR.
- Souza, J.C.S., Rodrigues, M.A.P., Schilling, M.Th. & Do Coutto Filho, M.B. (2001). Fault Location in Electrical Power Systems Using Intelligent Systems Techniques. *IEEE Transactions on Power Delivery*, N° 1, January, pp. 59-67.
- Sun, J., Qin, S. and Song, Y. (2004). Fault diagnosis of Electric Power Systems Based on Fuzzy Petri Nets. *IEEE Transactions on Power Systems*, Vol. 19, No. 4, November, pp. 2053-2059.
- Yager, R.R. (1980). On a general class of fuzzy connectives. *Fuzzy Sets Systems*, vol. 4, pp. 235-242.
- Zadeh, L.A. (1965). Fuzzy sets. *Fuzzy Sets, Information and Control*, vol. 8, pp. 338-353.
- Zimmermann, H.J. (1985). *Fuzzy Set Theory and Applications*. Kluwer, Boston.