

EDWIN BENITO MITACC MEZA

**LOCALIZAÇÃO DE DEFEITOS EM SISTEMAS DE POTÊNCIA
UTILIZANDO UM MODELO *NEURO-FUZZY***

Dissertação apresentada ao Curso de Pós-Graduação em Computação Aplicada e Automação da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Mestre. Área de Concentração: Computação em Potência.

Orientadores:

Prof. Julio Cesar Stacchini de Souza, D. Sc.

Prof. Marcus Theodor Schilling, D. Sc.

NITERÓI
2001

006.3 Meza, Edwin Benito Mitacc
M617 Localização de Defeitos em Sistemas de
2001 Potência Utilizando um Modelo *Neuro-Fuzzy* /
Edwin Benito Mitacc Meza.- Niterói:
UFF/CTC/CAA, 2001.
165 p.

Dissertação (Mestrado) - Computação Aplicada
e Automação, Universidade Federal Fluminense,
2001.

1. Proteção de Sistemas de Potência. 2.
Supervisão em Tempo-Real. 3. Inteligência
computacional. I. Título.

EDWIN BENITO MITACC MEZA

**LOCALIZAÇÃO DE DEFEITOS EM SISTEMAS DE POTÊNCIA
UTILIZANDO UM MODELO *NEURO-FUZZY***

Dissertação apresentada ao Curso de Pós-Graduação em Computação Aplicada e Automação da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Mestre. Área de Concentração: Computação em Potência.

Aprovada em 25/06/2001.

BANCA EXAMINADORA

Prof. Julio Cesar Stacchini de Souza, D.Sc. - Orientador
Universidade Federal Fluminense

Prof. Marcus Theodor Schilling, D. Sc. - Orientador
Universidade Federal Fluminense

Prof. Milton Brown Do Coutto Filho, D. Sc.
Universidade Federal Fluminense

Prof. Luiz Satoru Ochi, D. Sc.
Universidade Federal Fluminense

Prof. Glauco Nery Taranto, Ph. D.
UFRJ/COPPE

NITERÓI
2001

A minha família e amigos pelo
apoio, incentivo e compreensão.

AGRADECIMENTOS

Agradeço a Deus, por sua constante presença em minha vida, dando-me coragem para enfrentar todos os obstáculos.

Aos meus orientadores, Prof. Julio Cesar Stacchini de Souza e Prof. Marcus Theodor Schilling pela orientação constante, incentivo, confiança, amizade e amplo acesso a seus conhecimentos.

À CAPES, CNPq, FAPERJ e FINEP (projeto SAGE) pelo apoio financeiro que possibilitou a realização deste trabalho

Aos professores e funcionários do CAA pelo companheirismo e pela ajuda com a qual sempre pude contar.

Aos amigos Sergio Carvalho, Fabio Coelho e Marco Aurelio Rodrigues pelo constante apoio.

A todos aqueles que de forma direta e indireta contribuíram para que alcançasse esta realização.

A Maria Cristina pela compreensão e carinho, sem os quais não seria possível desenvolver esse trabalho.

Em sistemas de potência, um grande número de mensagens e alarmes são transmitidos ao centro de controle após a ocorrência de distúrbios. Estes distúrbios estão em geral associados à presença de defeitos de diferentes tipos e localizações no sistema. Como decorrência, parte do sistema é isolada de modo a eliminar o defeito. 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. Dessa maneira, é fundamental que a localização do defeito seja determinada de forma bastante rápida. Na ocorrência de um defeito, os operadores devem tirar conclusões e tomar decisões a partir de um grande conjunto de informações, o que pode levar um tempo demasiadamente grande. Outros problemas tais como falhas no sistema de proteção, problemas de comunicação, aquisição de dados corrompidos, etc. podem tornar a obtenção de diagnósticos uma tarefa bastante complicada.

Nesta Dissertação investiga-se a aplicação de um modelo *Neuro-Fuzzy* para o processamento de alarmes e diagnósticos de defeitos em sistemas de potência, através da construção de redes neurais 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 o diagnóstico. São investigadas diversas técnicas para o estabelecimento das relações *fuzzy* entre padrões de alarme e defeitos no sistema. O modelo a ser desenvolvido deverá ser capaz de permitir a introdução do conhecimento qualitativo sobre o problema tratado (lógica *fuzzy*) e ao mesmo tempo apresentar características de robustez, tolerância a falhas e generalização (redes neurais).

Palavras-Chave: Proteção de Sistemas de Potência, Supervisão em tempo-real, Lógica *Fuzzy*, Redes Neurais, Reconhecimento de Padrões.

ABSTRACT

In electrical power systems a large number of messages and alarms are transmitted to the control center in case of disturbances. These disturbances are associated with faults that may be of different types and can occur anywhere in the system. In such situations part of the system is isolated in order to eliminate the fault. Protection devices are responsible for detecting the occurrence of a fault and isolating only the faulted section. It is also very important to restore the system normal operating conditions as soon as possible. Then, it is essential that the fault location is determined in a very short time. In the control center the operator usually has to draw conclusions from a large amount of informations, which may be very time-consuming. Other problems such as protection devices failures, communication problems, acquisition of corrupted data, etc. can make the fault location a very difficult task.

This work investigates the application of a *neuro-fuzzy* model for alarms processing and fault diagnosis in power systems, through the construction of artificial neural networks that perform the fuzzy mapping of alarms received in case of disturbances for outputs that reflect the degree of membership on each class (fault occurrence). Different techniques to establish the fuzzy relations among alarm patterns and fault occurrences in power systems are examined. The proposed model combines the introduction of qualitative information about the problem (fuzzy logic) with fault tolerance and generalization capability (neural networks).

Keywords: Power Systems Protection, Real-Time monitoring, Fuzzy Logic, Neural Networks, Pattern Recognition.

CAPÍTULO 1 - INTRODUÇÃO

1.1	Considerações Gerais	1
1.2	Objetivo	3
1.3	Estruturação da Dissertação	4

CAPÍTULO 2 - LOCALIZAÇÃO DE DEFEITOS EM SISTEMAS DE POTÊNCIA

2.1	Introdução	6
2.2	Sistema de Proteção	8
2.2.1	A função dos sistemas de proteção	9
2.2.2	Características funcionais do sistema de proteção	10
2.3	Defeitos em Sistemas de Potência	11
2.3.1	Defeitos e outras anormalidades	11
2.3.2	Natureza dos defeitos	12
2.4	Filosofia de Proteção	13
2.4.1	Proteção principal	13
2.4.2	Proteção de Retaguarda	15
2.5	Relés de Proteção e suas Aplicações	17
2.5.1	Relés diferenciais	17
2.4.2	Relés de distância	18
2.4.2	Relés de proteção para falha de disjuntor	20
2.6	Avaliação dos Relés de Proteção	21
2.7	Proteção Digital Versus Convencional	22
2.8	Estado Atual e Perspectivas Futuras	26

CAPÍTULO 3 - LÓGICA DIFUSA E REDES NEURAIIS

3.1	Introdução	29
3.2	Lógica Difusa	29
3.2.1	Conjuntos Difusos	31
3.2.1.1	Funções de caracterização ou pertinência	32
3.2.1.2	Cardinalidade, cortes α e altura de um conjunto difuso	37

3.2.1.3	Números difusos	37
3.2.2	Operações básicas da teoria de conjuntos para conjuntos difusos	37
3.2.2.1	Interseção de conjuntos difusos	38
3.2.2.2	União de conjuntos difusos	38
3.2.2.3	Propriedade da união e da interseção de conjuntos difusos	39
3.2.2.4	Subconjuntos difusos	40
3.2.2.5	Conjuntos difusos disjuntos	40
3.2.2.6	Igualdade entre conjuntos difusos	40
3.2.2.7	Complemento de conjuntos difusos	40
3.2.2.8	Operações algébricas de conjuntos difusos	41
3.2.3	Operações de agregação da teoria de conjuntos difusos	42
3.2.3.1	Interseção difusa: <i>t-normas</i>	42
3.2.3.2	União difusa: <i>s-normas</i> ou <i>t-conormas</i>	43
3.2.3.3	Famílias paramétricas de <i>t-normas</i> e <i>s-normas</i>	44
3.2.3.4	Critérios para selecionar operadores de agregação apropriados	47
3.2.4	Relações difusas	49
3.2.5	Aplicações da lógica difusa em sistemas de potência	50
3.3	Redes Neurais Artificiais (RNAs)	53
3.3.1	Introdução	53
3.3.2	Um breve histórico	55
3.3.3	Características gerais das redes neurais artificiais	57
3.3.4	Processos de aprendizado	61
3.3.4.1	Aprendizado supervisionado	62
3.3.4.2	Aprendizado não-supervisionado	65
3.3.4.3	Aprendizado por reforço	66
3.3.5	Redes perceptron multi-camadas (MLP)	67
3.3.5.1	Algoritmo <i>backpropagation</i>	68
3.3.5.2	Treinamento da rede MLP	70
3.3.5.3	Utilização	72
3.3.5.4	Limitações	72
3.3.6	Etapas na construção de classificadores neurais	73

3.3.6.1	Coleta de dados e construção dos conjuntos de treinamento e teste	73
3.3.6.2	Escolha da arquitetura	73
3.3.6.3	Treinamento	74
3.3.6.4	Teste e validação do treinamento	75
3.3.6.5	Integração com o ambiente de aplicação	75
3.3.7	Vantagens das RNAs	76
3.3.8	Aplicações de redes neurais em sistemas de potência	77
3.4	Conclusão	79

CAPÍTULO 4 - MODELAGEM DIFUSA PARA LOCALIZAÇÃO DE DEFEITOS EM SISTEMAS DE POTÊNCIA

4.1	Introdução	80
4.2	Importância da Lógica Difusa no Problema de Localização de Defeitos em Sistemas de Potência	81
4.3	Descrição dos Sistemas de Potência a serem Testados	82
4.3.1	Sistema de 7 barras	82
4.3.2	Sistema Light	83
4.4	Relações Difusas e Diagramas Sagitais para a Localização de Defeitos em Sistemas de Potência	84
4.5	Procedimento para o Estabelecimento das Relações Difusas	87
4.6	Modelos Utilizados	87
4.6.1	Família Hamacher	88
4.6.2	Família Yager	88
4.6.3	Família Dubois&Prade	89
4.6.4	Família Dombi	89
4.6.5	Exemplo de aplicação dos modelos descritos	90
4.7	Avaliação dos Modelos no Processo de Localização de Defeitos em Sistemas de Potência	93
4.7.1	Escolha do parâmetro adequado aos modelos apresentados	94
4.7.2	Seleção do melhor modelo para representar o problema de localização de defeitos em sistemas de potência	95
4.8	Conclusões	95

CAPÍTULO 5 - METODOLOGIA PROPOSTA

5.1	Introdução	97
5.2	Arquitetura do Modelo <i>Neuro-Fuzzy</i>	98
5.3	Construção das Redes <i>Neuro-Fuzzy</i>	100
5.3.1	Divisão do sistema em áreas	100
5.3.2	Seleção das variáveis de entrada	101
5.3.3	Treinamento	104
5.4	Classificação em Tempo-Real	105
5.5	Índices de Desempenho	107
5.6	Conclusões	110

CAPÍTULO 6 - TESTES E RESULTADOS

6.1	Introdução	111
6.1.1	Treinamento das RNFs	111
6.2	Testes com o Sistema de 7 Barras	113
6.3	Testes com o Sistema Light	120

CAPÍTULO 7 - CONCLUSÕES E TRABALHOS FUTUROS

7.1	Conclusões	133
7.2	Contribuições deste Trabalho	134
7.3	Propostas para Trabalhos Futuros	135

APÊNDICE A - MODELAGEM DIFUSA 136

A.1	Descrição	136
A.2	Sistema 7 Barras	136
A.3	Sistema Light	141

APÊNDICE B - VARIÁVEIS DE ENTRADA UTILIZADA PARA CADA RNF 147

B.1	Sistema 7 Barras	147
B.2	Sistema Light	149

LISTA DE FIGURAS

Figura 2.1 - Diagrama de um sistema de potência ilustrando as zonas de proteção principal	15
Figura 2.2 - Entrelaçamento das zonas de proteção adjacentes	16
Figura 2.3 - Filosofia de proteção	16
Figura 2.4 - Ilustração para a proteção de retaguarda da linha de transmissão E-F	17
Figura 2.5 - Ligação diferencial	19
Figura 2.6 - Características dos relés de distância	20
Figura 2.7 - Diagrama de tempo do esquema de falha de disjuntor	22
Figura 2.8 - Diagrama esquemático com relés convencionais	26
Figura 2.9 - Diagrama esquemático com relés digitais	27
Figura 3.1 - Limites de um conjunto difuso	34
Figura 3.2 - Função característica	35
Figura 3.3 - Máquinas de estado de classificação de temperatura	36
Figura 3.4 - Cardinalidade, altura, suporte, núcleo e o corte de nível 0,5 do conjunto difuso A	38
Figura 3.5 - Diagrama Sagital	52
Figura 3.6 - Constituintes da célula neuronal	55
Figura 3.7 - Esquema da unidade McCulloch e Pitts	60
Figura 3.8 - Organização em camadas	61
Figura 3.9 - Rede não-realimentada e rede realimentada	62
Figura 3.10 - Funções de ativação	62
Figura 3.11 - Aprendizado supervisionado	64
Figura 3.12 - Regra delta	65
Quadro 3.1 - Esquema de treinamento	66
Figura 3.13 - Aprendizado não-supervisionado	67
Figura 3.14 - Aprendizado por reforço	68
Figura 3.15 - Exemplo de superfície de erro	71
Figura 3.16 - Esquema de treinamento <i>backpropagation</i>	73
Figura 3.17 - Superfície de erro e treinamento <i>backpropagation</i>	73

Figura 4.1 - Sistema elétrico de Potência de sete barras	85
Figura 4.2 - Sistema elétrico da Light	87
Figura 4.3 - Diagramas sagitais para o sistema de sete barras	89
Figura 4.4 - Diagrama Sagital da Linha B-C do Sistema de Sete Barras	94
Figura 5.1 - Arquitetura do modelo <i>Neuro-Fuzzy</i> proposto	104
Figura 5.2 - Sistema elétrico de Potência de sete barras	104
Figura 5.3 - Construção do conjunto de treinamento	108
Figura 5.4 - Fluxograma de Operação	110
Figura 5.5 - Construção das redes	112
Figura 5.6 - Teste e Validação da metodologia	113
Figura 6.1 - Defeito na barra A	118
Figura 6.2 - Defeito na barra C	119
Figura 6.3 - Defeito na linha B-C	120
Figura 6.4 - Defeito na barra C	121
Figura 6.5 - Defeito na linha C-G	122
Figura 6.6 - Defeito na linha FCN-GRA-2	124
Figura 6.7 - Defeito na linha FCN-GRA-2	125
Figura 6.8 - Defeito na linha TSU-GRA-1	126
Figura 6.9 - Defeito na barra FCN	128
Figura 6.10 - Defeito na linha TSU-GRA-1	129
Figura 6.11 - Defeito na linha FCN-GRA-JDB-1	130
Figura 6.12 - Defeito na linha FCN-GRA-4	131
Figura 6.13 - Defeito na linha FCN-GRA-1	132
Figura 6.14 - Defeito na Barra TSU	133
Figura 6.15 - Defeito na linha TSU-GRA-4	134
Figura B.1 - Sistema elétrico de potência de 7 barras	160
Figura B.2 - Sistema elétrico da Light	162

LISTA DE TABELAS

Tabela 3.1 - Matriz de relação C1×C2	51
Tabela 3.2 - Áreas de aplicação de conjuntos difusos em sistemas de potência	54
Tabela 4.1 - Configuração do padrão de alarme - Sistema 7 barras	85
Tabela 4.2 - Configuração do padrão de alarme - Sistema Light	86
Tabela 4.3 - Subestações do sistema Light	86
Tabela 4.4 - Valor adequado do parâmetro em cada modelo apresentado	97
Tabela 5.1 - Redes <i>neuro-fuzzy</i> por área	105
Tabela 5.2 - Alarmes considerados na definição das variáveis de entrada	106
Tabela 5.3 - Variáveis de entrada para o RNF ₁	106
Tabela 5.4 - Configuração final do RNF ₁	106
Tabela 6.1 - Número de casos para treinamento - sistema 7 barras	116
Tabela 6.2 - Número de casos para treinamento - sistema Light	117
Tabela 6.3 - Caso 1 (7 barras) - Graus de pertinência obtidos	118
Tabela 6.4 - Caso 2 (7 barras) - Graus de pertinência obtidos	120
Tabela 6.5 - Caso 3 (7 barras) - Graus de pertinência obtidos	121
Tabela 6.6 - Caso 4 (7 barras) - Graus de pertinência obtidos	122
Tabela 6.7 - Caso 5 (7 barras) - Graus de pertinência obtidos	123
Tabela 6.8 - Desempenho global para o sistema de 7 barras	123
Tabela 6.9 - Caso 1 (Light) - Graus de pertinência obtidos	125
Tabela 6.10 - Caso 2 (Light) - Graus de pertinência obtidos	126
Tabela 6.11 - Caso 3 (Light) - Graus de pertinência obtidos	127
Tabela 6.12 - Caso 4 (Light) - Graus de pertinência obtidos	128
Tabela 6.13 - Caso 5 (Light) - Graus de pertinência obtidos	130
Tabela 6.14 - Caso 6 (Light) - Graus de pertinência obtidos	131
Tabela 6.15 - Caso 7 (Light) - Graus de pertinência obtidos	132
Tabela 6.16 - Caso 8 (Light) - Graus de pertinência obtidos	133
Tabela 6.17 - Caso 9 (Light) - Graus de pertinência obtidos	134
Tabela 6.18 - Caso 10 (Light) - Graus de pertinência obtidos	135
Tabela 6.19 - Desempenho global para o sistema Light	136
Tabela A.1 - Simulação de casos para o sistema de sete barras	154

Tabela A.2 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma=3$	154
Tabela A.3 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma=4$	154
Tabela A.4 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma=5$	155
Tabela A.5 - Resultados do diagnóstico difuso com o modelo Yager para $p=1$	155
Tabela A.6 - Resultados do diagnóstico difuso com o modelo Yager para $p=2$	155
Tabela A.7 - Resultados do diagnóstico difuso com o modelo Yager para $p=3$	156
Tabela A.8 - Resultados do diagnóstico difuso com o modelo D&P para $\alpha =0,8$	156
Tabela A.9 - Resultados do diagnóstico difuso com o modelo D&P para $\alpha =0,9$	156
Tabela A.10 - Resultados do diagnóstico difuso com o modelo D&P para $\alpha =0,95$	157
Tabela A.11 - Resultados do diagnóstico difuso com o modelo Dombi para $\lambda=0,2$	157
Tabela A.12 - Resultados do diagnóstico difuso com o modelo Dombi para $\lambda=0,4$	157
Tabela A.13 - Resultados do diagnóstico difuso com o modelo Dombi para $\lambda=0,6$	158
Tabela A.14 - Simulação de casos para o sistema Light	158
Tabela A.15 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma=3$	159
Tabela A.16 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma=4$	159
Tabela A.17 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma=5$	160
Tabela A.18 - Resultados do diagnóstico difuso com o modelo Yager para $p=1$	160
Tabela A.19 - Resultados do diagnóstico difuso com o modelo Yager para $p=2$	160
Tabela A.20 - Resultados do diagnóstico difuso com o modelo Yager para $p=3$	161
Tabela A.21 - Resultados do diagnóstico difuso com o modelo D&P para $\alpha =0,8$	161
Tabela A.22 - Resultados do diagnóstico difuso com o modelo D&P para $\alpha =0,9$	161
Tabela A.23 - Resultados do diagnóstico difuso com o modelo D&P para $\alpha =0,95$	162
Tabela A.24 - Resultados do diagnóstico difuso com o modelo Dombi para $\lambda=0,2$	162
Tabela A.25 - Resultados do diagnóstico difuso com o modelo Dombi para $\lambda=0,4$	162
Tabela A.26 - Resultados do diagnóstico difuso com o modelo Dombi para $\lambda=0,6$	163
Tabela B.1 - Variáveis de entrada da RNF ₁ - sistema 7 barras	165
Tabela B.2 - Variáveis de entrada da RNF ₂ - sistema 7 barras	166
Tabela B.3 - Variáveis de entrada da RNF ₃ - sistema 7 barras	166
Tabela B.4 - Variáveis de entrada da RNF ₁ - sistema Light	167
Tabela B.5 - Variáveis de entrada da RNF ₂ - sistema Light	168
Tabela B.6 - Variáveis de entrada da RNF ₃ - sistema Light	169
Tabela B.7 - Variáveis de entrada da RNF ₄ - sistema Light	169

Tabela B.8 - Variáveis de entrada da RNF ₅ - sistema Light	169
Tabela B.9 - Variáveis de entrada da RNF ₆ - sistema Light	169
Tabela B.10 - Variáveis de entrada da RNF ₇ - sistema Light	170
Tabela B.11 - Variáveis de entrada da RNF ₈ - sistema Light	170
Tabela B.12 - Variáveis de entrada da RNF ₉ - sistema Light	171

1.1 Considerações Gerais

Em sistemas de potência, um grande número de mensagens e alarmes são transmitidos ao centro de controle após a ocorrência de distúrbios. Estes distúrbios estão em geral associados à presença de defeitos de diferentes tipos e localizações no sistema. Como decorrência, parte do sistema é isolada de modo a eliminar o defeito. 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. Dessa maneira, é fundamental que a localização do defeito seja determinada de forma bastante rápida. Na ocorrência de um defeito, os operadores devem tirar conclusões e tomar decisões a partir de um grande conjunto de informações, o que pode levar um tempo demasiadamente grande. Nos primeiros 60 segundos de um grande distúrbio o número de mensagens recebidas freqüentemente excede 15 a 20 mensagens por segundo. Testes mostraram que o ser humano tem capacidade de interpretar corretamente não mais do que 2 a 3 mensagens por segundo. Além do grande volume de informações a ser processado, outros problemas tais como falhas no sistema de proteção, problemas de comunicação, aquisição de dados corrompidos, etc. podem tornar a obtenção de diagnósticos uma tarefa bastante complicada. Nestes casos, a área desligada do sistema é em geral mais extensa do que o necessário, podendo gerar dúvidas quanto ao trecho defeituoso e diagnósticos incorretos.

Projetar um sistema para obtenção de diagnósticos torna-se essencial para a automatização de funções em um centro de controle. Tal sistema deve agregar rapidez e precisão. Isto motivou os pesquisadores à utilização de métodos baseados em Inteligência Artificial(IA).

Como tentativas iniciais, sistemas especialistas baseados em regras foram propostos [CD91, HKH94, KW92, LT87, PB91]. Nestas aplicações um conjunto de padrões de alarme é empregado para a construção de uma base de conhecimento. O conhecimento e a experiência dos especialistas humanos são explorados para a construção de um conjunto de regras que forma o mecanismo de inferência utilizado para a produção de diagnósticos em tempo-real. Quando um distúrbio ocorre, o padrão de alarmes recebido no centro de controle é avaliado pelo conjunto de regras e um diagnóstico é obtido. Entretanto, sistemas especialistas são capazes de produzir bons resultados apenas para aquelas situações que foram consideradas durante seu desenvolvimento. A maior limitação desta aplicação reside na dificuldade de tratar padrões de alarmes novos ou corrompidos.

Por outro lado, Redes neurais são tolerantes a falhas e capazes de aprender sobre um dado problema a partir de um treinamento *off-line*, utilizando casos históricos ou simulados, representativos do domínio do problema, de modo a realizar inferências em tempo real [H94]. Alguns métodos baseados na aplicação de redes neurais também foram propostos para o diagnóstico de defeitos em sistemas de potência. Em [C89a, JDS91] a utilização de uma única rede neural para todo o sistema inviabiliza a aplicação a sistemas de grande porte, onde a dimensão do vetor de entrada seria extremamente grande. Além disso, esses métodos assumem uma topologia fixa para o sistema e a rede neural deve ser retreinada após cada variação topológica. Em [AIS95] diversas redes neurais são empregadas para a localização de defeitos em subestações. A utilização de diferentes redes neurais para diferentes topologias do sistema também foi proposta [KK91, KP91, R95]. Esses métodos assumem usualmente que não ocorrem falhas no sistema de proteção e que todas as mensagens e alarmes estão sempre disponíveis no centro de controle. Esta situação em geral não ocorre para sistemas reais. Em [HKH94] a aplicação de redes neurais específicas por componente foi proposta. Após a ocorrência de um distúrbio, algumas redes são executadas, sendo a saída de cada rede utilizada como entrada para as demais. Isto leva a um processo iterativo no qual o diagnóstico final é obtido após todas as redes neurais terem estabilizado seus diagnósticos individuais. No entanto, em casos de falhas no sistema de proteção a informação disponível pode não ser suficiente para obter diagnósticos individuais corretos para as redes neurais, levando a um diagnóstico final incorreto.

Em [CP97] é proposto um sistema especialista para o processamento de alarmes e localização de defeitos em sistemas de potência, que utiliza basicamente a teoria dos conjuntos difusos, ferramenta capaz de permitir a introdução do conhecimento qualitativo sobre o problema tratado. Inicialmente este sistema difuso, além de apresentar os candidatos a elemento defeituoso, avalia a possibilidade de que ocorra um defeito naquele elemento na forma de grau de pertinência.

Embora essa abordagem introduza informações importantes referentes ao conhecimento dos operadores a respeito do sistema e do problema tratado, a utilização de sistemas especialistas apresenta os inconvenientes mencionados anteriormente.

1.2 Objetivo

A utilização da lógica difusa permite incorporar o conhecimento e a experiência dos especialistas sobre o problema tratado. Quando utilizada adequadamente, esta técnica pode trazer grandes benefícios para o processo de solução do problema. Conforme mencionado anteriormente, em [CP97] foi proposta a aplicação de lógica difusa para a construção de sistemas especialistas visando o diagnóstico de defeitos. Entretanto, os sistemas especialistas não são tolerantes a falhas e podem apresentar um desempenho inadequado em tais situações. Em [SRSC01], foi proposto um método baseado em classificadores neurais, que apresenta bons resultados quanto a tolerância a falhas e resposta em situações de falha do sistema de proteção. Em alguns casos, porém, o fato dos classificadores neurais serem treinados para fornecer saídas binárias faz com que certos resultados não permitam uma interpretação adequada para posterior diagnóstico.

Este trabalho propõe uma metodologia baseada na aplicação de um modelo *Neuro-Fuzzy* para o processamento de alarmes e localização de defeitos em sistema de potência. Está prevista a construção de redes neurais 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 o diagnóstico. O modelo a ser desenvolvido deverá ser capaz de permitir a introdução do conhecimento qualitativo sobre o problema tratado (*lógica fuzzy*) e ao mesmo tempo apresentar características de robustez,

tolerância a falhas e generalização (*redes neurais*). A identificação de um componente defeituoso requer o conhecimento de apenas um conjunto parcial de alarmes, em geral a vizinhança do componente. Este fato é explorado através do desenvolvimento de uma estratégia local que permite a redução do problema. Esta estratégia leva à construção de diversas redes *neuro-fuzzy* para supervisionar componentes do sistema, utilizando um número reduzido de variáveis de entrada.

Dentre os pontos a serem abordados nesse trabalho, podem-se citar:

- investigação das relações difusas mais adequadas para o problema de processamento de alarmes e localização de defeitos;
- construção do conjunto de treinamento a partir das relações difusas entre alarmes e possíveis eventos geradores;
- construção do modelo *Neuro-Fuzzy* e da metodologia proposta;
- simulações com um sistema teste e um sistema real;
- obtenção de índices de desempenho para avaliar a metodologia adotada.

Nesta abordagem, o conjunto de treinamento também será construído utilizando exemplares representativos de falhas no sistema de proteção. A diferença básica em relação ao conjunto de treinamento estabelecido para os classificadores neurais, previamente propostos em [SRSC01], está nas saídas desejadas, que não devem apenas classificar cada componente como defeituoso ou não-defeituoso, mas sim expressar o grau de pertinência dos padrões apresentados, nos eventos representados em cada saída (classes). Este conjunto pode ser construído a partir do estabelecimento das relações difusas mencionadas anteriormente. O diagnóstico final será obtido em função das saídas obtidas pelo modelo proposto.

1.3 Estrutura da Dissertação

Esta dissertação está estruturada da seguinte maneira:

No Capítulo 2 é apresentado e discutido o problema de proteção de sistemas de potência. As filosofias de proteção, bem como os principais equipamentos utilizados, são também apresentados.

O Capítulo 3 apresenta uma revisão teórica sobre lógica nebulosa e redes neurais artificiais. Conceitos importantes para o tratamento com incertezas, utilizando a lógica difusa, são apresentados. Aspectos relacionados ao treinamento e validação de redes neurais também são discutidos.

No Capítulo 4 é apresentada uma modelagem difusa para o problema de localização de defeitos em sistemas de potência. São apresentados diagramas Sagitais que representam as relações difusas no problema tratado, o qual permite obter o grau de pertinência dos padrões de alarme para cada componente com operações de união e interseção. Também são apresentados diferentes modelos que realizam operações de união e interseção difusa.

O Capítulo 5 apresenta a metodologia proposta para o processamento de alarmes e localização de defeitos em sistemas de potência. Um modelo *Neuro-Fuzzy* é proposto para obter graus de pertinência de padrões de alarme nas classes do problema. O treinamento destas redes e sua utilização em tempo-real são discutidos.

No Capítulo 6 são ilustrados os testes realizados em um sistema de 7 barras e em parte do sistema Light. Resultados são apresentados e discutidos para diversas situações de operação simuladas.

O Capítulo 7 apresenta as conclusões do trabalho e também as propostas para trabalhos futuros.

LOCALIZAÇÃO DE DEFEITOS EM SISTEMAS DE POTÊNCIA

2.1 Introdução

O principal objetivo de um sistema de potência é atender a demanda com o máximo de continuidade e qualidade possíveis, respeitando restrições elétricas, econômicas e ambientais. Para cumprir este objetivo é importante transportar energia elétrica da usina geradora ao consumidor. A fim de obter-se continuidade no fornecimento de energia elétrica, o sistema de potência deve ser confiável. A ocorrência de uma situação inesperada como descargas elétricas, colisões com linhas de transmissão e falhas devido a envelhecimento dos equipamentos em um sistema de potência pode causar a interrupção no fornecimento de energia. A interrupção do fornecimento é realizada por equipamentos de proteção, visando resguardar a estabilidade do sistema e a vida útil dos equipamentos envolvidos na transmissão da energia. O rápido restabelecimento do fornecimento de energia depende da identificação do ponto onde ocorreu o defeito no sistema e realização dos reparos necessários [C77]. A função de identificação é referida como “Diagnóstico de Defeito em Sistemas de Potência”.

O Diagnóstico de Defeito pode ser dividido em local e centralizado. O diagnóstico de defeito local ocorre nas instalações das usinas e subestações. O diagnóstico de defeito centralizado em um nível acima ocorre nos centros de controle, o qual utiliza diferentes canais de comunicação para a transmissão das informações de defeito apresentados no sistema.

Na ocorrência de um defeito no sistema, um número muito elevado de informações são geradas e transferidas por diferentes canais de comunicação aos Centros de Operação do Sistema (COS). Nos dias de hoje, pode-se ainda considerar que, na grande maioria das concessionárias de energia elétrica do Brasil, os dados referentes às perturbações são coletados inicialmente pelos operadores locais e transferidos por telefone aos operadores do Centro de Operação, para que eles possam produzir um diagnóstico e agir de forma a restabelecer as condições normais de operação.

Na maioria das perturbações ocorridas no sistema elétrico, é possível diagnosticar e agir imediatamente, através dos operadores das subestações. Porém durante grandes distúrbios ou naqueles envolvendo falhas de algum componente do sistema de proteção (relés, disjuntores, etc), o diagnóstico nem sempre é imediato e ações indevidas podem vir a agravar as condições operativas do sistema.

Durante a ocorrência de um grande distúrbio, nos primeiros 60 segundos o número de mensagens freqüentemente excede 15 a 20 mensagens por segundo. Testes mostraram que o ser humano tem capacidade de interpretar corretamente não mais do que 2 a 3 mensagens por segundo.

Além do grande volume de informações a serem processadas, outros problemas tais como falhas no sistema de proteção, problemas de comunicação, aquisição de dados corrompidos, etc. podem tornar a obtenção de diagnósticos uma tarefa bastante complicada. Nestes casos, a área desligada do sistema é em geral mais extensa do que o necessário, podendo gerar dúvidas quanto ao trecho defeituoso e diagnósticos incorretos [RSSC99].

A análise para obtenção da localização do defeito é baseada nas informações de operação dos relés de proteção além dos alarmes de abertura dos disjuntores. Para obter a localização do defeito é necessário levar-se em conta os tipos de relés e os esquemas de proteção que atuaram.

2.2 Sistemas de Proteção

A história da tecnologia utilizada em um sistema elétrico através do mundo apresenta nos recentes anos um progresso rápido e constante, o qual tem tornado possível projetar e construir sistemas de potência econômicos e confiáveis, capazes de satisfazer o crescimento contínuo da demanda de energia elétrica. Neste processo, o sistema de proteção e controle tem uma participação significativa, e o progresso em projeto e desenvolvimento nesses campos deve, necessariamente, acompanhar concepções avançadas de geradores, transformadores de força, linhas de transmissão e cabos subterrâneos. Além disso, o progresso nos campos de proteção e controle é um pré-requisito vital para uma operação eficiente e um desenvolvimento contínuo do sistema de potência como um todo [P81].

A função de proteção não é preventiva como seu nome pode sugerir, mas age somente após a ocorrência de uma anormalidade no sistema elétrico, como por exemplo em sobrecargas severas, curtos-circuitos, inversões de potência, etc. É óbvio que sem uma proteção seletiva seria impossível operar um sistema de potência moderno. O objetivo da proteção é remover tão rápido quanto possível qualquer elemento onde o defeito ocorreu.

Usualmente, pensa-se em um sistema de potência em termos de grandes estações de geração, transformadores, linhas de transmissão, etc. Apesar destes serem alguns dos elementos básicos, muitos outros componentes são também importantes e necessários. O relé de proteção é um deles, o qual faz parte do sistema de proteção acima descrito.

A função dos relés de proteção no desenho e operação do sistema de potência é explicada por uma breve análise do conhecimento e da experiência adquirida pelos especialistas. Existem três aspectos de um sistema de potência que são úteis para essa análise. Estes aspectos são os seguintes:

- a) Operação normal;
- b) Prevenção de falhas elétricas; e
- c) Diminuição dos efeitos de falha elétrica.

O termo "Operação normal" não se refere a falhas de equipamentos, nem erros dos operadores. Este envolve os requisitos mínimos para o atendimento à carga existente e previsões.

As provisões para uma operação normal envolve um maior custo para equipamentos e operação, porém um sistema projetado só para este aspecto não poderia possivelmente adequar-se aos requisitos de hoje em dia. Falhas de equipamentos elétricos poderiam causar interrupções intoleráveis. Nesse ponto devem-se tomar provisões adicionais para reduzir danos a equipamentos e interrupções do serviço na ocorrência de um defeito.

A aplicação dos relés de proteção é um requisito de projeto do sistema que visa reduzir danos na ocorrência de um defeito. Quando menciona-se relés de "proteção", quer dizer que, juntamente com outros equipamentos, os relés ajudam a isolar a parte defeituosa para eliminar o defeito.

2.2.1 A função dos sistemas de proteção

A função principal dos relés de proteção é propiciar a remoção imediata de serviço de qualquer elemento do sistema de potência quando este sofre um curto-circuito, ou começa a operar em qualquer modo anormal que possa causar danos ou interferir na operação efetiva do resto do sistema. Os relés de proteção atuam em conjunto com disjuntores que são capazes de desligar o elemento defeituoso quando for necessário.

Os disjuntores são localizados de forma a desligar do sistema cada gerador, transformador, barramento, linhas de transmissão, etc. Estes disjuntores devem ter suficiente capacidade para que possam carregar momentaneamente a corrente máxima do curto-circuito e em seguida interrompê-la.

Uma função secundária dos relés de proteção é fornecer a localização e tipo de defeito. Tais dados não somente ajudam no restabelecimento do sistema como também, pela comparação com observações dos especialistas humanos e registros dos oscilógrafos

automáticos, fornecem meios para fazer uma análise da efetividade das características de redução e prevenção de defeitos incluindo os próprios relés de proteção.

2.2.2 Características funcionais do sistema de proteção

A aplicação lógica dos relés de proteção divide o sistema de potência em várias zonas, cada uma requerendo seu próprio grupo de relés. Em todos os casos, as principais características funcionais associadas a qualquer sistema de proteção, podem ser descritas como a seguir [W76].

a) Confiabilidade - A confiabilidade dos relés de proteção (relés) é um requisito básico. Quando os relés de proteção não cumprem sua função corretamente, as características associadas à redução dos danos são amplamente ineficazes. Assim, é essencial que os componentes de proteção sejam inerentemente confiáveis, e que sua aplicação, instalação, e manutenção assegurem seu funcionamento adequado. A confiabilidade é um assunto de projeto baseado sobre longas experiências. A simplicidade e a robustez contribuem na confiabilidade do sistema, porém por eles mesmos não oferecem uma solução completa. A aplicação adequada dos componentes de proteção envolve não somente uma escolha adequada dos equipamentos de proteção senão também dos aparelhos associados. Por exemplo, a ausência de fontes adequadas de corrente e tensão para dar energia aos relés podem comprometer ou colocar em risco a proteção do sistema. De uma maneira geral, os sistemas de proteção modernos são altamente confiáveis e levam em conta o compromisso prático entre segurança e confiança. Independente de outros sistemas estarem momentaneamente "cegos" durante um certo período, os relés devem desempenhar precisamente sua função, operando em resposta a problemas em suas áreas de cobertura.

b) Velocidade - Relés que possam antecipar um defeito parecem ser utopia. Mas, mesmo se disponível, indubitavelmente tornariam ainda mais complexa a questão: o defeito realmente requereria um disparo? O desenvolvimento de relés mais rápidos deve ser avaliado em relação ao aumento da probabilidade de mais operações indesejáveis e inexplicadas. O tempo, por mais curto que seja, é ainda o melhor aliado para a distinção

entre um problema real e um falso. Aplicado a relés, o termo alta velocidade indica que o tempo de operação não excede a 50 ms (3 ciclos, na base de 60 Hz). O termo instantâneo indica que nenhum retardo é expressamente introduzido na operação.

c) Seletividade x Economia - Máxima continuidade de serviço com mínima porção do sistema desconectada e máxima proteção em mínimo custo. Relés de alta velocidade oferecem maior continuidade de serviço pela redução de danos provocados pelo defeito e perigos pessoais. Esses relés têm um custo inicial elevado, portanto nem sempre justificado. Conseqüentemente, tanto relés de baixa quanto de alta velocidade são em geral usados para proteger o sistema elétrico.

d) Simplicidade - Como em qualquer outra disciplina de engenharia, simplicidade no sistema de proteção é sempre uma característica de bom projeto. O sistema de proteção mais simples, entretanto, não é sempre o mais econômico. A simplicidade do sistema melhora a confiabilidade deste, considerando o fato de que existindo diminua a chance do sistema funcionar inadequadamente.

e) Sensibilidade - Qualquer equipamento do sistema de proteção deve ser suficientemente sensível para que possa operar confiavelmente quando for necessário, sujeito às condições atuais que produz a tendência mínima de operação.

2.3 Defeitos em Sistemas de Potência

2.3.1 Defeitos e outras anormalidades

Os sistemas de potência são sujeitos a muitos tipos de defeito. Os principais são: trifásico com ou sem conexão à terra, bifásico (fase-fase), bifásico-terra (fase-fase-terra) e monofásico (fase-terra).

Defeitos correlacionados ocorrem algumas vezes, em pontos separados do sistema e em diferentes fases (defeitos através do solo). Às vezes são acompanhados por um condutor partido, ou pode mesmo tomar a forma de um condutor partido sem conexão para

terra. Todos pertencem a linhas, mas os principais são comuns a todos os tipos de instalação.

Geradores, transformadores e motores são sujeitos também a curtos-circuitos entre espiras da mesma fase.

Com exceção do curto-circuito trifásico com ou sem conexão à terra, todos os defeitos listados representam condições desbalanceadas no sistema trifásico. A análise elétrica precisa das possíveis condições de defeito é vital para uma correta aplicação do sistema de proteção.

2.3.2 Natureza dos defeitos

A natureza dos defeitos é simplesmente definida como qualquer condição que venha causar uma redução no isolamento entre os condutores das fases, ou entre os condutores das fases e terra. Na prática, uma redução de isolamento não é considerada como um defeito até que seja detectável, isto é, até que resulte em algumas das alternativas: aumento de corrente; redução da impedância entre condutores (ou condutores e terra) a um valor baixo da menor impedância normal de carga do circuito. Então, um alto grau de poluição em uma cadeia de isoladores, embora reduza o isolamento da fase afetada, não caracteriza um defeito que provoque uma descarga através da cadeia, que produza corrente elevada ou outra anormalidade detectável.

Outras causas de defeito são: Falhas nas linhas de transmissão (pássaros, aeronaves, descargas atmosféricas, isoladores quebrados ou perfurados, circuitos abertos de condutores, carregamentos anormais; máquinas, cabos e transformadores), falha de isolamento, danos mecânicos, contatos acidentais com a terra, sobretensão, carregamento anormal.

Todos os incidentes originários dessas causas são denominados defeitos "primários" ou "de sistema". Outro tipo de defeito é considerado como secundário, porque

define uma operação de proteção que resulta no disparo sem existência de um defeito no sistema de potência.

Tais defeitos podem ser resultados de falhas na proteção, por exemplo, ajuste incorretos, conexão incorreta ou defeituosa ou erros humanos quando da realização de teste ou manutenção.

2.4 Filosofia de Proteção

Considere aqui os equipamentos para a proteção contra curtos-circuitos no sistema. Existem dois grupos de tais equipamentos: proteção principal ou de primeira linha, e proteção secundária ou de retaguarda.

A proteção principal é a primeira linha de defesa, enquanto que a proteção de retaguarda utiliza-se somente quando ocorre uma falha na proteção principal.

2.4.1 Proteção principal

Na Figura 2.1 ilustram-se as zonas de proteção principal. Os disjuntores são localizados nas conexões de cada elemento do sistema de potência. Esta provisão faz possível desconectar somente o elemento defeituoso. Ocasionalmente, um disjuntor entre dois elementos adjacentes pode ser omitido, neste caso ambos elementos devem ser desconectados pela falha em qualquer dos dois elementos.

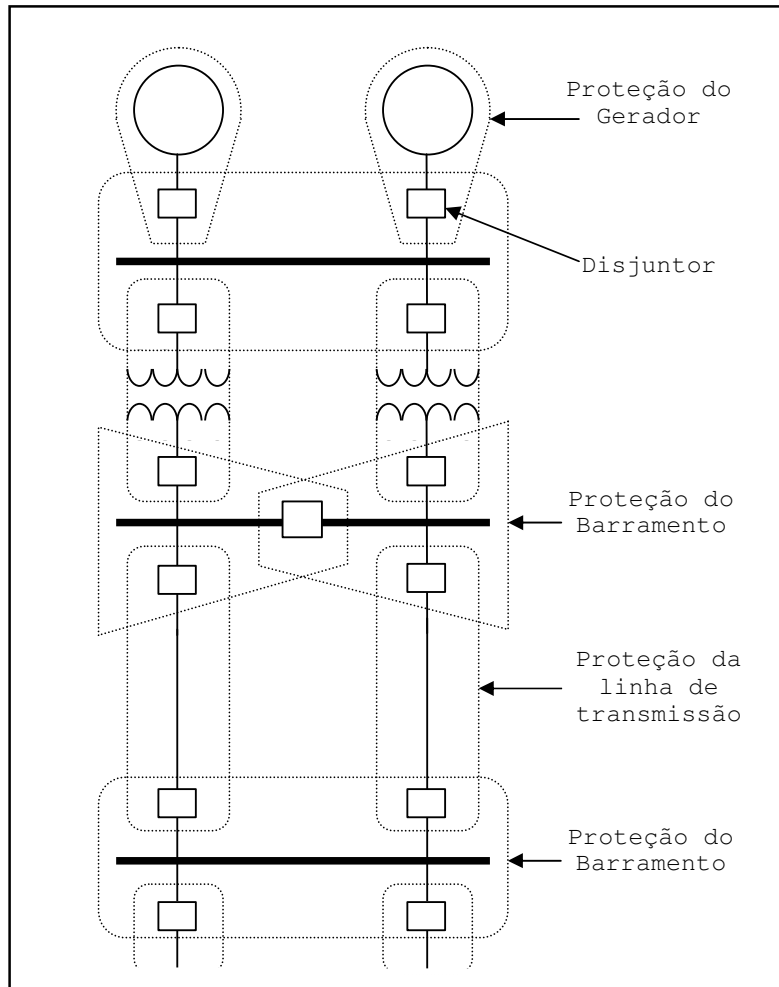


Figura 2.1 - Diagrama de um sistema de potência ilustrando as zonas de proteção principal

Uma zona distinta de proteção é estabelecida em volta de cada elemento do sistema. A ocorrência de qualquer falha dentro de uma dada zona ocasiona a abertura de todos os disjuntores desta zona, e somente esses disjuntores.

Isto torna evidente que, para falhas dentro de uma região onde duas zonas de proteção adjacentes coincidem, muitos disjuntores são "abertos" mais do que o mínimo necessário para desconectar o elemento defeituoso.

Finalmente pode-se observar que zonas de proteção adjacentes da Figura 2.1. se entrelaçam em volta de um disjuntor. Isto é preferido na prática porque, para falhas em

qualquer lugar, exceto na região entrelaçada, um número mínimo de disjuntores serão abertos. Por outro lado, entrelaçar as zonas adjacentes evita a possibilidade de áreas desprotegidas. Isto é ilustrado na Figura 2.2.

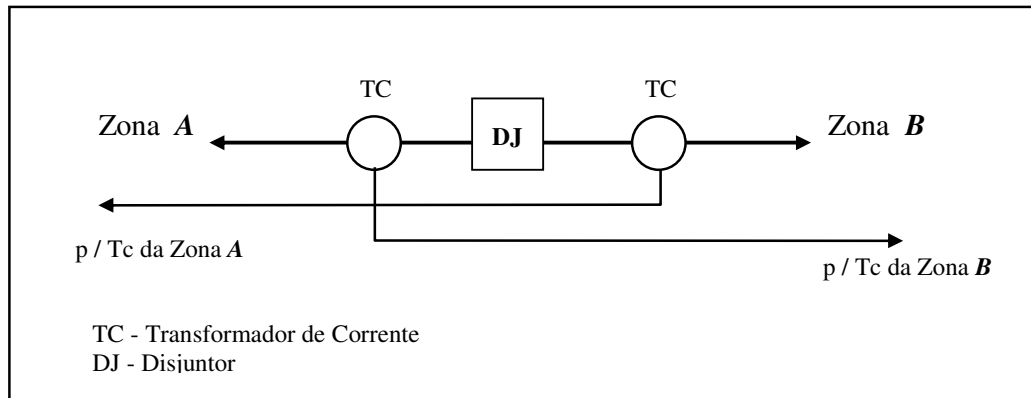


Figura 2.2 - Entrelaçamento das zonas de proteção adjacentes

2.4.2 Proteção de retaguarda

Existem duas razões para a utilização da proteção de retaguarda. A primeira é óbvia: reserva da proteção principal. A segunda justifica-se para cobrir aquelas partes de um circuito protegido que não são atendidas pela proteção principal, por razão da localização dos transformadores de corrente e potencial. A Figura 2.3 ilustra esta filosofia.

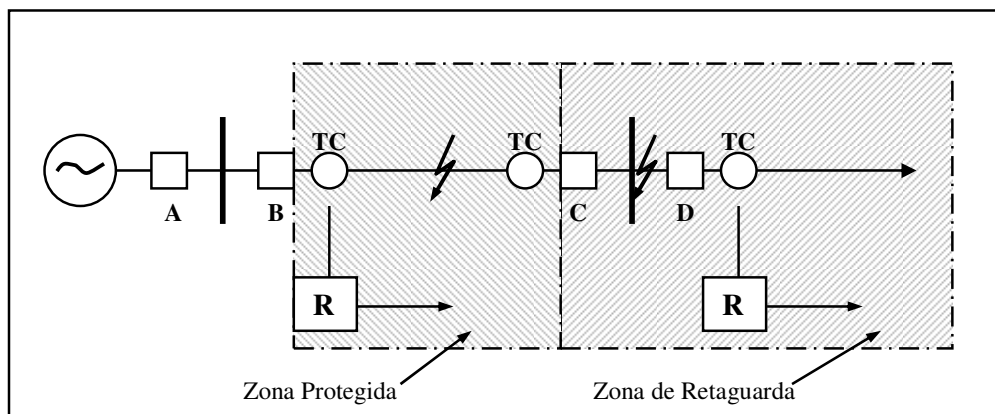


Figura 2.3 - Filosofia de proteção

Quando afirma-se que a proteção principal pode falhar, quer se dizer que muitas ações podem acontecer para impedir que a proteção principal induza à desconexão do defeito no sistema de potência. A proteção principal pode falhar devido a falências apresentadas:

1. No fornecimento de corrente ou tensão para os relés;
2. Na proteção dos relés;
3. No mecanismo de abertura dos disjuntores;
4. Nos disjuntores.

É desejável que a proteção de retaguarda seja organizada de modo que qualquer que seja a causa de falha da proteção principal, não ocasione também a falha da proteção de retaguarda. É evidente que este requisito é completamente satisfeito somente se os relés de proteção de retaguarda estão localizados de modo que não utilizem ou controlem qualquer coisa em comum com os relés de proteção principal que estão sendo resguardados. Considere, por exemplo, a proteção de retaguarda para a linha de transmissão *EF* da Figura 2.4. Os relés de retaguarda para esta linha são normalmente organizados para abrir os disjuntores *A*, *B*, *I* e *J*. Assim, na ocorrência de uma falha na abertura do disjuntor *E* pelo defeito na linha *EF*, os disjuntores *A* e *B* são abertos, sendo o sistema apartado fisicamente do equipamento falido.

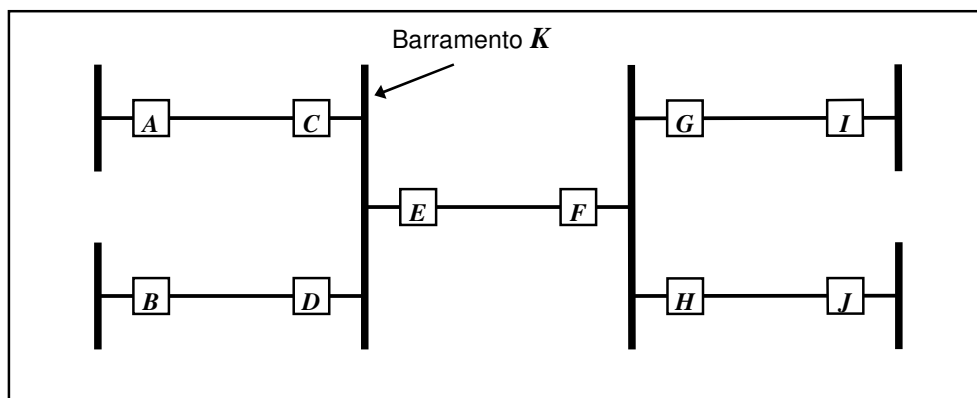


Figura 2.4 - Ilustração para a proteção de retaguarda da linha de transmissão EF

Os relés de retaguarda localizados nos pontos *A*, *B* e *F* fornecem a proteção de retaguarda para defeitos no barramento *K*. Além disso, os relés de retaguarda *A* e *F*

forneem a proteção de retaguarda para defeitos na linha **DB**. Em outras palavras, a zona de proteção dos relés de retaguarda estende-se em uma única direção a partir da localização de qualquer relé de retaguarda e pelo menos entrelaça-se a cada elemento adjacente do sistema.

Uma segunda função dos relés de retaguarda é muitas vezes cuidar da proteção principal quando os equipamentos desta estão fora de serviço por causa de manutenção preventiva ou reparo.

2.5 Relés de Proteção e Suas Aplicações

Os relés de proteção medem a quantidade associada a certas grandezas do sistema de potência e inicia uma ação apropriada quando uma dada condição de operação ocorre. A medição pode ser de uma simples grandeza fundamental (tal como: corrente, tensão ou frequência), envolvendo uma simples determinação de magnitude ou a grandeza pode ser integrada num certo período de tempo. A integração pode ser fixa ou variável. Alternativamente, o relé pode ser suprido com mais de uma grandeza do sistema; sendo então a medição uma soma, diferença, produto ou relação das grandezas de entrada. A resolução pode ser mais complexa levando em conta o ângulo de fase, como na medição de potência, ou mesmo ser uma natureza menos facilmente definida, mas dando ao relé uma característica de resposta especial, como é feito em muitos relés de distância. A seguir será apresentada uma descrição sucinta dos relés mais utilizados.

2.5.1 Relés diferenciais

Com base na Lei das Correntes Kirchhoff, que estabelece que a soma algébrica das correntes que saem de qualquer nó é zero, os relés diferenciais são o principal esquema de proteção de transformadores de força, geradores, barramentos e cabos subterrâneos. Quando conectado de uma maneira adequada, quase qualquer tipo de relé pode operar como um relé diferencial.

Esta proteção apresenta uma zona de atuação bem definida, limitada pelos transformadores de corrente, sem nenhum retardo intencional de operação (temporização), conforme mostrado na Figura 2.5.

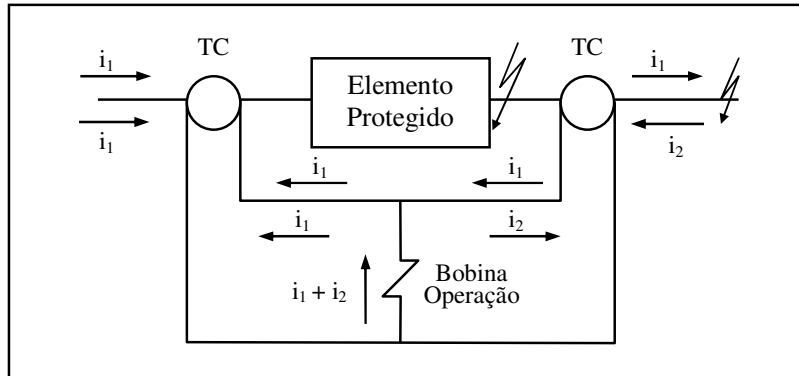


Figura 2.5 - Ligação diferencial

No caso específico de transformadores de força, esses relés podem não ser tão sensíveis quanto os relés diferenciais utilizados na proteção de geradores e barramentos. Os relés diferenciais de transformadores estão sujeitos a vários fatores, que podem causar operações indevidas:

- Diferentes níveis de tensão;
- Dificuldade de casamento de relações dos transformadores de corrente;
- Defasagem angular de 30° introduzida pelo transformadores de força com conexão ΔY ;
- Correntes de magnetização.

2.5.2 Relés de distância

Talvez tais relés formem a família mais interessante e versátil de relés de proteção. O princípio de operação do relé de distância é baseado no fato que, de qualquer ponto de medição no sistema de potência a impedância da linha para o defeito neste sistema pode ser determinada pela medição da tensão e corrente no ponto de medição, é dizer, um relé

de distancia compara a corrente e a tensão do sistema de potência para determinar a existência de um defeito dentro ou fora de sua zona de operação.

A maior vantagem dos relés de distância é que sua zona de operação é uma função somente da impedância da linha protegida, que é uma constante, e é relativamente independente dos módulos de tensão e corrente. Logo, os relés de distância possuem um alcance fixo, isto é, não variam devido a mudanças nas condições operativas do sistema (topologia). Algumas características representadas em um diagrama **R-X** são mostradas na Figura 2.6.




Figura 2.6 - Características dos relés de distância

As zonas de operação estão no interior dos círculos para os tipos (a), (b) e (c). Isto é, qualquer fasorial $V:I$ que caia dentro do círculo, a unidade de distância opera. Os tipos (a) e (d) possuem uma característica não direcional; são utilizados geralmente como detectores de defeito no sistema elétrico. O tipo (c) possui uma característica direcional, sendo utilizado em esquemas independentes de proteção de linhas, enquanto o tipo (b) possui uma característica deslocada (*off-set*), que garante a sua operação para defeitos com tensão "zero" (cruzamento dos eixos), essencial nos esquemas de teleproteção. Os tipos (b) e (c) usualmente constituem três zonas de proteção: proteção principal, responsável pela detecção e eliminação de defeitos em 100% da linha de transmissão, deve operar sem qualquer retardo (esquemas de teleproteção); proteção de retaguarda de 1ª zona, responsável pela proteção de 80-90% da linha de transmissão, serve como retaguarda instantânea; e proteção de retaguarda de 2ª zona, geralmente ajustada em 120-150% do comprimento da linha de transmissão, serve como retaguarda das linhas adjacentes. Por último, é apresentada a característica *blinders* que é muito usada quando a impedância de

carga (carga pesada) situa-se próxima a zona de operação do relé, o que pode provocar operações indevidas quando da ocorrência de oscilações de potência.

2.5.3 Relés de proteção para falha de disjuntor

Com o crescente interesse na continuidade de serviço, esquemas para falha de disjuntor (*Breaker-failure*) vêm sendo implementados pelas concessionárias de energia elétrica. Quando da ocorrência de defeito no sistema elétrico os relés de proteção operam e além de enviarem um comando de abertura para o seu respectivo disjuntor, é iniciado o esquema de falha do disjuntor. Se após um determinado período de tempo, geralmente 600 ms, o disjuntor não opera, o esquema de falha do disjuntor atua para abrir os outros disjuntores associados à barra do disjuntor falhado. Este esquema evita danos aos equipamentos do sistema elétrico, devido a condições de defeitos sustentados, uma vez que não existindo esse esquema o defeito seria eliminado pela proteção de retaguarda temporizada dos terminais remotos de todas as linhas associadas à barra, o que elevaria em muito o tempo de eliminação do defeito. Muitos disjuntores modernos dispõem de duas bobinas de abertura independentes.

O esquema é basicamente constituído de um relé detector de sobrecorrente (função 50BF) que fica permanentemente operado, um temporizador (função 62BF) responsável pela discriminação da falha do disjuntor, e um ou dois relés auxiliares (função 62X e Y) que, energizados pelos relés de proteção dos componentes, confirmam o disparo da proteção através da outra bobina de abertura e dão início ao esquema de falha de disjuntor. Se o disjuntor efetivamente abre, a corrente é cessada e o relé função 50BF é desarmado, normalizando o esquema. Caso contrário, enquanto houver corrente circulando, significa que o disjuntor não abriu e o relé função 50BF mantém o temporizador energizado. Ao final do tempo programado, um comando é enviado para a abertura de todos os disjuntores da barra.

Na Figura 2.7 é apresentado um diagrama de tempo do esquema em questão.

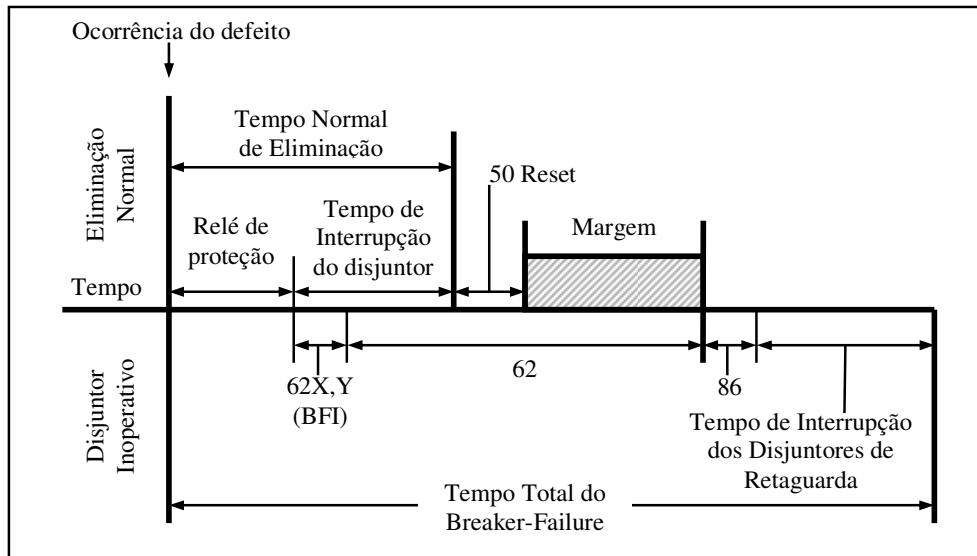


Figura 2.7. - Diagrama de Tempo do Esquema de Falha de Disjuntor

2.6 Avaliação dos Relés de Proteção

Embora um sistema de potência moderno não possa operar sem relés de proteção, este não torna-se inestimável. Como em todo planejamento, a economia tem um papel muito importante. Ainda que a engenharia de proteção possa usualmente justificar despesas em relação aos relés de proteção, diversas circunstâncias podem mudar tais conceitos, e muitas vezes torna necessário avaliar os benefícios a serem atingidos. Geralmente não é uma questão de se os relés de proteção são justificados, mas de que maneira pode-se encaminhar em direção a um melhor investimento na disponibilidade dos relés.

Semelhante a todas as outras partes de um sistema de potência, os relés de proteção precisam ser avaliados sobre a base de sua contribuição ao serviço mais economicamente possível dos clientes. A contribuição dos relés de proteção é ajudar ao resto do sistema de potência no funcionamento tão eficientemente e tão efetivamente como possível frente a uma dificuldade [HL86]. De que modo os relés de proteção cuidam disto é mostrado a seguir. Em relação à minimização dos danos quando ocorrem falhas, os relés de proteção minimizam:

1. O custo de consertar o dano;
2. A probabilidade que o problema possa espalhar-se e comprometer outros equipamentos;
3. O tempo que o equipamento fica fora de serviço;
4. A perda no rendimento enquanto o equipamento está fora de serviço.

Pelo expressado anteriormente, os relés de proteção ajudam a minimizar a quantidade do equipamento de reserva necessário, desde que exista uma menor probabilidade de que outra falha ocorra antes do conserto da primeira falha. A qualidade dos equipamentos de proteção podem afetar o custo do planejamento na aplicação dos próprios equipamentos. Equipamentos de proteção que possam operar apropriadamente, ainda quando mudanças futuras são feitas no sistema ou na sua operação, evitam custos de planejamentos futuros e outros custos relacionados.

Não se pode concluir que o custo justificável para um dado equipamento de proteção é necessariamente proporcional ao valor ou importância do elemento do sistema a ser diretamente protegido. Uma falha com aquele elemento do sistema pode afetar a habilidade do sistema inteiro para o serviço prestado, portanto aquele equipamento de proteção está atualmente protegendo o serviço do sistema inteiro. Alguns dos mais sérios *blackouts* têm sido causados pelos efeitos consecutivos de uma falha originada num equipamento relativamente não importante que não estava protegido apropriadamente [R98b].

2.7 Proteção Digital Versus Convencional

Computadores têm sido aplicados em uma grande variedade de tarefas "*offline*" e "*online*" relacionadas a análise e operação do sistema elétrico. Tarefas "*offline*" incluem estudos de fluxo de carga, estudos de curto-circuito, estudos de estabilidade, estudos de confiabilidade, ajustes de relés, análise de perturbações e estudos de coordenação. Tarefas "*online*" incluem despacho de geração, aquisição de dados, controle e supervisão (SCADA), supervisão de seqüência de eventos, registros oscilográficos, etc.

O uso de tecnologia digital na proteção de equipamentos do sistema de proteção é de origem relativamente recente, sendo os primeiros relés e sistemas digitais disponibilizados comercialmente em meados da década de 80 [P98]. As vantagens oferecidas pela tecnologia digital aplicada a relés, e algumas incertezas que prejudicam sua imediata aplicação são resumidas abaixo. Entre os benefícios estão:

a) Custo - O custo de um relé digital nos estágios iniciais era de 10 a 20 vezes maior do que o custo do relé convencional. Durante os últimos anos, o custo do computador digital foi decrescendo constantemente, ao mesmo tempo em que sua potência computacional aumentou substancialmente. O custo dos relés convencionais aumentou nesse mesmo período, primeiramente por causa de alguns melhoramentos no projeto mas também devido a um relativamente baixo volume de produção e venda. Nos dias atuais, o custo de um relé digital (incluindo software) em relação ao relé convencional é igual, para o mesmo desempenho. Esta análise leva em conta o fato de que um único relé digital substitui em alguns casos de três a quatro relés convencionais, reduzindo também a necessidade de condutores e espaço nos painéis de subestações.

b) Auto verificação e confiabilidade - O relé digital pode ser programado para supervisionar continuamente seus subsistemas, tanto hardware quanto software, detectando dessa forma qualquer mau funcionamento que possa vir a ocorrer. Ele pode assim ser projetado a falhar em um modo seguro, isto é, levado a ficar fora de serviço se uma falha for detectada, e enviar um alarme para o centro de operação. Essa característica dos relés digitais é talvez o maior argumento técnico a favor desta tecnologia.

A má operação de relés não é uma ocorrência freqüente, considerando-se o grande número de relés existentes no sistema elétrico. Por outro lado, a maioria dos colapsos no sistema de potência está associada a operações incorretas de relés. Assim sendo, espera-se que com a característica de auto verificação dos relés digitais, falhas em componentes dos relés possam ser detectadas logo após ocorrerem, podendo ser reparadas antes que os mesmos tenham chance de operar incorretamente. Nesse sentido, embora os relés digitais sejam mais complexos do que os relés eletromecânicos ou estáticos, e daí teoricamente com maior probabilidade de ocorrer uma falha, do ponto de vista de um sistema integrado eles são mais confiáveis.

c) *Flexibilidade funcional e relés adaptativos* - Considerando que computadores digitais podem ser programados para desempenhar várias funções, desde que tenham os sinais de entrada e saída necessários àquelas funções, é mais fácil o relé digital executar outras tarefas na subestação. Por exemplo, medição e supervisão de fluxos e tensão em transformadores e linhas de transmissão, controle de abertura e fechamento de disjuntores e chaves, são algumas funções que podem ser realizadas pelos relés digitais.

A função de proteção necessita de intensa atividade computacional quando um defeito ocorre no sistema elétrico. Esta intensa atividade ocupa ao relé digital uma pequena fração de sua vida útil, menos de 0,1%. O relé digital pode então realizar outras tarefas praticamente sem nenhum custo extra. Com a capacidade de programação e comunicação, o relé digital oferece ainda outra possível vantagem, não facilmente realizável nos relés convencionais, que é a habilidade de mudar as suas características (ajustes) em função das condições do sistema.

A alta expectativa gerada pelos benefícios dos relés digitais deve ser moderada e, função de várias questões não resolvidas. A tecnologia digital avançou muito nos últimos vinte anos. Isto implica que o hardware tem um tempo de vida útil relativamente curto. As mudanças significativas de hardware em curto período de tempo e a questão de manutenção tornam-se cruciais.

Os relés existentes têm apresentado bom desempenho por longos períodos, alguns ao longo de trinta anos ou mais. Tais relés foram mantidos durante esse período. É difícil considerar um tempo de vida similar para relés baseados na tecnologia digital. A solução talvez seja a modularidade do hardware.

Os programas de computadores para aplicação em relés, são em grande parte escritos inteiramente em linguagem de máquina. A razão para isso, é a necessidade de utilizar o tempo disponível após da ocorrência de um defeito tão eficientemente quanto possível. Linguagens de alto nível tendem a ser ineficientes nas aplicações de relés. O problema com a linguagem de máquina é sua não portabilidade. Desde que o custo do software seja uma parte muito significativa no desenvolvimento dos relés digitais, a falta de portabilidade de software é um problema a ser considerado.

Existe ainda a preocupação com o ambiente adverso das subestações onde os relés devem funcionar. Temperaturas extremas, umidade, poluição, assim como interferência eletromagnética devem ser previstas. Não existem dúvidas de que os relés digitais podem ser robustos de modo a suportar todas essas adversidades. Entretanto, para tal, pode ser necessário adotar medidas caras. Porém, o sentimento geral entre os engenheiros de proteção atualmente é de que todos os problemas relacionados à ambientação são tecnicamente solucionáveis, e somente mais experiências reais de instalação de campo revelarão se existe qualquer problema não previsto a ser resolvido nessa área.

A utilização dos relés de proteção digitais amplia os recursos para um diagnóstico de defeito mais seguro, face à grande quantidade de informações disponíveis e discriminadas por função, não implicando em grandes investimentos por parte do projeto. No caso de relés convencionais, por exemplo, a obtenção da função de proteção ou mesmo do relé que atuou envolve uma modificação substancial do projeto, uma vez que os mesmos, além de não possuírem contatos disponíveis, atuam em um único circuito de disparo (*trip*), não possibilitando dessa forma a discriminação da informação.

O esquema para o caso dos relés convencionais é ilustrado na Figura 2.8, enquanto a Figura 2.9 ilustra o caso para os relés digitais.

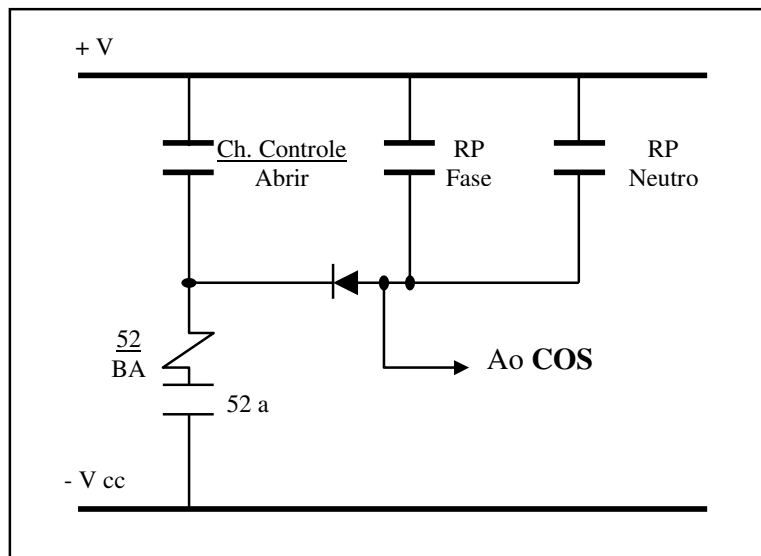


Figura 2.8 - Diagrama esquemático com relés convencionais

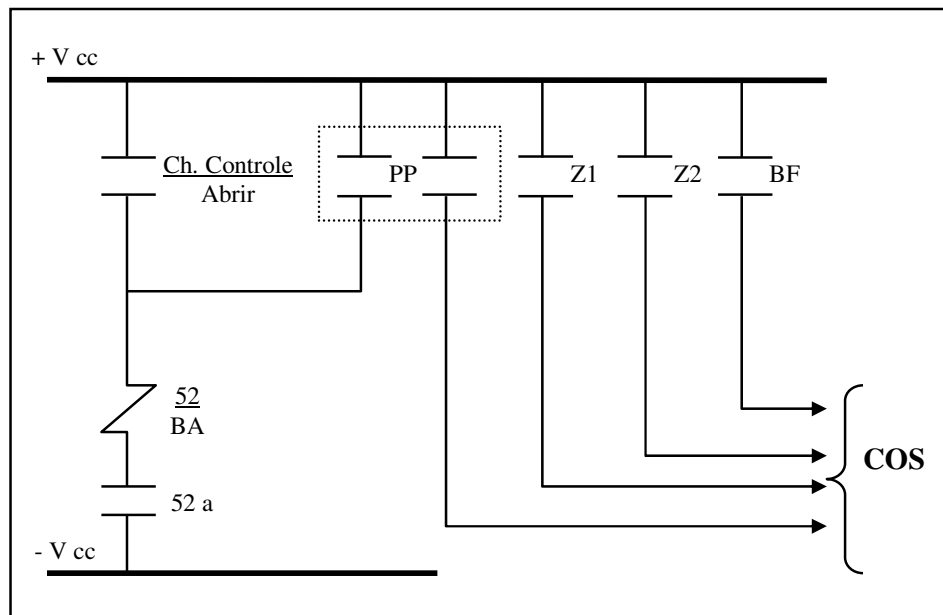


Figura 2.9 - Diagrama esquemático com relés digitais

2.8 Estado Atual e Perspectivas Futuras

Atualmente, na grande maioria das concessionárias de energia elétrica, é responsabilidade dos operadores analisar e identificar quais componentes do sistema elétrico foram submetidos a um defeito, utilizando para tal as informações de alarmes disponíveis. Como consequência, ações apropriadas são tomadas para restabelecer o sistema elétrico a uma condição normal de operação.

Este diagnóstico é baseado em regras heurísticas construídas a partir da experiência vivida pelos operadores. Entretanto, nos casos de distúrbios de grande porte, defeitos múltiplos ou na falha de operação de dispositivos de proteção, a obtenção de um diagnóstico preciso e rápido torna-se difícil, e em alguns casos, impossível.

Com o advento da tecnologia digital, e tendo em vista a necessidade de redução do custo da mão de obra, uma nova concepção de operação do sistema elétrico vem se impondo. Algumas subestações e usinas digitalizadas operam de forma totalmente desassistidas, controladas remotamente através dos Centros de Operação Regionais (COR)

e/ou do Centro de Operação do Sistema (COS). Esta mudança de concepção tornou-se viável através da utilização de relés de proteção digitais, medidores digitais, unidades de controle, todos interligados via rede de comunicação local (fibra ótica) a uma Unidade Central ou Unidade Terminal Remota (UTR) local. Os dados são atualizados constantemente e transmitidos via modem aos Centros de Operação.

Os dados são armazenados localmente na Unidade Central da subestação/usina e remotamente nos Centros de Operação em forma de listas cronológicas, sendo classificados como evento ou alarmes. Qualquer ocorrência na subestação/usina é considerada como evento e os alarmes são todos os eventos gerados por condições anormais de operação, necessitando da ação e reconhecimento do operador para sua normalização.

Até o momento, medições adequadas e a manipulação dos alarmes dentro do Centro de Operação (COS) ainda não resolveram satisfatoriamente o problema de diagnóstico. Nos casos de distúrbios, os relés de proteção, tanto quanto disjuntores e outras unidades de proteção, geram mensagens e alarmes. Dependendo da disponibilidade dos meios de comunicação, essas mensagens originárias de diferentes instalações e vários equipamentos do sistema elétrico de potência são transmitidas aos Centros de Operação.

A maneira de apresentação das mensagens e algumas restrições técnicas tornam complicada a análise e obtenção, por parte dos operadores, de uma conclusão confiável:

- Os sistemas SCADA freqüentemente apresentam as mensagens e alarmes como listas cronológicas. Interfaces gráficas usualmente carecem de muitas informações dos dispositivos de proteção necessárias à interpretação dos alarmes recebidos;
- No caso de defeitos no sistema elétrico de potência, o operador recebe uma sobrecarga de informações. Testes comprovaram, que o ser humano não pode interpretar corretamente mais do que 2 a 3 mensagens por segundo. Nos grandes distúrbios uma média de 15 a 20 mensagens por segundo são geradas;

- Alarmes causados por eventos secundários podem facilmente ser misturados com alarmes causados pelo distúrbio primário;
- O conjunto de mensagens pode ser incompleto e inconsistente, devido a mau funcionamento de relés, falha de disjuntores ou ausência de meios de comunicação em algumas subestações.

Após um distúrbio, o operador tem que selecionar as mensagens apropriadas, obter as conclusões dos dados disponíveis, e tomar as ações apropriadas para o restabelecimento do sistema. A utilização de um processamento automático de alarmes para apoio a decisão nos centros de operação efetivamente auxiliará o operador e acelerará o restabelecimento de energia aos consumidores. Além disso, o perigo da amplitude dos defeitos devido a má interpretação dos alarmes pode ser reduzida.

LÓGICA DIFUSA E REDES NEURAIIS

3.1 Introdução

A Lógica Difusa e as Redes Neurais Artificiais são alguns dos elementos da Inteligência Artificial (IA), que é parte da ciência de computação. IA compreende o estudo e criação de sistemas computarizados que mostram certa forma de inteligência: sistemas que aprendem novos conceitos e tarefas, sistemas que podem raciocinar e derivar conclusões úteis do mundo que nos rodeia, sistemas que podem compreender uma linguagem natural ou perceber e compreender uma cena visual, e sistemas que realizam outro tipo de atividade que requer inteligência.

Apesar da diversidade de conceitos propostos para IA, geralmente todos coincidem em que IA trata de alcançar inteligência através da computação. Segundo os objetivos, a IA pode ser considerada em parte como engenharia e em parte como ciência. Como engenharia, o objetivo da IA é resolver problemas reais, atuando como um conjunto de idéias de como representar e utilizar o conhecimento, e de como desenvolver sistemas computacionais. Como ciência, o objetivo da IA é procurar explicação das diversas classes de inteligência, através da representação do conhecimento e da aplicação nos sistemas computacionais desenvolvidos.

3.2 Lógica Difusa

Dois dos principais aspectos da imperfeição da informação são a imprecisão e a incerteza. Estas duas características são intrinsecamente ligadas e opostas entre si: quanto melhor se pode modelar a incerteza mais se diminui a imprecisão e vice-versa. Por

exemplo, suponhamos que estejamos seguros em dizer que um dado filme começa entre 3h e 4h. Se formos obrigados a dar uma opinião mais precisa, tenderemos a aumentar a incerteza, dizendo, por exemplo, que o filme começará as 3h30' com uma probabilidade diferente de 1. Uma informação imprecisa também pode ser vaga, como por exemplo, quando dizemos que o filme começa "por volta das 3h30".

As teorias mais conhecidas para tratar imprecisão e incerteza são respectivamente a teoria dos conjuntos e a teoria das probabilidades. Estas teorias, embora muito úteis, nem sempre conseguem captar a riqueza da informação fornecida por seres humanos. A teoria dos conjuntos não é capaz de tratar o aspecto vago da informação e a teoria de probabilidades, na qual a probabilidade de um evento determina completamente a probabilidade do evento contrário, é mais adaptada para tratar de informações extraídas de uma massa de dados do que aquelas fornecidas por seres humanos [SC97].

A teoria dos conjuntos difusos foi desenvolvida a partir de 1965 por Lotfi Zadeh, para tratar do aspecto vago da informação [Z65]. A teoria dos conjuntos, que será chamada nesta dissertação de "clássica", pode ser vista então como um caso particular desta teoria mais geral. A partir de 1978, Lotfi Zadeh desenvolveu a teoria de possibilidades [Z78], que trata da incerteza da informação, podendo pois ser comparada com a teoria das probabilidades. Esta teoria, por ser menos restritiva, pode ser considerada mais adequada para o tratamento de informações fornecidas por seres humanos que a de probabilidades. Efetivamente, mesmo no discurso usual percebemos que a noção de possibilidade é menos restritiva que aquela da probabilidade: é mais fácil dizer que algum evento é possível do que provável.

A teoria dos conjuntos difusos e a teoria de possibilidades são intimamente ligadas. Por exemplo, o conjunto difuso que modela a informação "idade avançada" pode ser usado para modelar a distribuição de possibilidade da idade de uma dada pessoa, da qual só sabemos que ela é idosa. O fato destas teorias serem ligadas é muito importante no sentido de que é possível se tratar tanto a imprecisão quanto a incerteza de um conjunto de informações em um único ambiente formal. De fato, a maior parte do tempo não é necessário fazer a distinção entre um conjunto difuso e uma distribuição de possibilidades.

Estas teorias têm sido cada vez mais usadas em sistemas que utilizam informações fornecidas por seres humanos para automatizar procedimentos quaisquer, como por exemplo no controle de processos, no auxílio à decisão, etc. Estas teorias têm sido utilizadas em aplicações que vão do controle de eletrodomésticos ao controle de satélites, do mercado financeiro à medicina, e tendem a crescer cada vez mais, sobretudo em sistemas híbridos, que incorporam abordagens conexionistas e evolutivas, no que é chamado hoje em dia, de "*soft computing*".

A teoria dos conjuntos difusos, quando utilizada em um contexto lógico, como o de sistemas baseados em conhecimento, é conhecida como lógica difusa, lógica nebulosa ou lógica "*fuzzy*". A seguir, serão mostrados as definições básicas da teoria dos conjuntos difusos.

3.2.1 Conjuntos difusos

Na teoria clássica dos conjuntos, denominado usualmente de "*crisp*", a transição de um dado elemento do universo entre a pertinência e a não-pertinência é dada por uma função binária que apresenta descontinuidades abruptas e bem definidas. Isto determina o caráter rígido apresentado pelas fronteiras de tais conjuntos. Já para um elemento do universo pertencente a um conjunto difuso, desenvolvido por Lofti Zadeh, esta transição pode dar-se de modo suave e gradual, devido ao fato de que as fronteiras exibidas por tais conjuntos apresentam um caráter vago, nebuloso, impreciso e ambíguo.

Na Figura 3.1b mostra-se o limite incerto ou ambíguo de um conjunto difuso A sob o universo de discurso Ω : o limite sombreado representa a região limite de A . Na região central do conjunto difuso, o ponto a é claramente membro pleno de A . Fora da região limite do conjunto difuso, o ponto b é claramente não membro do conjunto difuso. Entretanto, a associação do ponto c , o qual fica sob a região limite, é ambíguo. Se a pertinência no conjunto é representado pelo número 1, e a não pertinência é representado pelo 0, então o ponto c da figura deve ter algum valor intermediário de pertinência sob o intervalo $[0,1]$. Presumivelmente a pertinência do ponto c em A aproxima-se ao valor de 1

quando este movimenta-se perto da região central na figura, e aproxima-se ao valor de 0 quando este movimenta-se perto da saída da região limite de A .




Figura 3.1 - a) Limites do conjunto clássico b) Limites do conjunto difuso

Assim, um conjunto difuso, é um conjunto contendo elementos que têm diversos graus de pertinência ao conjunto. Esta idéia é diferente com conjuntos convencionais ou "*crisp*", Figura 3.1a, porque membros de um conjunto convencional não poderiam ser membros a menos que sua pertinência fosse total ou completa neste conjunto (sua pertinência é designado pelo valor de 1). Elementos num conjunto difuso, porque sua associação não necessita ser completa ou total, podem também ser membros de outros conjuntos difusos sob o mesmo universo de discurso Ω .

Portanto, a função pertinência de um elemento do universo a um conjunto difuso apresenta como propriedade a capacidade de descrever o grau de vaguidão, de ambigüidade ou de imprecisão de pertinência do elemento ao conjunto.

3.2.1.1 Funções de caracterização ou pertinência

Formalmente, um conjunto difuso A do universo de discurso Ω é definido por uma função de pertinência $\mu_A : \Omega \rightarrow [0,1]$. Essa função associa a cada elemento x de Ω o grau $\mu_A(x)$, com o qual x pertence a A [Z65]. A função de pertinência $\mu_A(x)$ indica o grau de compatibilidade entre x e o conceito expresso por A :

- $\mu_A(x) = 1$ indica que x é completamente compatível com A ;
- $\mu_A(x) = 0$ indica que x é completamente incompatível com A ;
- $0 < \mu_A(x) < 1$ indica que x é parcialmente compatível com A , com grau $\mu_A(x)$.

Um conjunto A da teoria dos conjuntos clássica pode ser visto como um conjunto nebuloso específico, denominado usualmente de "*crisp*", para o qual $\mu_A(x) : \Omega \rightarrow \{0,1\}$, ou seja, a pertinência é do tipo "tudo ou nada", "sim ou não", e não gradual como para os conjuntos difusos.

A diferença entre estes conceitos em relação à variável idade é ilustrada na Figura 3.2a e na Figura 3.2b, que descrevem respectivamente a representação do conceito "adolescente" através de um conjunto "*crisp*" e de um conjunto difuso.




Figura 3.2 - a) Função característica do conjunto "*crisp*" adolescente b) Função trapezoidal característica do conjunto difuso adolescente

O conjunto "*crisp*" A não exprime completamente o conceito de "adolescente", pois uma pessoa com 12 anos e 11 meses seria considerada completamente incompatível com este conceito. Na verdade, qualquer intervalo "*crisp*" que se tome para representar este conceito é arbitrário.

Já o conjunto difuso B permiti exprimir que qualquer pessoa com idade entre 13 e 17 anos é um adolescente, acima de 19 ou abaixo de 11 não é considerado um adolescente, e no intervalo $[11,13]$ (respectivamente $[17,19]$) é considerado tanto mais adolescente quanto mais próxima de 13 (respectivamente de 17) é sua idade.

A utilização de funções de caracterização com representação de pertinência permite definir o conceito de *variável difusa*. Uma variável difusa apresenta a propriedade de mapear transições graduais entre estados e, conseqüentemente, possuem a capacidade natural de representar conceitos lingüísticos e cognitivos tais como, por exemplo, os de expressão, de negociação, de tratamento, de relacionamento ou de comportamento. Variáveis tradicionais ou Binárias, não apresentam esta capacidade. Embora a definição de estados através de conjuntos convencionais seja matematicamente correta, ela comporta-se de maneira irrealista face às incertezas e/ou erros presentes no problema.

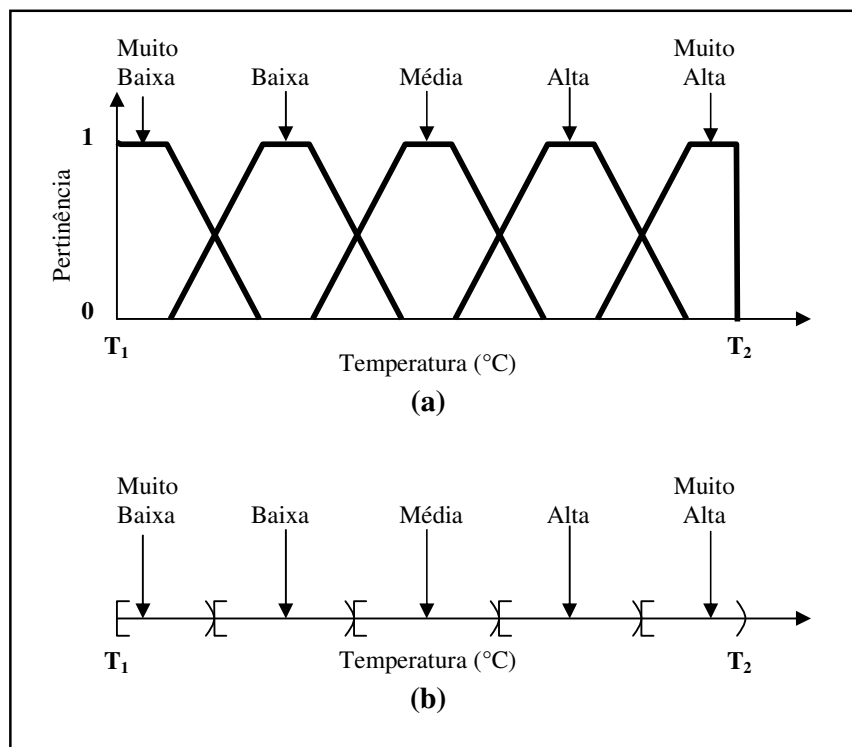


Figura 3.3 - Máquinas de estado de classificação de temperatura

Na figura 3.3, apresenta-se duas máquinas de estado capazes de classificar temperaturas. Em (a) tem-se uma máquina de estado difuso, é dizer, que utiliza variáveis de estado imprecisas. Nela pode-se observar a sobreposição das fronteiras dos conjuntos difusos utilizados na composição da máquina. Observa-se que, nesta máquina de estados, um dado ponto de temperatura possui um grau de pertinência não binário associado a cada um dos diversos estados de temperatura definidos na máquina; o funcional *grau de pertinência* é capaz de elucidar as transições suaves entre os diversos estados que o sistema pode assumir.

Em (b) observa-se a mesma máquina de estados de classificação de temperatura apresentada em (a), porém, agora definida sobre conjuntos convencionais. Observe que um dado ponto de temperatura possui um grau de pertinência binário associado aos estados de temperatura definidos na máquina. Aqui, o funcional *grau de pertinência* é capaz de elucidar somente transições binárias entre os possíveis estados de temperatura que o sistema pode assumir.

3.2.1.2 Cardinalidade, cortes- α e altura de um conjunto difuso

A cardinalidade é uma propriedade que determina o número de elementos de um conjunto. Na lógica clássica este conceito torna-se transparente já que é fácil perceber se um determinado elemento pertence ou não a um conjunto. Na teoria dos conjuntos difusos isto não é tão evidente, uma vez que o número de elementos pode estar relacionado com a pertinência do conjunto.

A cardinalidade de um conjunto difuso A é expressa como:

- Para Ω discreto

$$|A| = \sum_{x \in \Omega} \mu_A(x) \quad (3.1)$$

- Para Ω contínuo

$$|A| = \int_{\Omega} \mu_A(x) \quad (3.2)$$

Pode-se obter a representação aproximada de um conjunto difuso A em Ω através de conjuntos "*crisp*" em Ω . Estes subconjuntos, denotado por A_α e denominados de cortes de nível ou cortes- α , são definidos como:

$$A_\alpha = \{ x \in \Omega / \mu_A(x) \geq \alpha \} \quad (3.3)$$

Os casos extremos destes conjuntos são o suporte de A , denotado como $Su(A)$, que agrupa elementos de Ω que são de alguma forma compatíveis com o conceito expresso por

A , e o núcleo de A , denotado por $Nu(A)$, que agrupa elementos de A que são completamente compatíveis com o conceito expresso por A .

$$Su(A) = \{ x \in \Omega / \mu_A(x) > 0 \} = \lim_{\alpha \rightarrow 0} A_\alpha \quad (3.4)$$

$$Nu(A) = \{ x \in \Omega / \mu_A(x) = 1 \} = A_1 \quad (3.5)$$

A altura de A ($Al(A)$) representa o maior grau de compatibilidade dos elementos de Ω em relação ao conceito expresso por A :

$$Al(A) = \sup_{x \in \Omega} \mu_A(x) \quad (3.6)$$

Um conjunto difuso A é dito normalizado se e somente se $Al(A) = 1$. A Figura 3.4 ilustra a cardinalidade, a altura, o suporte, o núcleo, e o corte de nível 0,5 de um conjunto difuso A [BNW98 e R98a].




Figura 3.4 - Cardinalidade, altura, suporte, núcleo e o corte de nível 0.5 do conjunto difuso A

Um conjunto difuso A é dito ser convexo em $\Omega \subseteq \mathfrak{R}$ se e somente se, seus cortes- α são convexos, é dizer, se:

$$\forall x, y \in \Omega, \forall \lambda \in [0, 1], \mu_A(\lambda x + (1-\lambda)y) \geq \min(\mu_A(x), \mu_A(y)) \quad (3.7)$$

Seja A um conjunto difuso convexo, com $Su(A) = [s_{\text{inf}}, s_{\text{sup}}]$ e $Nu(A) = [n_{\text{inf}}, n_{\text{sup}}]$. Um intervalo difuso é um conjunto difuso normalizado e convexo em \mathfrak{R} tal que a função que descreve $\mu_A(x)$ entre s_{inf} e n_{inf} e aquela entre n_{sup} e s_{sup} são estritamente monotônicas (respectivamente, crescente e decrescente). O conjunto difuso da Figura 3.4 é um intervalo difuso.

3.2.1.3 Números difusos

Um número difuso é um intervalo nebuloso unimodal, ou seja, é um subconjunto difuso de números reais. Alguns exemplos de números difusos são os conjuntos difusos "pequeno", "aproximadamente 8", "muito próximo a 5", "mais ou menos grande", etc.

3.2.2 Operações básicas da teoria de conjuntos para conjuntos difusos

Similarmente às operações nos conjuntos "*crisp*", existe a necessidade de proceder às operações de interseção, união e negação, entre outras, nos conjuntos difusos. Segundo Zimmermann [Z85], o componente crucial de um conjunto difuso é sua função de pertinência. Assim, as operações sobre conjuntos difusos são definidas via funções de pertinência.

Primeiramente serão apresentados os conceitos sugeridos por [Z65], os quais constituem uma estrutura consistente para a teoria de conjuntos difusos. Eles não são, entretanto, o único caminho possível para uma consistente extensão ou agregação da teoria de conjuntos. Assim, Lotfi Zadeh e outros autores têm sugerido definições alternativas ou adicionais para operações da teoria de conjuntos difusos.

3.2.2.1 Interseção de conjuntos difusos

Se A é um conjunto difuso que apresenta uma função de pertinência $\mu_A(x)$ e B é um conjunto difuso que apresenta uma função de pertinência $\mu_B(x)$, então a operação de interseção de A com B define o conjunto difuso $A \cap B$ obtido através da função de pertinência $\mu_{A \cap B}(x)$, dada por:

$$\mu_{A \cap B}(x) = \min [\mu_A(x), \mu_B(x)] \quad (3.8)$$

ou

$$\mu_{A \cap B}(x) \equiv \mu_A(x) \wedge \mu_B(x), \quad (3.9)$$

isto é, um elemento pertence ao conjunto interseção difuso se pertencer a ambos os conjuntos difusos, com algum grau de pertinência não nulo.

Sejam A , B e C conjuntos difusos quaisquer definidos sobre um universo Ω através de suas funções de pertinência $\mu_A(x)$, $\mu_B(x)$ e $\mu_C(x)$, respectivamente. As seguintes propriedades da operação de interseção têm sua validade verificada:

1. $A \cap A = A$ (Propriedade da idempotência)
2. $A \cap \Omega = A$ (Elemento neutro)
3. $A \cap B = B \cap A$ (Propriedade comutativa)
4. $(A \cap B) \cap C = A \cap (B \cap C)$ (Propriedade associativa)
5. $A \cap \emptyset = \emptyset$ (Propriedade de absorção)

3.2.2.2 União de conjuntos difusos

Se A é um conjunto difuso que apresenta uma função de pertinência $\mu_A(x)$ e B é um conjunto difuso que apresenta uma função de pertinência $\mu_B(x)$, então a operação união de A com B define o conjunto difuso $A \cup B$ obtido através da função de pertinência $\mu_{A \cup B}(x)$, dada por:

$$\mu_{A \cup B}(x) = \max [\mu_A(x), \mu_B(x)] \quad (3.10)$$

ou

$$\mu_{A \cup B}(x) \equiv \mu_A(x) \vee \mu_B(x), \quad (3.11)$$

isto é, um elemento pertence ao conjunto união difuso se pertencer a pelo menos um dos conjuntos difusos, com grau de pertinência não nulo.

Sejam A , B e C conjuntos difusos quaisquer definidos sobre um universo Ω através de suas funções de pertinência $\mu_A(x)$, $\mu_B(x)$ e $\mu_C(x)$, respectivamente. As seguintes propriedades da operação de reunião têm sua validade verificada:

1. $A \cup A = A$ (Propriedade da idempotência)
2. $A \cup \emptyset = A$ (Elemento neutro)
3. $A \cup B = B \cup A$ (Propriedade comutativa)
4. $(A \cup B) \cup C = A \cup (B \cup C)$ (Propriedade associativa)
5. $A \cup \Omega = \Omega$ (Propriedade de absorção)

3.2.2.3 Propriedades da união e da interseção de conjuntos difusos

Sejam A , B e C conjuntos difusos quaisquer definidos sobre um universo Ω através de suas funções de pertinência $\mu_A(x)$, $\mu_B(x)$ e $\mu_C(x)$, respectivamente. As seguintes propriedades têm sua validade verificada:

1. $A \cup (A \cap B) = A$ (Propriedade da absorção)
2. $A \cap (A \cup B) = A$ (Propriedade da absorção)
3. $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$ (Propriedade distributiva da reunião em relação à interseção)
4. $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$ (Propriedade distributiva da reunião em relação à interseção)

3.2.2.4 Subconjuntos difusos

Diz-se que o conjunto difuso A é um subconjunto do conjunto difuso B , e representado por $A \subset B$, se e somente se $\mu_A(x) \leq \mu_B(x)$, $\forall x \in \Omega$.

Se $A \subseteq B$ e $A \neq B$, então A é denominado um subconjunto próprio de B , isto quer dizer, $A \subset B$.

3.2.2.5 Conjuntos difusos disjuntos

Quando dois conjuntos difusos A e B não têm elementos em comum, A e B são denominados conjuntos disjuntos. Em termos de notação temos: $A \cap B = \emptyset$.

3.2.2.6 Igualdade entre conjuntos difusos

Dois conjuntos difusos A e B , definido através de suas funções de caracterização $\mu_A(x)$ e $\mu_B(x)$, respectivamente, são denominados iguais se e somente se:

$$\mu_A(x) = \mu_B(x), \quad \forall x \in \Omega. \quad (3.12)$$

3.2.2.7 Complemento de conjuntos difusos

Se A é um conjunto difuso que apresenta função de pertinência $\mu_A(x)$, a operação de complementação do conjunto A define o conjunto difuso \bar{A} , obtido pela função de pertinência $\mu_{\bar{A}}(x)$ dada por:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (3.13)$$

3.2.2.8 Operações algébricas de conjuntos difusos

Algumas operações algébricas de conjuntos difusos são dadas a seguir.

Soma algébrica de dois conjuntos difusos: A soma algébrica de dois conjuntos difusos A e B , denotado por $A+B$, é definido como:

$$\mu_{A+B}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x) \cdot \mu_B(x) \quad (3.14)$$

Produto algébrico de dois conjuntos difusos: O produto algébrico de dois conjuntos difusos, denotado por $A \cdot B$, é definido por:

$$\mu_{A \cdot B}(x) = \mu_A(x) \cdot \mu_B(x) \quad (3.15)$$

Soma limitada de dois conjuntos difusos: A soma limitada de dois conjuntos difusos, denotado por $A \oplus B$, é definido por:

$$\mu_{A \oplus B}(x) \equiv \min \{ 1, \mu_A(x) + \mu_B(x) \} \quad (3.16)$$

A soma $\mu_A(x) + \mu_B(x)$ pode exceder a unidade. Neste caso escolhe-se 1 como o valor da soma limitada.

Diferença limitada de dois conjuntos difusos: A diferença limitada de dois conjuntos difusos, denotado por $A \ominus B$, é definido por:

$$\mu_{A \ominus B}(x) \equiv \max \{ 0, \mu_A(x) + \mu_B(x) - 1 \} \quad (3.17)$$

Desde que $\mu_A(x) + \mu_B(x) - 1$, pode ser um valor negativo, escolheremos zero como o valor da função de pertinência, neste caso.

3.2.3 Operações de agregação da teoria de conjuntos difusos

Além dos operadores utilizados anteriormente (*max* e *min*), outros operadores têm sido também sugeridos. Estas sugestões variam com respeito à generalidade ou adaptabilidade dos operadores, bem como ao grau para o qual eles são justificados. As variações de justificação vão desde argumentação intuitiva para justificações empíricas e axiomáticas. As variações de adaptabilidade vão desde conceitos definidos via “famílias” parametrizadas de operadores para classes gerais de operadores que satisfazem certas propriedades.

Nesta seção discutiremos as duas classes básicas de operadores de agregação: a interseção que é implementada por uma família de operadores denominados de *t-normas*, e a união que é implementada por uma família de operadores denominados de *t-conormas* ou *s-normas* [DP95]. Cada classe contém operadores parametrizados como também não-parametrizados.

3.2.3.1 Interseção difusa: *t-normas*

Para representar a interseção de conjuntos difusos, [Z65] sugere o operador *min*, o produto algébrico $A \cdot B$ e a interseção drástica, modelado pela diferença limitada que foi definida anteriormente. Estes três operadores fazem parte do chamado *triangular norms* ou *t-normas*.

Define-se *t-normas* como um valor simples, de funções bi-avaliadas da forma

$$t: [0,1] \times [0,1] \rightarrow [0,1] \quad (3.18)$$

de modo que

$$\mu_{A \cap B}(x) = t[\mu_A(x), \mu_B(x)] \quad (3.19)$$

onde a função $t(\cdot)$ satisfaz as seguintes condições:

1. $t(0,0)=0; t(\mu_A(x),1) = t(1, \mu_A(x)) = \mu_A(x), \forall x \in \Omega$
2. $t(\mu_A(x), \mu_B(x)) \leq t(\mu_C(x), \mu_D(x))$
se $\mu_A(x) \leq \mu_C(x)$ e $\mu_B(x) \leq \mu_D(x)$ (Monotonia)
3. $t(\mu_A(x), \mu_B(x)) = t(\mu_B(x), \mu_A(x))$ (Comutativo)
4. $t(\mu_A(x), t(\mu_B(x), \mu_C(x))) = t(t(\mu_A(x), \mu_B(x)), \mu_C(x))$ (Associativa)

A função t define uma classe geral de operadores de interseção para conjuntos difusos. Os operadores que pertencem a esta classe de t -normas são, em particular, associativos, e por conseguinte é possível computar os valores de pertinência para a interseção de dois ou mais conjuntos difusos aplicando de modo repetitivo um operador t -norma.

3.2.3.2 União difusa: s -normas ou t -conormas

Para representar a união de conjuntos difusos, [Z65] sugere o operador max , a soma algébrica e a união drástica, modelada pela soma limitada. Estes três operadores fazem parte do chamado *triangular conormas* ou t -conormas (muitas vezes chamado de s -normas)

O operador max , a soma algébrica e a soma limitada são mapeadas da forma:

$$s: [0,1] \times [0,1] \rightarrow [0,1] \quad (3.20)$$

de modo que

$$\mu_{A \cup B}(x) = s[\mu_A(x), \mu_B(x)] \quad (3.21)$$

onde a função $s(\cdot)$ satisfaz as seguintes condições:

1. $s(1,1)=1; s(\mu_A(x),0) = s(0, \mu_A(x)) = \mu_A(x), \forall x \in \Omega$
2. $s(\mu_A(x), \mu_B(x)) \leq s(\mu_C(x), \mu_D(x))$
se $\mu_A(x) \leq \mu_C(x)$ e $\mu_B(x) \leq \mu_D(x)$ (Monotonia)
3. $s(\mu_A(x), \mu_B(x)) = s(\mu_B(x), \mu_A(x))$ (Comutativo)

$$4. \quad s(\mu_A(x), s(\mu_B(x), \mu_C(x))) = s(s(\mu_A(x), \mu_B(x)), \mu_C(x)) \quad (\text{Associativa})$$

Triangular normas e conormas são próximos num sentido de dualidade lógica.

3.2.3.3 Famílias paramétricas de *t-normas* e *s-normas*

Em muitas situações práticas, pode ser desejável trabalhar com outros operadores além dos anteriores, com o objetivo de adaptá-los ao contexto da aplicação. Segundo [GKY95] e [H98] uma grande quantidade de trabalhos têm sido feitos por muitos autores que criaram famílias paramétricas de *t-normas* e *s-normas*, freqüentemente mantendo a propriedade associativa. A continuação daremos a conhecer alguns dos operadores paramétricos, os quais são de interesse para o trabalho de pesquisa.

a) Família Hamacher

Hamacher define uma família *triangular* de operadores em termos do parâmetro γ .

Interseção Hamacher: A interseção de dois conjuntos difusos A e B , é definido em termos do parâmetro γ como:

$$t_H(a, b, \gamma) = \mu_{A \cap B}(x) = \frac{ab}{\gamma + (1 - \gamma)(a + b - ab)}, \quad \gamma \geq 0 \quad (3.22)$$

onde $a = \mu_A(x)$ e $b = \mu_B(x)$. Os axiomas básicos de Hamacher para derivar um modelo matemático em relação ao operador Λ (também definido como *.AND.*), são os seguintes:

1. O operador Λ é associativo, isto é:

$$A \Lambda (B \Lambda C) = (A \Lambda B) \Lambda C$$

2. O operador Λ é contínuo.
3. A diferença essencial entre o operador Hamacher e as propriedades de interseção descritas anteriormente, é que o operador Λ é injetivo em cada argumento, isto é,

$$(A \Lambda B) = (A \Lambda C) \Rightarrow B = C$$

$$(A \wedge B) = (C \wedge B) \Rightarrow A = C$$

$$4. \mu_A(x) = 1 \Rightarrow \mu_{A \wedge A}(x) = 1.$$

Para $\gamma=1$, este reduz-se ao produto algébrico.

União Hamacher: A união de dois conjuntos difusos A e B , é definido em termos do parâmetro γ como:

$$s_H(a, b, \gamma) = \mu_{A \cup B}(x) = \frac{a + b + (\gamma - 1) ab}{1 + \gamma ab}, \quad \gamma \geq 0 \quad (3.23)$$

onde $\gamma \geq -1$ e $\gamma = \gamma - 1$. Para $\gamma = 0$, este operador de união se reduz à soma algébrica.

b) Família Yager

Yager define outra família de operadores em termos do parâmetro p .

Interseção Yager: A interseção de dois conjuntos difusos A e B , é definido em termos do parâmetro p como:

$$t_Y(a, b, p) = \mu_{A \cap B}(x) = 1 - \min \{ 1, [(1-a)^p + (1-b)^p]^{1/p} \} \quad p \geq 1 \quad (3.24)$$

Este operador de interseção converge ao operador \min quando $p \rightarrow \infty$. Para $p = 1$, este operador de interseção se reduz à interseção drástica ou diferença limitada dado por $\mu = \max\{0, (a+b-1)\}$. A interseção Yager tem certas propriedades interessantes, como:

$$t_Y(a, 0, p) = 0 \qquad t_Y(a, 1, p) = a$$

União Yager: Este é um típico s -norma parametrizado definido pela função:

$$s_Y(a, b, p) = \mu_{A \cup B}(x) = \min \{ 1, [a^p + b^p]^{1/p} \} \quad p \geq 1 \quad (3.25)$$

Este operador união de Yager converge para o operador max quando $p \rightarrow \infty$. Para $p=1$, o operador se reduz à união drástica, isto é, a soma limitada $\mu = \min\{1, a+b\}$. Propriedades adicionais da união Yager incluem:

$$s_Y(a, 1, p) = 1 \qquad s_Y(a, 0, p) = a$$

Os operadores Yager satisfazem as leis DeMorgan [KF98] e são comutativas, associativas para todo p , e monotonicamente não decrescente em $\mu(x)$. Estes operadores não são distributivos.

c) Família Dubois & Prade

Dubois & Prade em [DP80] apresentaram uma família parametrizada, comutativa e associativa, de operadores em termos de um parâmetro α .

Interseção Dubois & Prade: A interseção de dois conjuntos difusos A e B , é definido como:

$$t_{DP}(a, b, \alpha) = \mu_{A \cap B}(x) = \frac{ab}{\max(a, b, \alpha)} \quad (3.26)$$

uma representação equivalente é dada por:

$$t_{DP}(a, b, \alpha) = \begin{cases} \mu_{A \cap B}(x) = \frac{ab}{\alpha} & 0 \leq a, b \leq \alpha \\ \min\{a, b\} & \alpha \leq a, b \leq 1 \end{cases} \quad (3.27)$$

Desta equação, pode-se observar que o parâmetro α atua como um *threshold*. Este operador de interseção decresce com respeito a α e situa-se entre $\min\{a, b\}$, resultante da operação para $\alpha = 1$, e o produto algébrico ab , para $\alpha = 1$.

União Dubois & Prade: A união de dois conjuntos difusos A e B , é definido, segundo Dubois & Prade, como:

$$s_{DP}(a, b, \alpha) = \mu_{A \cup B}(x) = \frac{a + b - ab - \min\{a, b, (1-\alpha)\}}{\max\{(1-a), (1-b), \alpha\}} \quad (3.28)$$

d) Família Dombi

Dombi apresenta uma família parametrizada de operadores em termos de um parâmetro λ .

Interseção Dombi: A interseção de dois conjuntos difusos A e B , é definido como:

$$t_D(a, b, \lambda) = \mu_{A \cap B}(x) = \frac{1}{1 + [(1/a - 1)^\lambda + (1/b - 1)^\lambda]^{1/\lambda}} \quad (3.29)$$

União Dombi: A união de dois conjuntos difusos A e B , é definido como:

$$s_D(a, b, \lambda) = \mu_{A \cup B}(x) = \frac{1}{1 + [(1/a - 1)^{-\lambda} + (1/b - 1)^{-\lambda}]^{-1/\lambda}} \quad (3.30)$$

para este sistema $\lambda \in (0, \infty)$.

3.2.3.4 Critérios para selecionar operadores de agregação apropriados

Segundo [H98], uma grande variedade de operadores, para agregação de conjuntos difusos, pode confundir e criar dificuldade para decidir qual será utilizado em um modelo específico ou em uma situação específica. A seguir serão apresentados alguns dos critérios mais importantes para ajudar na seleção do operador apropriado.

Ajuste empírico: Se a teoria de conjuntos difusos é utilizada como uma linguagem de modelação para situações ou sistemas reais, não somente será importante que os operadores satisfaçam certos axiomas ou certas propriedades formais, como por exemplo a comutatividade e associatividade, os quais são certamente importantes desde um ponto de vista matemático, mas também devem ser modelos apropriados ao comportamento de um sistema real; e isto pode ser comprovado somente pela verificação empírica.

Adaptabilidade: Se queremos utilizar um número pequeno de operadores para modelar várias situações, então estes operadores devem ser adaptáveis ao contexto específico. Isto pode, por exemplo, ser alcançado pela parametrização. Deste modo os operadores *min* e *max* não podem ser adaptados de nenhuma maneira. Isto é aceitável em situações na qual eles não são adequados sob diferentes circunstâncias. Assim, operadores da família Yager podem ser adaptados para certos contextos pelo ajuste apropriado do parâmetro *p*.

Eficiência numérica: Se comparamos o operador *min* com, por exemplo, o operador de interseção Yager, torna-se quase óbvio que o segundo requer maior esforço computacional que o primeiro. Na prática, isto pode ser muito importante, em particular quando temos que resolver problemas de grande porte.

Compensação: A lógica " \wedge " não permite a compensação de nenhuma maneira, isto é, um elemento da interseção de dois conjuntos não pode compensar um baixo grau de pertinência em um dos conjuntos intersectados com um elevado grau de pertinência no outro. Em compensação, no contexto de operadores agregados para conjuntos difusos, pretende-se o seguinte: Dado que o grau de pertinência para um conjunto difuso agregado é:

$$\mu_{Agr}(x_k) = f(\mu_A(x_k), \mu_B(x_k)) = k \quad (3.31)$$

f é compensatório se $\mu_{Agr}(x_k) = k$ é alcançado para um diferente $\mu_A(x_k)$ pela mudança em $\mu_B(x_k)$. Assim o operador *min* não é compensatório, enquanto o operador produto, o operador Hamacher, e outros o são.

Escala de compensação: Se for possível utilizar uma combinação convexa do operador *min* e *max*, uma compensação poderia obviamente ocorrer no intervalo entre *min* e *max*. O operador produto permite a compensação no intervalo aberto (0,1). Em geral, a uma escala ampla de compensação, melhor o operador compensatório.

Comportamento da agregação: Se consideramos conjuntos difusos, o grau de pertinência no conjunto agregado depende freqüentemente do número de conjuntos combinados. Se um dos conjuntos difusos combina-se, por exemplo, com o operador produto, cada conjunto difuso adicional normalmente decresce o grau de pertinência agregado resultante. Isto pode ser uma característica desejável, mas também pode ser inadequado.

3.2.4 Relações difusas

As relações difusas, assim como as relações clássicas, mapeiam elementos de universos distintos, por exemplo Ω_1 e Ω_2 , entretanto a "força" da relação é medida através de uma função de pertinência, que expressa os vários graus de pertinência no intervalo [0,1].

Como exemplo, sejam os grupos de países $C_1 = \{\text{Brasil, México, Cabo Verde}\}$ e $C_2 = \{\text{Peru, EEUU, Japão, Austrália}\}$. Uma relação que expresse o quanto os países do grupo C_1 são próximos dos países do grupo C_2 poderia ser representada por uma matriz de relação (Tabela 3.1).

Tabela 3.1 - Matriz de relação $C_1 \times C_2$

$$R_{C_1 \times C_2} = \begin{matrix} & \begin{matrix} \text{Peru} & \text{EEUU} & \text{Japão} & \text{Austrália} \end{matrix} \\ \begin{matrix} \text{Brasil} \\ \text{México} \\ \text{Cabo Verde} \end{matrix} & \left[\begin{matrix} 0.95 & 0.55 & 0.10 & 0.10 \\ 0.60 & 0.95 & 0.50 & 0.55 \\ 0.50 & 0.60 & 0.05 & 0.05 \end{matrix} \right] \end{matrix}$$

Ao compor a matriz de relação devemos apenas atribuir valores no intervalo [0,1] à função de pertinência da relação, de tal modo que quanto menor for a distância entre os países, mais próximo de 1 deverá ser o valor dessa função. Esta relação pode também ser também representada por um Diagrama *Sagital*, como na seguinte figura:




Figura 3.5 - Diagrama Sagital

3.2.5 Aplicações da lógica difusa em sistemas de potência

A tecnologia baseada na lógica difusa tem alcançado um sucesso impressionante em diversas aplicações na engenharia, desde produtos consumidos no mercado para sofisticados problemas de decisão e controle [C96a, C96b]. Aplicações relacionadas à área de sistemas de potência são extensivos com mais de 100 publicações arquivados em uma pesquisa de 1995 [MMT95]. Muitas destas aplicações têm se baseado na prática e diferentes métodos difusos têm se tornado uma importante aproximação a ser considerado pelos especialistas. Alguns dos métodos ou modelos mais utilizados, fornecidos pela modelação na abordagem de conjuntos difusos, são:

- a) Métodos de representação para enunciados em linguagem natural;
- b) Modelos de incerteza, onde estatísticas são imprecisas ou não disponíveis;
- c) Modelos de informação de enunciados subjetivos (por exemplo, as medidas difusas de opinião e possibilidade);
- d) Medidas da qualidade de enunciados subjetivos (por exemplo, as medidas de informação difusa de imprecisão e confusão);
- e) Integração entre métodos numéricos e lógicos;
- f) Modelos para restrições graduais;
- g) Modelos para resolução de múltiplos objetivos que se opõem.

A incerteza aparece em muitos aspectos dentro de problemas de sistemas de potência. Historicamente, a incerteza tem sido modelada fortuitamente, como um modelo estocástico para variações de carga aleatória, ruídos em medidas para a estimação de estado, flutuações nos parâmetros do modelo, e assim por diante. Na prática, a incerteza aparece certamente no conhecimento da performance do sistema e também nos objetivos de operação. Claramente, os objetivos em muitos problemas de decisão são subjetivos. Por exemplo, a importância relativa do custo versus confiabilidade não é precisa.

A base dos modelos do sistema também mostra certa incerteza através de aproximações que aparecem de, modelos linearizados e outros modelos de aproximação, variações dos parâmetros, custos e vendas, e assim por diante.

Heurísticas, intuição, experiência, e descrições lingüísticas são obviamente importantes para engenheiros de sistemas de potência. Virtualmente na prática qualquer problema de engenharia requer alguma "imprecisão" na formulação do problema e na análise subsequente. Por exemplo, projetores de sistemas de distribuição contam com programas de simulação, que prevêem a carga regional, para fornecer informação em relação a vários cenários de planejamento [CT96].

Avaliações subjetivas das incertezas, acima citadas, são necessárias para tomar uma decisão. Estas incertezas podem ser, de um modo geral, separadas em dois grupos:

1. Medidas e modelos do sistema:
 - Contingências;
 - Modo de falha do equipamento,
 - Medições de ruídos,
 - Tempos de ocorrência de eventos,
 - Previsão de demandas, etc.

2. Restrições e objetivos do processo de tomada de decisão:
 - Risco aceitável de segurança,
 - Avaliação da satisfação do cliente,
 - Objetivos econômicos,

- Objetivos ambientais,
- Limites de carga de equipamentos,
- Limites normais de operação,
- Objetivos na qualidade de energia,
- Objetivos de segurança,
- Limites de estabilidade, etc.

Assim podemos concluir que os conjuntos difusos são aplicados em muitas áreas de sistema de potência. A Tabela 3.2 é uma lista das áreas de aplicação mais comuns de conjuntos difusos em sistemas de potência.

Tabela 3.2 - Áreas de aplicação de conjuntos difusos em sistemas de potência

Áreas	Problemas	Referências
Áreas relacionadas ao Planejamento	Planejamento Programação Avaliação da segurança	[DZ89, MM89] [MS92, TI88] [HSB93, M91a]
Áreas de Operação	Análises de contingências Controle da potência/tensão Reativa Previsão de carga Gerenciamento de carga Estimação de estado	[SK92, M91, MS92a] [T92, TL91, AS93] [TSM91, E79]

Quanto à topologia, a rede pode ser realimentada ou não-realimentada. A rede é realimentada quando se pode encontrar um circuito no grafo orientado que a representa, e não-realimentada, caso contrário. A Figura 3.9 ilustra dois destes casos.

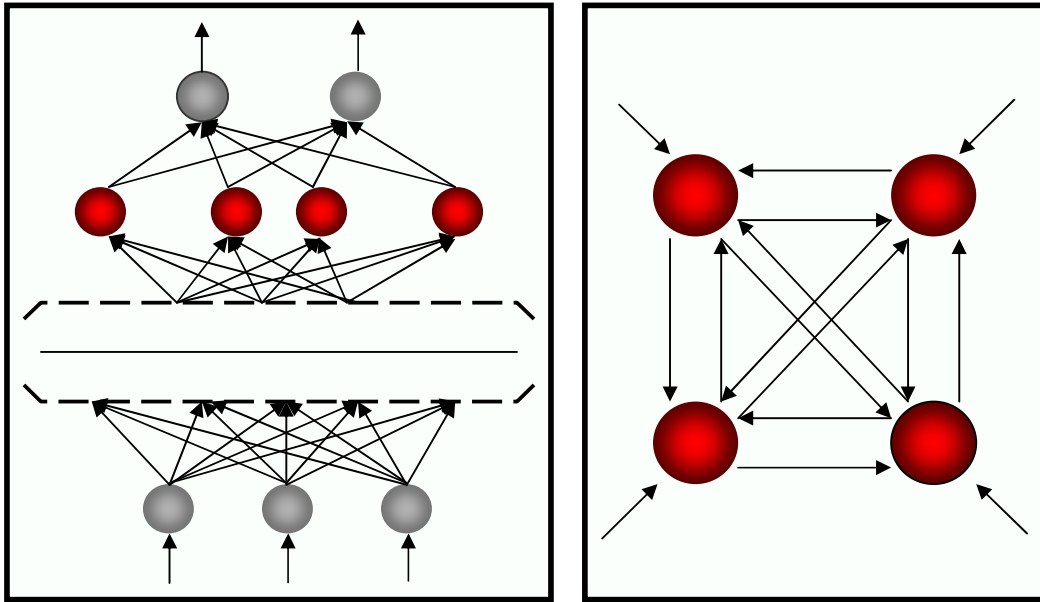


Figura 3.9 - (a) Rede não-realimentada (b) Rede realimentada

Quanto as características dos nós ou neurônios, podemos dizer que elas estão relacionadas principalmente as respostas geradas por eles, que são calculadas através de uma função de ativação. Existem vários tipos de funções de ativação, as mais comuns são: Função degrau, Combinador linear e Sigmóide (Figura 3.10).

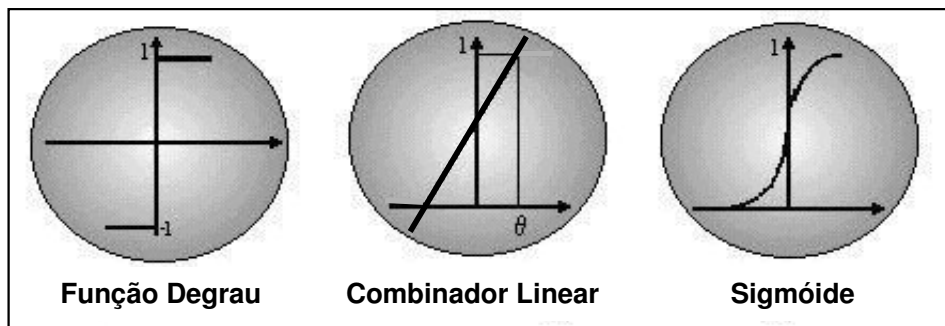


Figura 3.10 - Funções de ativação

A seguir, serão analisados os processos de aprendizado.

3.3.4 Processos de aprendizado

A propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicados a seus pesos, denominado treinamento. O aprendizado ocorre quando a rede neural apresenta um desempenho satisfatório na execução da tarefa para a qual foi projetada.

Denomina-se algoritmo de aprendizado um conjunto de procedimentos bem definidos para a aquisição de conhecimento. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais. Estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto existem os seguintes paradigmas de aprendizado [CAT98]:

- **Aprendizado Supervisionado**, quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada;
- **Aprendizado Não Supervisionado** (auto-organização), quando não existe uma agente externo indicando a resposta desejada para os padrões de entrada;
- **Aprendizado por Reforço**, quando a única informação de realimentação fornecida à rede é se uma determinada saída está correta ou não, isto é, não é fornecida à rede a resposta correta para o padrão de entrada.

Denomina-se ciclo uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos num ciclo pode ser executado de dois modos:

- 1) **Modo Padrão**: A correção dos pesos acontece a cada apresentação à rede de um exemplar do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplar apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções.

- 2) **Modo *Batch***: Apenas uma correção é feita por ciclo. Todos os exemplares do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro faz-se as correções dos pesos.

3.3.4.1 Aprendizado supervisionado

Este tipo de aprendizado é mais comumente empregado no treinamento das RNAs, sendo chamado aprendizado supervisionado porque a entrada e a saída desejada para a rede são fornecidas por um agente externo. O objetivo é ajustar os parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos.

A Figura 3.11 ilustra o mecanismo de aprendizado supervisionado.

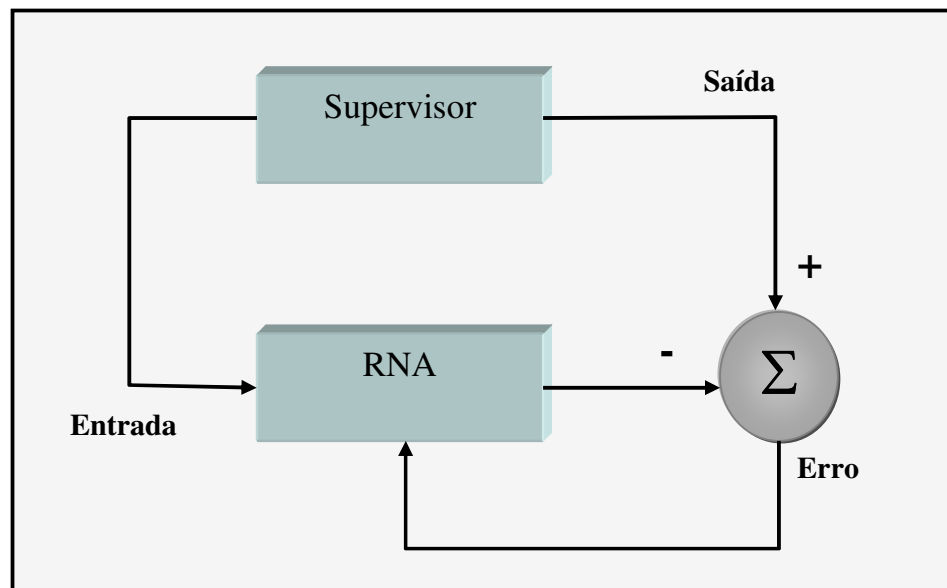


Figura 3.11 - Aprendizado supervisionado

O supervisor indica explicitamente um comportamento bom ou ruim para a rede, visando direcionar o processo de treinamento. A cada padrão de entrada submetido à rede, compara-se a resposta desejada com a resposta calculada, ajustando-se os pesos das conexões para minimizar o erro de saída. A minimização da diferença é incremental, já que

pequenos ajustes são feitos nos pesos à cada etapa do treinamento, de tal forma que estes caminhem para uma solução. A soma dos erros quadráticos de todas as saídas é normalmente utilizada com medida de desempenho da rede e também como função de custo a ser minimizada pelo algoritmo de treinamento.

Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta [WH60] (Figura 3.12) e sua generalização para redes de múltiplas camadas, o algoritmo *backpropagation* [RHW86].




Figura 3.12 - Regra delta

O objetivo deste método de aprendizado é partir de um ponto arbitrário da superfície da função de erro, movendo-se até um mínimo local aceitável. Deste modo, temos o seguinte esquema de treinamento:

Iniciar todas as conexões com pesos aleatórios;

Repita até que o erro E seja satisfatoriamente pequeno ($E \leq e$).

Para cada par de treinamento (X,d) , **faça**:

Calcular a resposta obtida O ;

Se o erro não for satisfatoriamente pequeno $E > e$, **então**:

Atualizar pesos: $W_{novo} = W_{anterior} + \eta EX$

Quadro 3.1 - Esquema de treinamento

Onde:

- O par de treinamento (X, d) corresponde ao padrão de entrada e a sua respectiva resposta desejada;
- O erro E é definido como: Resposta Desejada - Resposta Obtida ($d-O$);
- A taxa de aprendizado η é uma constante positiva, que está relacionada à velocidade do aprendizado.

Com relação à superfície de erro obtida através do algoritmo, dependendo do tipo de unidade de processamento utilizada para construir a rede, podem-se identificar duas situações diferentes:

1. A rede ser formada inteiramente por unidades de processamento lineares, nesse caso a superfície do erro é dada exatamente pela função quadrática dos pesos da rede, o que quer dizer que esta possui um único mínimo.
2. A rede ser formada por unidades de processamento não lineares. neste caso, a superfície do erro poderá ter, além do mínimo global, um ou mais mínimos locais.

Em ambas as situações, o objetivo deste método de aprendizado é partir de um ponto arbitrário da superfície, movendo-se até um mínimo local aceitável. Na primeira situação só existe um único mínimo, já que trata-se de uma superfície de erro quadrática

(ver Figura 3.12), facilmente atingido à partir de qualquer ponto inicial da superfície. Na segunda situação, nem sempre um único mínimo é alcançado, já que saídas não-lineares geram superfícies de erro irregulares, podendo levar a rede a se estabilizar em um mínimo local não aceitável. Apesar disto, existem técnicas de treinamento que levam a rede a se aproximar de um mínimo local aceitável, como o algoritmo *backpropagation* [RHW86].

3.3.4.2 Aprendizado não-supervisionado

No aprendizado não-supervisionado, como o próprio nome sugere, não existe um supervisor para acompanhar o processo de aprendizado. Este método é ilustrado na Figura 3.13.

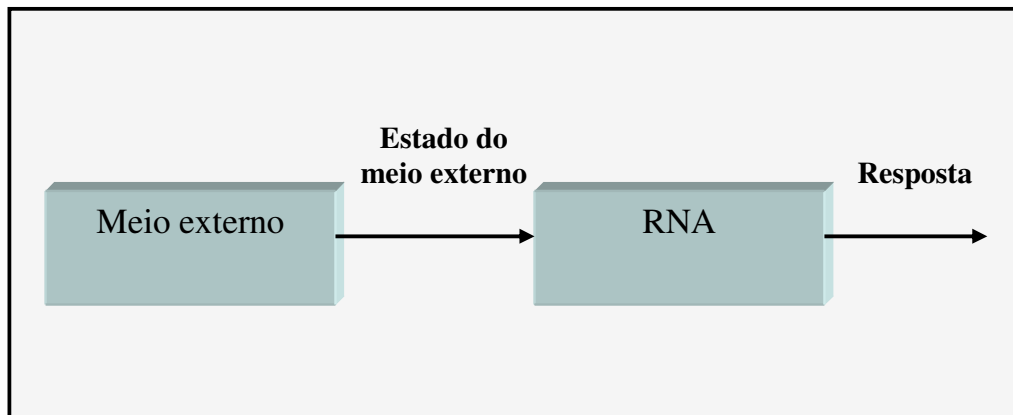


Figura 3.13 - Aprendizado não-supervisionado

Para estes algoritmos, somente os padrões de entrada estão disponíveis para a rede, ao contrário do aprendizado supervisionado, cujo conjunto de treinamento possui pares de entrada e saída.

A estrutura do sistema de aprendizado não-supervisionado pode se apresentar sob uma variedade de formas diferentes. Ela pode, por exemplo, consistir de uma camada de entrada, uma camada de saída, conexões *feed-forward* da entrada para a saída e conexões laterais entre os neurônios da camada de saída. Um outro exemplo é uma rede *feed-forward* com múltiplas camadas, onde a livre organização procede na base de camada por camada. Nestes dois exemplos, o processo de aprendizado consiste em modificar

repetidamente os pesos sinápticos de todas as conexões do sistema em resposta às entradas [H49, L88].

Redes auto-organizáveis também utilizam aprendizado não supervisionado. RNAs auto-organizáveis possuem um amplo leque de aplicações, principalmente em problema de reconhecimento de padrões e categorização de dados, onde as classes não são conhecidas à *priori*. Os modelos de redes auto-organizáveis mais conhecidos são os mapas auto-organizáveis de Kohonen [K89], baseados em aspectos neurofisiológicos e a família de redes ART de Grossberg e Carpenter, baseadas na Teoria de Ressonância Adaptativa [CG88].

3.3.4.3 Aprendizado por reforço

Este aprendizado pode ser visto como um caso particular do aprendizado supervisionado. A diferença é a medida de desempenho usada em cada um dos sistemas. No aprendizado supervisionado, a medida de desempenho é baseada no conjunto de respostas desejadas usando um critério de erro conhecido, enquanto no aprendizado por reforço o desempenho é baseado em qualquer medida que possa ser fornecida ao sistema. No aprendizado por reforço, a única informação de realimentação fornecida à rede é se uma determinada saída está correta ou não, isto é, não é fornecida à rede a resposta correta para o padrão de entrada. Este aprendizado é ilustrado na figura 3.14.

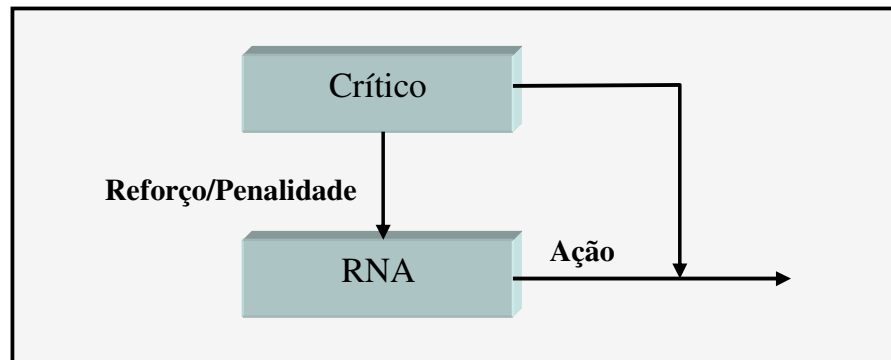


Figura 3.14 - Aprendizado por reforço

Aprendizado por reforço é uma forma de aprendizado *on-line* obtido por um mapeamento de entrada-saída através de um processo de triagem e erro desenvolvido para maximizar o índice de desempenho escalar chamado de *signal de reforço*.

O termo aprendizagem por reforço foi inicialmente citado por Minsky [M61] em seus estudos iniciais de IA. Em [BSA83, H94 e S88] citam-se algumas classes de aprendizado por reforço, dependendo da natureza do ambiente.

3.3.5 Redes perceptron multi-camadas (MLP)

Quando Redes Neurais Artificiais de uma só camada são utilizadas, os padrões de treinamento apresentados à entrada são mapeados diretamente em um conjunto de saída da rede, ou seja não é possível a formação de uma representação interna. Neste caso, a codificação proveniente do mundo exterior deve ser suficiente para implementar esse mapeamento.

Tal restrição implica que padrões de entrada similares resultem em padrões de saída similares, o que leva o sistema à incapacidade de aprender importantes mapeamentos. Como resultado, padrões de entrada com estruturas similares, fornecidos do mundo externo e que correspondem a saídas diferentes, podem não ser corretamente mapeados por redes sem representações internas, isto é, sem camadas intermediárias. Um exemplo clássico deste caso é a função ou-exclusivo (XOR).

Minsky e Papert [MP69] analisaram matematicamente o Perceptron e demonstraram que redes de uma camada não são capazes de solucionar problemas que não sejam linearmente separáveis. Como não acreditavam na possibilidade de se construir um método de treinamento para redes com mais de uma camada, eles concluíram que as redes neurais seriam sempre suscetíveis a essa limitação.

Contudo, o desenvolvimento do algoritmo de treinamento *backpropagation*, proposto por Paul Werbos [W74] e amplamente divulgado por Rumelhart, Hinton e Williams em 1986 [RHW86], precedido por propostas semelhantes ocorridas nos anos 70 e

80, mostrou que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de Redes Neurais Artificiais mais utilizado, as redes Perceptron Multi-Camadas (MLP), treinadas com o algoritmo *backpropagation*.

Nessas redes, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, suas saídas são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação interna, mais rica e complexa, do problema.

Se existirem as conexões certas entre as unidades de entrada e um conjunto suficientemente grande de unidades intermediárias, pode-se sempre encontrar a representação que irá produzir o mapeamento correto da entrada para a saída através das unidades intermediárias.

Redes MLP apresentam um poder computacional muito maior do que aquele apresentado pelas redes sem camadas intermediárias. Ao contrário destas redes, MLP's podem tratar com dados que não são linearmente separáveis. Teoricamente, redes com duas camadas intermediárias podem implementar qualquer função, seja ela linearmente separável ou não, como provou Cybenko [C89b]. A precisão obtida e a implementação da função objetivo dependem do número de nodos utilizados nas camadas intermediárias.

3.3.5.1 Algoritmo *Backpropagation*

Durante o treinamento com o algoritmo *backpropagation*, a rede opera em uma sequência de dois passos [H94]. Primeiro, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Se esta não estiver correta, o erro é calculado. O erro é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado.

As redes que utilizam *backpropagation* trabalham com uma variação da regra delta, apropriada para redes multi-camadas: a regra delta generalizada. A regra delta essencialmente implementa um gradiente descendente no quadrado da soma do erro para funções de ativação lineares. Redes sem camadas intermediárias, podem resolver problemas onde a superfície de erro tem a forma de um parabolóide com apenas um mínimo.

Entretanto, a superfície do erro pode não ser tão simples, como a ilustrada na Figura 3.15, e suas derivadas mais difíceis de serem calculadas. Nestes casos devem ser utilizadas redes com camadas intermediárias. Ainda assim, as redes ficam sujeitas aos problemas de procedimentos "*hill-climbing*", ou seja, ao problema de mínimos locais.

A regra delta generalizada funciona quando são utilizadas na rede unidades com uma função de ativação semi-linear, que é uma função diferenciável e não decrescente. Note que a função *threshold* não se enquadra nesse requisito. Uma função de ativação amplamente utilizada, nestes casos, é a função sigmoide.

A taxa de aprendizado é uma constante de proporcionalidade no intervalo $[0,1]$, pois este procedimento de aprendizado requer apenas que a mudança no peso seja proporcional à η .




Figura 3.15 - Exemplo de superfície de erro

Entretanto, o verdadeiro gradiente descendente requer que sejam tomados passos infinitesimais. Assim quanto maior for essa constante, maior será a mudança nos pesos, aumentando a velocidade do aprendizado, o que pode levar à uma oscilação do modelo na superfície de erro. O ideal seria utilizar a maior taxa de aprendizado possível que não levasse à uma oscilação, resultando em um aprendizado mais rápido.

O treinamento das redes MLP com *backpropagation* pode demandar muitos passos, resultando um tempo de treinamento consideravelmente longo. Se for encontrado um mínimo local, o erro para o conjunto de treinamento pára de diminuir e estaciona-se em um valor que pode ser maior que o aceitável.

Uma maneira de aumentar a taxa de aprendizado sem levar à oscilação é modificar a regra delta generalizada para incluir o termo *momentum*, uma constante que determina o efeito das mudanças passadas dos pesos na direção atual do movimento no espaço de pesos [H94]. Desta forma, o termo *momentum* leva em consideração o efeito de mudanças anteriores de pesos na direção do movimento atual no espaço de pesos. O termo *momentum* torna-se útil em espaços de erro que contenham longas gargantas, com curvas acentuadas ou vales com descidas suaves, como foi apresentado na Figura 3.15.

3.3.5.2 Treinamento da rede MLP

O treinamento supervisionado da rede MLP utilizando *backpropagation* consiste em dois passos (Figura 3.16). No primeiro, um padrão é apresentado às unidades da camada de entrada e, a partir desta camada as unidades calculam sua resposta que é produzida na camada de saída, o erro é calculado e no segundo passo, este é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados utilizando a regra delta generalizada.

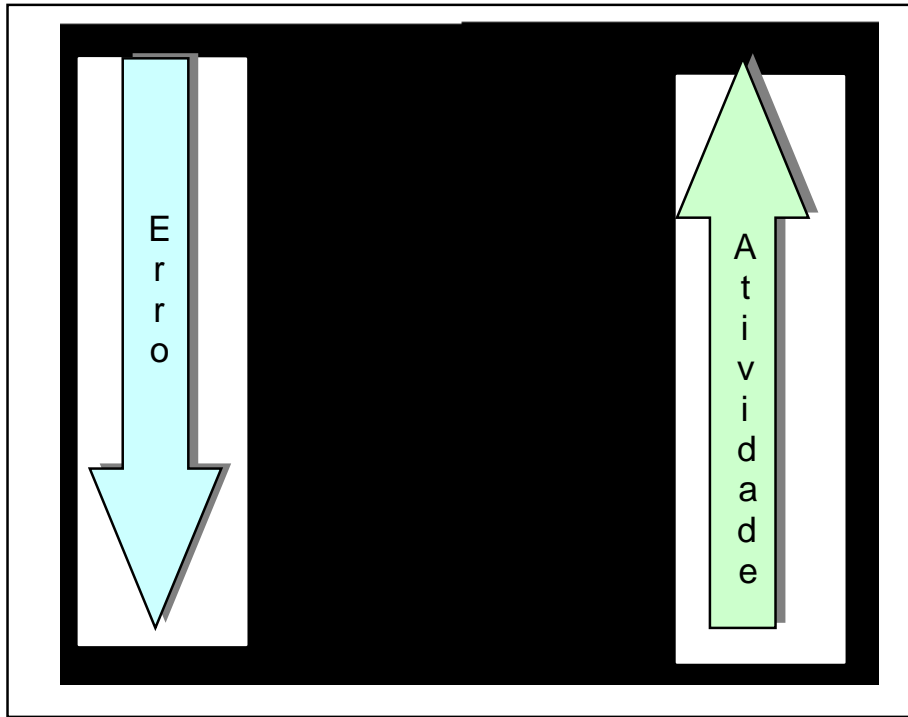


Figura 3.16 - Esquema de treinamento backpropagation

Com isso o erro vai sendo progressivamente diminuído, como pode ser observado na Figura 3.17.




Figura 3.17 - Superfície de erro e treinamento backpropagation

3.3.5.3 Utilização

Depois que a rede estiver treinada e o erro estiver em um nível satisfatório, ela poderá ser utilizada como uma ferramenta para classificação de dados. Para isto, a rede deverá ser utilizada apenas no modo progressivo (forward), como mostrado na Figura 3.16. Ou seja, novas entradas são apresentadas à rede e a saída são processadas nas camadas intermediárias e os resultados são apresentados na camada de saída, como no treinamento, mas sem a retropropagação do erro. A saída apresentada indica a resposta obtida, na interpretação da rede.

3.3.5.4 Limitações

As redes neurais que utilizam backpropagation assim como muitos outros tipos de redes neurais artificiais, podem ser vistas como "caixas pretas" na qual quase não se sabe porque a rede chega a um determinado resultado, uma vez que elas não apresentam justificativas para suas respostas. Neste sentido, pesquisas vêm sendo realizadas visando a extração do conhecimento de redes neurais artificiais, criação de procedimentos explicativos, onde se tenta justificar o comportamento da em determinadas situações [AG94, CS96, PG92].

Uma outra limitação refere-se ao tempo de treinamento de redes neurais utilizando backpropagation que tende a ser muito grande. Algumas vezes são necessários milhares de ciclos para se chegar à níveis de erros aceitáveis, principalmente se estiver sendo simulado em computadores seriais, pois a CPU deve calcular as operações para cada unidade e suas conexões separadamente, o que pode ser problemático em redes muito grandes, ou com grande quantidade de dados.

É muito difícil definir a arquitetura ideal da rede de forma que seja tão grande quanto o necessário para conseguir obter as representações necessárias no mesmo tempo pequena o suficiente para se ter um treinamento mais rápido. Não existem regras claras para se definir quantas unidades devem existir nas camadas intermediárias, quantas camadas, ou como devem ser as conexões entre essas unidades.

3.3.6 Etapas na construção das redes neurais

3.3.6.1 Coleta de dados e construção dos conjuntos de treinamento e teste

O primeiro passo do processo de desenvolvimento de redes neurais é a coleta de dados relativos ao problema. Esta tarefa requer uma cuidadosa análise sobre o problema para minimizar ambigüidades e erros nos dados. Deve-se preocupar de utilizar variáveis de entrada relevantes, capazes de representar o problema de uma forma adequada. Além disso, os dados coletados devem cobrir representativamente o domínio do problema. Normalmente, os dados coletados são separados em duas partes: dados de treinamento, que serão utilizados para o treinamento da rede e dados de teste, que serão utilizados para verificar sua performance sob condições de utilização. Pode ser necessário ainda pré-processar estes dados, através de operações de escalonamentos e conversões de formato para torná-los mais apropriados à sua utilização.

3.3.6.2 Escolha da arquitetura

O segundo passo é a definição da arquitetura da rede, que pode ser dividida em três etapas:

1. Seleção do paradigma neural apropriado à aplicação.
2. Determinação da topologia da rede a ser utilizada - o número de camadas, o número de unidades em cada camada, etc.
3. Determinação de parâmetros do algoritmo de treinamento e função de ativação. Este passo tem um grande impacto no processo de treinamento.

Embora métodos tenham sido propostos para a determinação automática da arquitetura da rede GMDH [F84], a definição da arquitetura mais adequada é ainda considerado um desafio, sendo uma etapa crítica para a construção do modelo.

3.3.6.3 Treinamento

O terceiro passo é o treinamento da rede. Nesta fase, segundo o algoritmo de treinamento escolhido, serão ajustados os pesos das conexões. É importante considerar, nesta fase, alguns aspectos tais como a escolha inicial dos pesos da rede, a frequência de atualização dos pesos e o tempo de treinamento.

Uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Normalmente, os valores iniciais dos pesos da rede são números aleatórios uniformemente distribuídos, em um intervalo definido. A escolha errada destes pesos pode levar a uma saturação prematura.

A frequência de ajuste dos pesos influencia o desempenho obtido durante o treinamento. Duas abordagens diferentes têm sido utilizadas para a frequência (periodicidade) para o ajuste de pesos pelo algoritmo de backpropagation

1. Por padrão (on-line)
2. Por ciclo (batch)

Existem vantagens e desvantagens em cada uma destas abordagens. Na abordagem por padrão, os pesos são atualizados após a apresentação de cada padrão de treinamento. Esta abordagem é estável se a taxa de aprendizado for pequena. Quando taxas elevadas são utilizadas, a rede geralmente se torna instável. A abordagem por ciclo é geralmente mais rápida. Principalmente se o conjunto de treinamento for grande e redundante. Uma outra vantagem desta técnica é que ela requer menos memória.

Na abordagem por ciclo, por sua vez, os pesos são atualizados após todos os padrões de treinamento terem sido apresentados. Esta técnica é geralmente mais estável, mas ela pode ser lenta se o conjunto de treinamento for grande e redundante. Esta abordagem apresenta uma estimativa mais precisa do vetor de saída, ao custo da necessidade de mais memória. A escolha da abordagem utilizada depende da aplicação e da distribuição estatística dos dados.

Quanto ao tempo de treinamento, vários fatores podem influenciar a duração, porém sempre será necessário utilizar algum critério de parada do algoritmo backpropagation. O critério de parada do algoritmo backpropagation é bem definido, e geralmente é utilizado um número máximo de ciclos. Mas, devem ser considerados a taxa de erro por ciclo, e a capacidade de generalização da rede. Pode ocorrer que em determinado instante do treinamento a generalização comece a degenerar, causando o problema de over-training ou seja a rede se especializa no conjunto de dados do treinamento e a capacidade de generalização.

O treinamento deve ser interrompido quando a rede apresentar uma capacidade de generalização e quando a taxa de erro for suficientemente baixa ou seja menor que um erro admissível. Assim, deve-se encontrar um ponto ótimo com erro mínimo e capacidade de generalização máxima.

3.3.6.4 Teste e validação do treinamento

O quarto passo é o teste da rede. Durante esta fase o teste é utilizado para determinar a performance da rede com dados que não foram utilizados. A performance da rede, medida nesta fase, é uma boa indicação de performance real.

Devem ser considerados ainda outros testes como análise do comportamento da rede utilizando entradas especiais e análise dos pesos atuais, pois se existirem valores muito pequenos, as conexões associadas podem ser consideradas insignificantes e assim serem eliminadas (pruning). De modo inverso, valores substantivamente maiores que os outros poderiam indicar que houve overtraining da rede.

3.3.6.5 Integração com o ambiente de aplicação

Finalmente, com a rede treinada e avaliada, ela pode ser integrada em um sistema do ambiente operacional da aplicação. Para maior eficiência na solução, este sistema deverá conter facilidades de utilização como interface com o ambiente e facilidades de

aquisição de dados através de planilhas eletrônicas, interfaces com unidades de processamento de sinais, ou arquivos padronizados. Uma boa documentação e o treinamento de usuários são necessários para o sucesso.

Além disso, o sistema deve periodicamente monitorar sua performance e fazer a manutenção da rede quando for necessário ou indicar aos projetistas a necessidade de retreinamento. Outras melhorias poderão ainda ser sugeridas pelos usuários forem se tornando mais familiares com o sistema, estas sugestões poderão ser muito úteis em novas versões ou em novos produtos.

3.3.7 Vantagens das RNAs

A capacidade computacional de uma rede neural deriva principalmente da sua estrutura maciçamente distribuída e paralela, bem como da habilidade em aprender e, portanto, generalizar. Generalização refere-se à habilidade de uma rede neural produzir bons resultados mesmo quando apresentada a situações não consideradas durante o processo de aprendizagem. Estas características tornam possível à rede resolver problemas complexos e de grande escala. As vantagens principais das redes neurais são:

1. Tratamento de não linearidades Um neurônio pode ser modelado como um dispositivo não linear. Além disso, uma rede neural constituída por interconexões adequadas de neurônios é capaz de representar funções não lineares. A não linearidade é uma propriedade altamente importante, uma vez que o mecanismo físico responsável pela geração de um sinal de entrada inerentemente não linear.
2. Adaptabilidade Redes neurais têm a capacidade de adaptar seus pesos sinápticos em função do ambiente. Em particular, uma rede treinada para operar em um ambiente específico pode ser facilmente re-treinada para lidar com pequenas mudanças no ambiente.

3. Aplicações em tempo real A capacidade de adaptação e aprendizado em tempo real das RNAs é muitas vezes importante para corrigir ações de controle de sistemas com parâmetros variáveis. O tempo de execução de RNAs treinadas é compatível com os requisitos de aplicação em tempo-real.
4. Tolerância a falhas Uma rede neural treinada tem o potencial de ser inerentemente tolerante a falhas no sentido que, seu desempenho não cai apenas levemente sob condições operacionais adversas.
5. Não necessitam de modelos precisos da realidade do problema sendo. Conseguem resolver bem problemas de difícil modelagem matemática.

3.3.8 Aplicações de redes neurais em sistemas de controle

Os diversos problemas relacionados à área de sistemas de controle podem ser formulados de diferentes maneiras, dependendo de sua natureza. Esses problemas podem ser formulados através de sistemas complexos, não-lineares, dinâmicos, discretos, estocásticos, etc. Muitos problemas não lineares envolvendo sistemas de grande porte são de difícil solução. Em muitos casos, não existe uma solução analítica adequada, em particular, quando o problema apresenta requisitos de tempo-real. No contexto, RNA's têm se apresentado como uma excelente alternativa.

A grande maioria das aplicações de redes neurais envolve a utilização dos seguintes modelos:

- redes supervisionadas (ex. Perceptron de múltiplas camadas)
- redes recorrentes (ex. rede de Hopfield)
- redes não-supervisionadas (ex. rede de Kohonen)

A rede Perceptron de múltiplas camadas (MLP) se apresenta como uma excelente ferramenta para a tarefa de aproximação, visando a solução de problemas não-lineares de grande dificuldade. A rede de Hopfield [H82] é uma alternativa às técnicas de

programação matemática para a solução de problemas de otimização. A rede de Kohonen [K89] tem como principal característica permitir uma melhor compreensão e melhor tratamento dos dados de entrada, podendo ser utilizada para visualização e compressão de dados.

Em sistemas de potência a rede Perceptron de múltiplas camadas tem sido a mais aplicada, quando comparada com a rede de Hopfield e com a rede de Kohonen. Estas aplicações incluem a utilização de outros modelos que são, geralmente, os três modelos citados.

Dentre as áreas com aplicações mais frequentes de RNAs em sistemas de potência pode-se citar:

- previsão de carga [CD91, HH92, R95];
- detecção/diagnóstico de defeitos [AIS95, C89, HKH94, JDS91, SC99], [KKP91, SRSC01];
- análise de segurança dinâmica [KIBEC91, WE93, ZDF93];
- análise de segurança estática [AEPDM89, EMDACA90, WE92];
- estimação de estado [MT89, SLA96, SLA98]
- controle de sistemas de potência [L92, N93], etc.

Muitas aplicações de RNAs a sistemas de potência têm sido também propostas através da utilização de modelos híbridos, ou seja, modelos que envolvem o emprego de RNAs com outras técnicas de computação inteligente, tais como lógica difusa, algoritmos genéticos, etc. Isto é particularmente interessante quando a aplicação de uma técnica isoladamente não é suficiente para tratar todos os aspectos de um determinado problema. Nestes casos, a abordagem através de modelos híbridos tem se mostrado adequada.

3.4 Conclusões

Neste capítulo foram vistos alguns conceitos das redes neurais e da teoria dos conjuntos difusos. O objetivo não foi cobrir de uma forma completa a lógica difusa e redes neurais artificiais, mas sim apresentar aspectos importantes destas áreas, visando um melhor embasamento no que se refere aos elementos necessários para o desenvolvimento do modelo proposto neste trabalho.

No próximo capítulo será investigada a modelagem difusa para localização de defeitos em sistemas de potência, utilizando conceitos aprendidos neste capítulo.

MODELAGEM DIFUSA PARA LOCALIZAÇÃO DE DEFEITOS EM SISTEMAS DE POTÊNCIA

4.1 Introdução

A localização de defeitos em sistemas de potência consiste em identificar o componente defeituoso fazendo uso de informações sobre a operação de equipamentos de proteção, tais como relés e disjuntores. Projetar este tipo de identificação requer um domínio complexo do conhecimento de especialistas. Visto que estes tipos de conhecimento são experimentais e incertos, a modelagem para identificação é muito difícil. Para o tratamento destas classes de conhecimento, foi proposta a teoria dos conjuntos difusos, o qual pode ser considerada a mais adequada para tratamento de informações fornecidas por especialistas. Esta abordagem (fuzzy), como será visto adiante, permite a introdução do conhecimento qualitativo no modelo proposto.

A abordagem difusa permite associar diversos padrões de eventos possíveis eventos (componentes com defeito) através de graus de pertinência. Assim, um operador de sistemas de potência pode identificar o componente defeituoso levando em consideração as incertezas apresentadas no sistema.

Este capítulo tem como objetivo avaliar diferentes modelos para mapeamento fuzzy visando a localização de defeitos em sistemas de potência. Para isto serão construídos diagramas Sagitais, apresentados na seção 3.2.4, para localizar defeitos utilizando operadores nas relações difusas. Estes operadores serão avaliados para encontrar o melhor modelo para representar o problema de localização de defeitos em sistemas de potência. Os graus de pertinência obtidos nesta modelagem serão utilizados na construção do conjunto de treinamento para o modelo fuzzy proposto nesta dissertação.

4.2 Importância da Lógica Difusa no Problema de Localização de Defeitos em Sistemas de Potência

Conforme foi mencionado anteriormente, o "tratamento da incerteza na informação" tem um papel muito importante no problema apresentado, uma vez que gera incerteza nas conclusões obtidas. Portanto, o processo de diagnóstico deve possuir habilidade para tratar incertezas, chegando a conclusões com a medida de incerteza, ou seja, compreensível e corretamente interpretável pelo usuário. Assim, o armazenamento desta porção de incerteza ou vagueza do conhecimento utilizando conjuntos difusos parece ser muito mais apropriado que o uso de conceitos e simbolismos do cálculo proposicional (Booleano).

No processo de localização de defeitos em sistemas de potência apresentam-se muitas fontes de incertezas, as quais foram mencionadas nos capítulos anteriores. Portanto, requer-se tratar efetivamente estas incertezas. Antes da aplicação da teoria de conjuntos difusos, o único instrumento matemático desenvolvido para o tratamento destas incertezas foi a teoria das probabilidades. Especialmente para diagnósticos em redes Bayesianas baseadas na teoria das probabilidades foram muito utilizadas. Porém, as idéias e técnicas não têm-se difundido muito devido a que estas não são facilmente evidenciadas ou deduzidas [C91]. Além disso, estas redes Bayesianas não são apropriadas para sistemas de potência como é mencionado em [CT93]. Por exemplo, as redes Bayesianas não são capazes de lidar com sistemas de potência de grande porte, como não permite lidar com múltiplos defeitos que possam ocorrer no sistema elétrico. Então, a utilização das relações difusas permite trabalhar eficientemente em sistemas de potência de grande porte, não dificultando a construção de diagramas Sagitais para sistemas de potência complexos. Outra característica importante da abordagem difusa é a facilidade de redução na solução.

4.3 Descrição dos Sistemas de Potência Utilizados

4.3.1 Sistema de 7 barras

Com o intuito de avaliar a metodologia proposta neste trabalho, elaborou-se um diagrama de um sistema elétrico hipotético, composto de 7 barras e 8 linhas de transmissão, além de seus respectivos disjuntores. As funções de alarme consideradas no modelo proposto estão descritas na Tabela 4.1.

Tabela 4.1 - Configuração do padrão de alarme - sistema 7 barras

Componente	Informação	Sigla	Descrição
Linha de Transmissão	Proteção Principal	PP	Disparo
	Proteção 1ª zona	Z1	Disparo
	Proteção 2ª zona	Z2	Disparo
	Proteção Falha Disjuntor	BF	Disparo
	Disjuntor	DJ	Abertura
Barramento	Proteção Diferencial	PD	Disparo
	Disjuntor	DJ	Abertura

O sistema elétrico de 7 barras é apresentado na Figura 4.

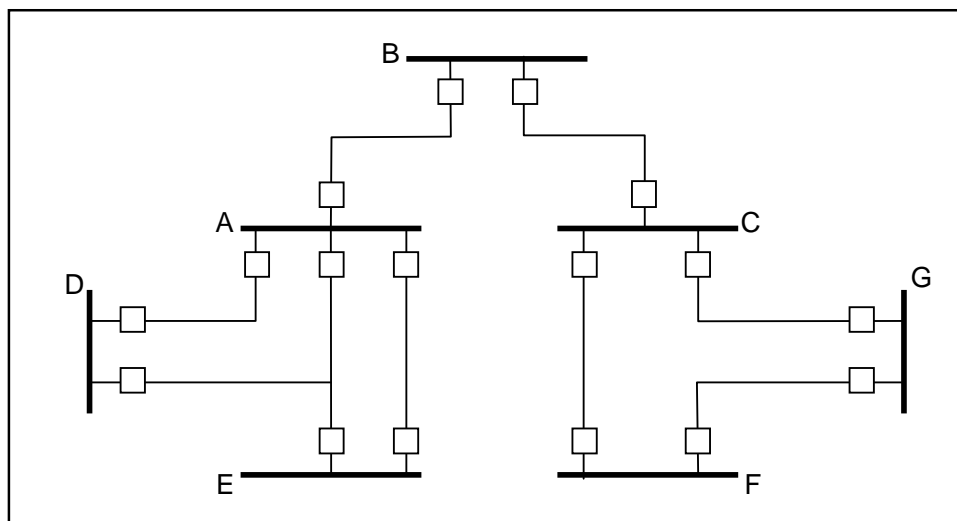


Figura 4.1 - Sistema Elétrico de Potência de sete barras

4.3.2 Sistema Light

A metodologia proposta será aqui testada em uma parte do sistema da Light Serviços de Eletricidade S.A., que atende a 30 municípios do Estado do Rio de Janeiro, correspondendo a 78% da demanda do estado. A parte do sistema considerada responsável pelo fornecimento de energia à zona sul, oeste e da cidade do Rio de Janeiro. O sistema elétrico em estudo é composto por cinco subestações Light e duas de Furnas Centrais Elétricas, interligadas por vinte linhas de transmissão de 138 kV, além dos respectivos disjuntores de terminais de linhas. As mesmas configurações consideradas no sistema de 7 barras serão consideradas no sistema Light e descritas na Tabela 4.2, por conveniência.

Tabela 4.2 - Configuração do padrão de alarme - sistema Light

Componente	Informação	Sigla	Descrição
Linha de Transmissão	Proteção Principal	PP	Disparo
	Proteção 1ª zona	Z1	Disparo
	Proteção 2ª zona	Z2	Disparo
	Proteção Falha Disjuntor	BF	Disparo
	Disjuntor	DJ	Abertura
Barramento	Proteção Diferencial	PD	Disparo
	Disjuntor	DJ	Abertura

O sistema Light é ilustrado na Figura 4.2 e a Tabela 4.3 list subestações contidas na parte do sistema em análise.

Tabela 4.3 - Subestações do sistema Light

Subestações	Sigla
Cascadura	CCD
Frei Caneca	FCN
Grajau	GRA
Jacarepaguá	JP
Jardim Botânico	JDB
Terminal Sul	TSU
Vila Valqueire	VVQ




Figura 4.2 - Sistema elétrico da Light

4.4 Relações Difusas e Diagramas Sagitais para a Localização de Defeitos em Sistemas de Potência

Uma relação clássica representa a presença ou ausência de associação, interação ou interligação entre elementos de dois ou mais conjuntos. Este conceito pode ser generalizado para permitir vários graus ou intensidades de interação entre elementos. Assim, graus de associação podem representar o grau de pertinência em uma relação difusa (fuzzy). Qualquer relação entre dois conjuntos X e Y é conhecido como uma relação binária, e é usualmente denotado por $R(X, Y)$. Uma relação difusa binária pode ser representado facilmente por um diagrama sagital. Cada conjunto X, Y é representado por um conjunto de nós no diagrama. Elementos x de X e y de Y com graus de associação $B(x, y)$ diferente de zero são representados no diagrama por setas conectando os nós respectivos. Estas setas são designadas com o grau de associação ou respectiva. Para o problema de localização de defeitos em sistemas de potência, propostos diagramas Sagitais que tenham 3 conjuntos de nós:

- Conjunto 1: componentes
- Conjunto 2: relés
- Conjunto 3: disjuntores,

Para o modelo hipotético, composto de 7 barras e 8 linhas de transmissão, pode-se construir diagramas Sagitais, como os exemplificados na Figura 4. Estes diagramas são construídos considerando as operações causais de relés e disjuntores em decorrência de um defeito, a causalidade é denotada por setas. A designação de cada elemento é determinada considerando as incertezas de operação e as prioridades de relés e disjuntores quando ocorre um defeito. Cabe mencionar que as designações consideradas nos diagramas Sagitais são estabelecidas com a ajuda de especialistas da área de proteção de sistemas de potência.

Para cada componente, os valores adotados buscam refletir o grau de associação entre este e cada relé que pode atuar em casos de defeito. Por exemplo, para uma linha de transmissão a associação com a proteção de primeira zona (Z1) é forte, devido a sua seletividade, enquanto a associação com a proteção de segunda zona (Z2) é mais fraca, já que esta pode também atuar para defeitos em componentes adjacentes. Da mesma forma, são observadas também as associações entre disjuntores e proteção que podem comandar uma abertura.

Para os relés e disjuntores apresentados nos diagramas, as que aparecem sublinhadas indicam o terminal onde o equipamento está localizado. O símbolo "O" conectando um relé e um disjuntor indica que o disjuntor não pode ser aberto comandado por aquele relé.

(a) Linha A-B

(b) Linha C-F

(c) Barra A

(d) Barra C

Figura 4.3 - Diagramas Sagitais para o Sistema de Sete Barras

4.5 Procedimento para o Estabelecimento das Relações Difusas

O processo para obtenção das relações difusas entre os padrões de alarme e os componentes do sistema, utilizando os diagramas sagitais, consiste dos seguintes passos:

Passo 1: Interseção das designações das setas que criam um caminho através do conjunto 1, conjunto 2, e conjunto 3, dado que equipamentos representados pelos nós do conjunto 2 e 3 operarem. Isto determina a operação dos nós do conjunto 2 e do conjunto 3.

Passo 2: União dos resultados do passo 1. Isto relaciona os caminhos conectados para um componente (nó do conjunto 1).

O resultado do passo 2 determina o grau de pertinência dos padrões de alarme em cada classe do problema (componentes possivelmente defeituosos). Pode-se portanto, a partir da comparação entre os graus de pertinência obtidos, identificar o componente defeituoso.

Existem muitas classes de operadores de interseção e união nas relações difusas, os quais podem ser utilizados nos passos acima descritos. Estes operadores de agregação, satisfazem todos os requerimentos axiomáticos para a união e interseção difusa [KF88]. Na próxima seção serão apresentados de forma sucinta os operadores que serão investigados neste trabalho, visando identificar aquele mais adequado para a obtenção das associações difusas entre padrões de alarme e componentes no problema de localização de defeitos em sistemas de potência. Estes operadores já foram previamente discutidos na seção 3.2.3.

4.6 Modelos Utilizados

Os modelos a serem apresentados baseiam-se principalmente na utilização dos diferentes operadores paramétricos de união e interseção difusa. Assim, segundo [GKY95, H98] uma grande quantidade de trabalhos têm sido feitos por muitos autores que criaram famílias paramétricas de *t-normas* (interseção) e *s-normas* (união).

A seguir serão apresentados alguns dos modelos que serão utilizados neste trabalho, os quais serão avaliados posteriormente, visando identificar o mais adequado.

4.6.1 Modelo Hamacher

Este modelo têm como objetivo utilizar operadores paramétricos, propostos por Hamacher [H98], o qual define uma família *triangular* de operadores em termos do parâmetro γ :

Operador de Interseção: A interseção de dois conjuntos difusos A e B , é definida em termos do parâmetro γ como:

$$t_H(a, b, \gamma) = \mu_{A \cap B}(x) = \frac{ab}{\gamma + (1 - \gamma)(a + b - ab)}, \quad \gamma \geq 0 \quad (4.1)$$

onde $a = \mu_A(x)$ e $b = \mu_B(x)$.

Operador de União: A união de dois conjuntos difusos A e B , é definida em termos do parâmetro γ como:

$$s_H(a, b, \gamma) = \mu_{A \cup B}(x) = \frac{a + b + (\gamma - 1)ab}{1 + \gamma ab}, \quad \gamma \geq 0 \quad (4.2)$$

onde $\gamma \geq -1$ e $\gamma' = \gamma - 1$.

4.6.2 Modelo Yager

Este modelo têm como objetivo utilizar operadores paramétricos, propostos por Yager [Y80], o qual define uma família *triangular* de operadores em termos do parâmetro p .

Operador de Interseção: A interseção de dois conjuntos difusos A e B , é definida em termos do parâmetro p como:

$$t_Y(a, b, p) = \mu_{A \cap B}(x) = 1 - \min \{ 1, [(1-a)^p + (1-b)^p]^{1/p} \} \quad p \geq 1 \quad (4.3)$$

Operador de União: Este é um típico s -norma parametrizado definido pela função:

$$s_Y(a, b, p) = \mu_{A \cup B}(x) = \min \{ 1, [a^p + b^p]^{1/p} \} \quad p \geq 1 \quad (4.4)$$

4.6.3 Modelo Dubois & Prade

Este modelo têm como objetivo utilizar operadores paramétricos, propostos por Dubois & Prade [DP80], onde define-se uma família parametrizada, comutativa e associativa, de operadores em termos de um parâmetro α .

Operador de Interseção: A interseção de dois conjuntos difusos A e B , é definida como:

$$t_{DP}(a, b, \alpha) = \mu_{A \cap B}(x) = \frac{ab}{\max(a, b, \alpha)} \quad (4.5)$$

Operador de União: A união de dois conjuntos difusos A e B , é definida, segundo Dubois & Prade, como:

$$s_{DP}(a, b, \alpha) = \mu_{A \cup B}(x) = \frac{a + b - ab - \min\{a, b, (1-\alpha)\}}{\max\{(1-a), (1-b), \alpha\}} \quad (4.6)$$

onde $0 \leq \alpha \leq 1$.

4.6.4 Modelo Dombi

Este modelo têm como objetivo utilizar operadores paramétricos, propostos por Dombi [DV83], o qual apresenta uma família parametrizada de operadores em termos de um parâmetro λ .

Operador de Interseção: A interseção de dois conjuntos difusos A e B , é definida como:

$$t_D(a, b, \lambda) = \mu_{A \cap B}(x) = \frac{1}{1 + [(1/a - 1)^\lambda + (1/b - 1)^\lambda]^{1/\lambda}} \quad (4.7)$$

Operador de União: A união de dois conjuntos difusos A e B , é definida como:

$$s_D(a, b, \lambda) = \mu_{A \cup B}(x) = \frac{1}{1 + [(1/a - 1)^{-\lambda} + (1/b - 1)^{-\lambda}]^{-1/\lambda}} \quad (4.8)$$

para este sistema $\lambda \in (0, \infty)$.

4.6.5 Exemplo de aplicação dos modelos descritos

De modo a exemplificar a utilização dos modelos descritos, considere o seguinte padrão de alarmes, observado para a ocorrência de um defeito na linha B-C do sistema de 7 barras da Figura 4.1:

Alarmes recebidos:

- Linha B-C terminal B: Z1 e DJ
- Linha B-C terminal C: Z2 e DJ

O diagrama Sagital correspondente a linha B-C é apresentado na Figura 4.4, onde a ativação dos alarmes recebidos criam caminhos através do conjunto 1, conjunto 2 e conjunto 3, o qual determina posteriormente o grau de pertinência da classe (componente).

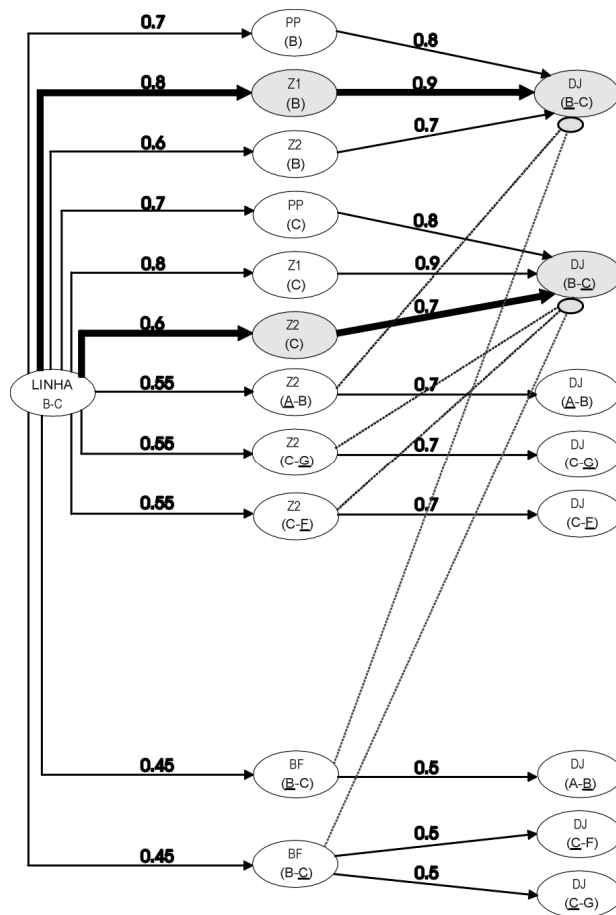


Figura 4.4 - Diagrama Sagital da Linha B-C do Sistema de Sete Barras

Utilizando os modelos descritos anteriormente, tem-se:

a) **Modelo Hamacher:** Da equação 4.1 e 4.2 com $\gamma = 3$, $\gamma' = 2$.

Passo 1:

$$t_{H(0,8; 0,9; 3)} = \frac{(0,8)(0,9)}{3 + (1 - 3) (0,8 + 0,9 - (0,8)(0,9))} = 0,69 \quad (\text{Terminal B})$$

$$t_{H(0,6; 0,7; 3)} = \frac{(0,6)(0,7)}{3 + (1 - 3) (0,6 + 0,7 - (0,6)(0,7))} = 0,34 \quad (\text{Terminal C})$$

Passo 2:

$$s_H(0,69; 0,34, 2) = \frac{0,69 + 0,34 + (2 - 1) (0,69)(0,34)}{1 + 2 (0,69)(0,34)} = 0,861$$

O modelo Hamacher forneceu um grau de pertinência igual a 0,861 para o componente, o qual é um resultado bom para o problema.

b) Modelo Yager: Da equação 4.3 e 4.4 com $p = 3$.

Passo 1:

$$t_Y(0,8; 0,9; 3) = 1 - \min \{ 1, [(1-0,8)^3 + (1-0,9)^3]^{1/3} \} = 0,792 \quad (\text{Terminal B})$$

$$t_Y(0,6; 0,7; 3) = 1 - \min \{ 1, [(1-0,6)^3 + (1-0,7)^3]^{1/3} \} = 0,551 \quad (\text{Terminal C})$$

Passo 2:

$$s_Y(0,792; 0,551; 3) = \min \{ 1, [0,792^3 + 0,551^3]^{1/3} \} = 0,8725$$

O modelo Yager, tal como o Hamacher forneceu um grau de pertinência adequado para o problema.

c) Modelo Dubois & Prade: Da equação 4.5 e 4.6 com $\alpha = 0,8$.

Passo 1:

$$t_{DP}(0,8; 0,9; 0,8) = \frac{(0,8)(0,9)}{\max (0,8; 0,9; 0,8)} = 0,800 \quad (\text{Terminal B})$$

$$t_{DP}(0,6; 0,7; 0,8) = \frac{(0,6)(0,7)}{\max (0,6; 0,7; 0,8)} = 0,525 \quad (\text{Terminal C})$$

Passo 2:

$$s_{DP}(0,80; 0,525; 0,8) = \frac{0,80 + 0,525 - (0,80)(0,525) - \min\{0,80; 0,525; (1-0,8)\}}{\max\{ (1-0,80); (1-0,525); 0,8 \}}$$

$$= 0,881$$

d) Modelo Dombi: Da equação 4.7 e 4.8 com $\lambda = 0,6$.

Passo 1:

$$t_D(0,8; 0,9; 0,6) = \frac{1}{1 + [(1/0,8 - 1)^{0,6} + (1/0,9 - 1)^{0,6}]^{1/0,6}}$$

$$= 0,643 \quad \text{(Terminal B)}$$

$$t_D(0,6; 0,7; 0,6) = \frac{1}{1 + [(1/0,6 - 1)^{0,6} + (1/0,7 - 1)^{0,6}]^{1/0,6}}$$

$$= 0,367 \quad \text{(Terminal C)}$$

Passo 2:

$$s_D(0,643; 0,367; 0,6) = \frac{1}{1 + [(1/0,643 - 1)^{-0,6} + (1/0,367 - 1)^{-0,6}]^{-1/0,6}}$$

$$= 0,7810$$

As mesmas análises podem ser realizadas para os outros componentes utilizando os respectivos diagramas Sagitais.

4.7 Avaliação dos Modelos no Processo de Localização de Defeitos em Sistemas de Potência

Como os modelos apresentados na seção anterior utilizam operadores paramétricos, é possível que diferentes resultados possam ser obtidos se diferentes valores dos parâmetros forem utilizados. Assim, como o parâmetro é muito importante para a solução final, é importante escolher o parâmetro mais adequado para cada modelo, para posteriormente realizar uma comparação entre os modelos propostos.

4.7.1 Escolha do parâmetro adequado aos modelos apresentados

A escolha do parâmetro adequado em cada modelo apresentado baseia-se principalmente na simulação de casos nos dois sistemas testados. Essas simulações utilizam diversos padrões de alarme no sistema.

O Apêndice A mostra alguns exemplares de simulação para o sistema de sete barras, assim como os resultados obtidos utilizando diferentes valores do parâmetro em cada modelo proposto.

A Tabela 4.4 mostra a análise final de cada modelo, onde define-se o parâmetro que se julgou mais adequado em cada caso.

Tabela 4.4 - Valor adequado do parâmetro em cada modelo

Modelo	Valor do Parâmetro
<i>Hamacher</i>	$\gamma = 5$ e $\gamma' = 4$ ($\gamma' = \gamma - 1$)
<i>Yager</i>	$p = 2$
<i>Dubois & Prade</i>	$\alpha = 0,95$
<i>Dombi</i>	$\lambda = 0,40$

Para cada modelo, o valor do parâmetro escolhido apresenta uma melhor resposta para a localização de defeitos em sistemas de potência. Este julgamento se baseia na análise qualitativa dos graus de pertinência obtidos por cada modelo, com diferentes valores do parâmetro, para diferentes situações de defeito na rede elétrica.

Por exemplo, defeitos bem caracterizados pelos alarmes gerados (sem falhas do sistema de proteção) definem claramente a classe correspondente. É esperado, e desejável, que os graus de pertinência em relação ao componente defeituoso (classe a ser identificada) possuam valores altos, enquanto os graus de pertinência associados as demais classes apresentem graus de pertinência baixos.

Por outro lado, quando após um defeito ocorrem falhas no sistema de proteção, o padrão de alarmes gerado pode não ser tão representativo da classe a ser identificada (componente defeituoso) como no caso anterior. Nesse caso, é esperado que o grau de pertinência associado ao componente defeituoso e o grau de pertinência de outro(s) componentes(s) estejam mais próximos. Porém, ainda é desejável que o grau de pertinência do componente defeituoso tenha o valor mais elevado e que os demais graus de pertinência (outros componentes) não se superponham a ele, ficando com os valores mais baixos possíveis. Alguns dos casos analisados são apresentados no Apêndice A.

4.7.2 Seleção do melhor modelo para a localização de defeitos em sistemas de potência

Com os parâmetros definidos para cada modelo, pode-se fazer uma análise para a escolha do melhor modelo para a localização de defeitos em sistemas de potência. As conclusões se baseiam na observação dos resultados para os diferentes modelos testados e seguiram a mesma análise qualitativa mencionada na seção 4.7.1.

Dessa maneira, foi possível concluir que o modelo *Hamacher* com o parâmetro γ igual a 5, apresenta melhores resultados para o problema de localização de defeitos em sistemas de potência.

A análise qualitativa e os resultados da modelagem difusa para a localização de defeitos em sistemas de potência serão publicados em [MSSC01].

4.8 Conclusões

Este capítulo apresentou uma modelagem difusa para o problema de localização de defeitos em sistemas de potência. Esta modelagem utiliza a lógica difusa para tratar incertezas apresentadas nas informações do sistema. Foram apresentados diagramas Sagitais, os quais representam as relações difusas no problema tratado, e permitem obter o

grau de pertinência dos padrões de alarme para cada componente com operações de união e interseção nas relações difusas. Para isso foram apresentados modelos que realizam operações de união e interseção difusa.

Comparando os diferentes graus de pertinência, pode-se identificar o componente defeituoso. As relações difusas estabelecidas podem ser utilizadas para a construção de sistemas especialistas visando a localização de defeitos em sistemas de potência. Porém, conforme mencionado anteriormente, os sistemas especialistas não são tolerantes a falhas e podem não responder bem para situações não consideradas durante sua construção. Por outro lado, pode-se utilizar as relações difusas para a construção de uma base de dados que associa diversos padrões de alarme a graus de pertinência nos componentes do sistema. Essa base de dados pode ser utilizada como conjunto de treinamento para uma rede neural que aprenderá a realizar o mapeamento *fuzzy* entre os padrões de alarme e os possíveis eventos (componentes com defeito). As redes neurais são tolerantes a falhas e devem desempenhar bem este papel. Além disso, a obtenção de valores *fuzzy* como resposta das redes neurais, ao invés de valores binários, permite uma melhor interpretação dos resultados, conforme será discutido no próximo capítulo.

METODOLOGIA PROPOSTA

5.1 Introdução

Conforme discutido anteriormente, a ocorrência de um dado defeito faz com que o sistema de proteção opere e um conjunto de alarmes seja enviado ao centro de controle, onde deve ser obtido um diagnóstico do evento ocorrido. Recentemente uma aplicação de redes neurais foi proposta para a solução deste problema [RSSC99], apresentando resultados satisfatórios mesmo em situações de falha no sistema de proteção. Entretanto, verificou-se que em outras situações, também na presença de falhas do sistema de proteção, não era possível obter um diagnóstico preciso a partir das saídas obtidas pelas redes neurais utilizadas. Isto ocorria porque as redes neurais eram treinadas para fornecer saídas binárias (defeituoso ou não defeituoso) e saídas com valores intermediários, obtidas para certas situações, não eram possíveis de serem interpretadas. Este trabalho propõe a utilização de um modelo *Neuro-Fuzzy*, onde as saídas desejadas para as redes neurais passam a ser os graus de pertinência de cada padrão de alarme do conjunto de treinamento nas classes do problema (componentes monitorados). Com isto, é possível realizar o mapeamento *fuzzy* entre padrões de entrada e saídas da rede, onde a capacidade de interpretação das saídas desejadas é preservada, preservando-se também a tolerância a falhas e capacidade de generalização, características das redes neurais. Para a construção deste modelo, deve ser gerado um conjunto de treinamento contendo as associações *fuzzy* entre padrões de alarme e possíveis componentes defeituosos, obtido utilizando as relações *fuzzy* discutidas no capítulo anterior.

Os alarmes gerados após um defeito devem corresponder a atuação de relés e disjuntores que protegem o elemento envolvido, podendo englobar também a proteção de alguns componentes adjacentes que neste caso atuam como proteção de retaguarda. Logo,

é razoável imaginar que a monitoração de apenas um conjunto limitado de alarmes seja suficiente para a identificação de um dado componente defeituoso. Haja vista esta característica, uma estratégia local é adotada visando reduzir a dimensão do problema. A metodologia utiliza o conceito das zonas de proteção e leva em consideração o fato de que, para identificar um componente com defeito são necessárias as informações associadas ao componente e, nas condições mais adversas, apenas algumas informações de componentes adjacentes.

Várias redes *neuro-fuzzy* são então utilizados, cada uma deles responsável pela detecção de defeitos envolvendo um número limitado de componentes do sistema elétrico. Cada uma destas redes é aqui denominada de Rede *Neuro-Fuzzy* (RNF). Uma vez treinadas, estas redes podem fornecer resultados em tempo-real, quando executados após a apresentação de suas variáveis de entrada, as quais são extraídas do conjunto de alarmes recebidos durante um distúrbio. A arquitetura e construção destas redes, assim como, sua utilização para produzir resultados em tempo-real serão discutidas nas seções seguintes.

5.2 Arquitetura do Modelo *Neuro-Fuzzy*

Nos últimos anos, tem havido um crescente interesse sobre os chamados sistemas *neuro-fuzzy* [L95, WM92]. A rigor qualquer sistema que misture os paradigmas de sistemas difusos e sistemas conexionistas poderia ser chamado de *neuro-fuzzy*, como, por exemplo, a utilização de um controlador difuso para alterar dinamicamente a taxa de aprendizado de uma rede neural. No entanto, o termo é utilizado para um tipo específico de sistema que de certa forma engloba os dois paradigmas. Nestes sistemas, os termos e regras de um sistema difuso são “aprendidos” mediante a apresentação de pares (entrada, saída desejada). Eles apresentam dois comportamentos distintos, dependendo de estar numa fase de aprendizado ou uma fase de processamento da informação: na fase de aprendizado, eles têm um comportamento de redes neurais, e na fase de processamento se comportam como um sistema difuso.

Estes sistemas são capazes de solucionar problemas apresentados pelos paradigmas em que se baseiam. Por exemplo, duas questões em aberto a respeito de redes neurais são:

- Como determinar quantas camadas e quantos nós devem ser usados em uma rede neural para que ela resolva efetivamente um dado problema, de maneira eficiente?
- Que tipo de conhecimento pode ser extraído de uma rede treinada e como pode ser feita esta extração?

Em relação a sistemas difusos, um problema importante e aparentemente insolúvel é:

- Como construir um sistema difuso, se ao invés de um especialista capaz de fornecer regras, temos somente um conjunto de exemplos do funcionamento ideal do sistema?

Como um sistema difuso, os sistemas *neuro-fuzzy* podem “explicar” o seu comportamento, através de regras que modelam o conhecimento do sistema. Como uma rede neural (do tipo supervisionada), o aprendizado do sistema *neuro-fuzzy* é feito a partir da apresentação de exemplos [SC97]. Ao contrário dos sistemas difusos, eles prescindem da necessidade de um especialista que lhes forneça as regras.

Em sistemas difusos, os pares de entrada-saída têm a estrutura de regras IF-THEN que relaciona variáveis difusas. Por outro lado, as redes neurais são capazes de criar uma arquitetura de aproximação que pode ser utilizado para generalizar as regras IF-THEN através da apresentação de exemplos, isto devido à natureza adaptativa do processo de aprendizado da rede neural. Na figura 5.1 é mostrada uma arquitetura *neuro-fuzzy* para o problema da localização de defeitos em sistemas de potência.

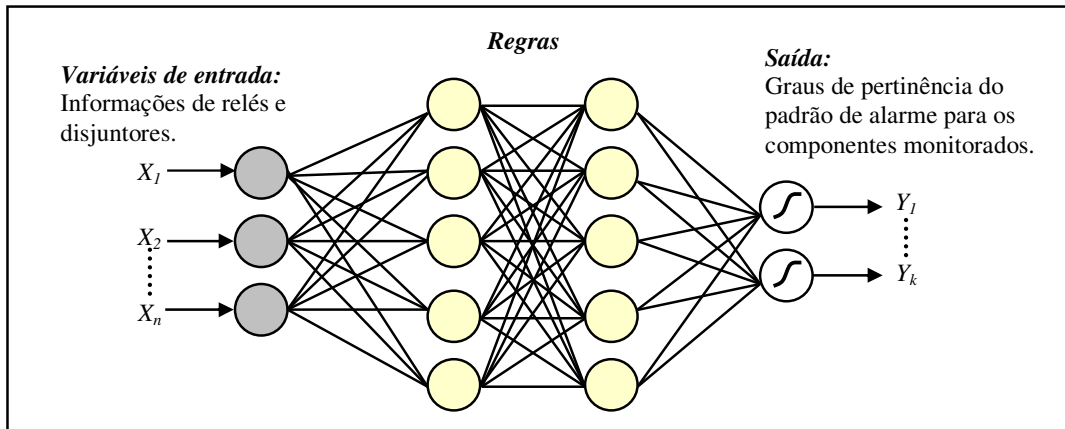


Figura 5.1 - Arquitetura do modelo *Neuro-Fuzzy* proposto

5.3 Construção das Redes *Neuro-Fuzzy*

5.3.1 Divisão do sistema em áreas

A metodologia empregada requer que o sistema seja dividido em áreas, cada uma delas compreendendo um conjunto de componentes que serão supervisionados por uma RNF específica. Isso pode ser ilustrado utilizando o sistema elétrico de potência de sete barras apresentado no capítulo anterior. Este sistema foi arbitrariamente dividido em três áreas, que englobam diferentes componentes.

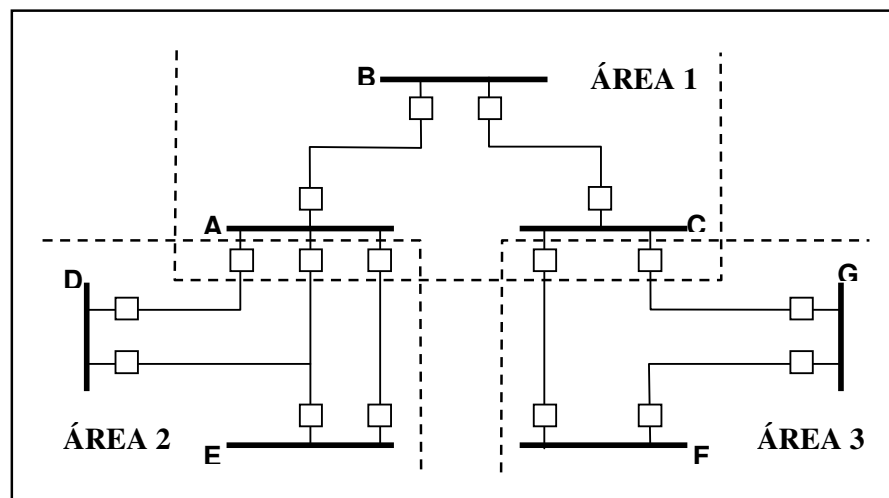


Figura 5.2 - Sistema Elétrico de Potência de sete barras

Neste caso, devem-se construir três redes responsáveis por detectar defeitos envolvendo os componentes do sistema, conforme ilustrado na Tabela 5.1.

Tabela 5.1 - Redes *Neuro-Fuzzy* por área

ÁREA	REDE <i>NEURO-FUZZY</i>	COMPONENTES SUPERVISIONADOS
1	RNF ₁	Linha A-B, Linha B-C e Barras A, B e C
2	RNF ₂	Linha A-D, Linha A-D-E, Linha A-E e Barras D e E
3	RNF ₃	Linha C-F, Linha C-G, Linha F-G e Barras F e G

A divisão do sistema elétrico de potência proposta neste trabalho não segue uma regra pré-estabelecida. Ela é baseada na experiência do especialista de proteção e varia de sistema para sistema. O objetivo principal é definir o tamanho da área em função da dimensão desejada para o vetor de entradas de cada RNF. É possível também estabelecer critérios baseados nas características topológicas do sistema em análise [R99].

5.3.2 Seleção das variáveis de entrada

O vetor de variáveis de entrada para cada rede *neuro-fuzzy* deve conter as informações sobre a atuação de relés e disjuntores, necessárias para que seja produzido um diagnóstico sobre os componentes da área monitorada. Isto deve envolver alarmes gerados pela atuação de relés e disjuntores na área monitorada e também algumas informações externas, importantes para o diagnóstico dos componentes próximos à fronteira entre áreas.

Na Tabela 5.2 são mostrados os alarmes que serão considerados na definição das variáveis de entrada:

Tabela 5.2 - Alarmes considerados na definição das variáveis de entrada

Componentes	Alarmes
Linha de Transmissão	Proteção Principal - Teleproteção (PP) Proteção de 1ª zona - Retaguarda Instantânea (Z1) Proteção de 2ª zona - Retaguarda Temporizada (Z2) Proteção para Falha do disjuntor - <i>Breaker Failure</i> (BF) Disjuntor (DJ)
Barramento	Proteção Diferencial de Barra (PD) Disjuntores (DJ)

Para a área do sistema da Figura 5.1, as variáveis de entrada para a RNF₁ serão aquelas apresentadas na Tabela 5.3. As variáveis 1 até 19 representam os relés de proteção na área supervisionada, e as variáveis 20 até 28 representam os disjuntores. Deve-se observar que as variáveis 24, 25 e 26 referem-se aos disjuntores das linhas A-D, A-D-E e A-E, localizados no terminal A, e que as variáveis 27 e 28 referem-se aos disjuntores das linhas C-F e C-G, localizados no terminal C.

Tabela 5.3 - Variáveis de entrada para a RNF₁

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	P	P	D	D	D	D	D	D	D	D	D
P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F	D	D	D	J	J	J	J	J	J	J	J	J
Terminal A				Terminal B				Terminal B				Terminal C				A	B	C	Terminal				Disj.		Disj.		
Linha A-B				Linha B-C				Linha B-C				Barra				Barra		Linha A-B		Linha B-C		Barra					

Além das variáveis inerentes aos componentes supervisionados pela RNF, foram utilizadas também algumas informações de componentes adjacentes. A configuração final das variáveis de entrada da área 1 (RNF₁) está representada na Tabela 5.4.

Tabela 5.4 - Configuração Final da RNF₁

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	
P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	P	P	D	D	D	D	D	D	D	D	D	D	Z	Z	D	Z	Z	D
P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F	D	D	D	J	J	J	J	J	J	J	J	J	J	1	2	J	1	2	J
Terminal A				Terminal B				Terminal B				Terminal C				A	B	C	Terminal				Disj.		Disj.		Área 2				Área 3			
Linha A-B				Linha B-C				Linha B-C				Barra				Barra		Linha A-B		Linha B-C		Barra												

Esta seleção de variáveis baseou-se na experiência dos especialistas de proteção e também das conclusões obtidas através de uma análise de extração/seleção de características relevantes para este problema [R99, SRSC01]. A seleção das variáveis de entrada utilizadas para as demais áreas, assim como para o sistema Light, seguiu a mesma filosofia.

Nas áreas adjacentes foram utilizadas variáveis que indicam a atuação ou não de alguma proteção de primeira zona, segunda zona e/ou de algum disjuntor nestas áreas (entradas 29, 30, 31, 32, 33 e 34 na Tabela 5.4). Estas variáveis foram incluídas visando melhorar o diagnóstico para defeitos em elementos próximos a fronteira, principalmente em casos de falhas de proteção e/ou disjuntores. A informação externa sobre a proteção de primeira zona é importante devido a sua seletividade e uma indicação de sua atuação em uma área adjacente tende a reforçar um diagnóstico que negue a ocorrência de um defeito em um componente supervisionado na área em análise. Por outro lado, a informação externa sobre a proteção de segunda zona, é importante para o treinamento da rede *neuro-fuzzy*, devido a que a falta desta informação pode apresentar padrões de alarme iguais com diferentes saídas desejadas, o qual dificulta o aprendizado da rede. A informação da proteção principal da linha, não caracteriza eficientemente um defeito na própria linha uma vez que pode vir a atuar para defeitos fora da área protegida. Além disso a proteção principal está associada a falhas nos canais de comunicação (Carrier), o qual é muito comum.

No caso específico das RNFs associadas somente à barra, os mesmos deverão receber como informação externa, a atuação da proteção para falha de disjuntor (BF) das linhas de transmissão associados ao terminal ligado à referida barra. Essa informação é relevante no caso de defeito na linha de transmissão com falha de disjuntor, o que poderia levar a RNF associada à barra a um diagnóstico incorreto (identificar defeito na barra, quando esta de fato ocorreu na linha).

Logo, para os componentes "linha de proteção" devem ser consideradas as informações de proteção de retaguarda instantânea (Z1), retaguarda temporizada (Z2) e o respectivo disjuntor, inerentes ao terminal remoto, de forma a enfatizar defeitos na área adjacente. Caso essas linhas façam fronteira com alguma área associada à barra, eles

deverão também receber informação da atuação da proteção diferencial da barra (DP). As variáveis de entrada utilizadas para cada RNF no sistema de 7 barras e no sistema Light são apresentados no Apêndice B.

Com o advento de relés de teleproteção digitais, que utilizam canais de comunicação via fibra ótica, o desempenho dessa proteção tende a melhorar, tornando essa informação mais confiável. Dessa forma, uma revisão na utilização das informações externas deverá levar em conta também a atuação da proteção principal (PP).

5.3.3 Treinamento

As variáveis de entrada de cada RNF são as informações sobre a atuação de relés e disjuntores necessários para a identificação do componente defeituoso na área monitorada, conforme discutido na seção anterior. O número de variáveis na saída de cada RNF corresponde ao número de componentes sendo supervisionado. A saída obtida reflete o grau de incerteza da inferência realizada, fornecendo subsídios realistas para o diagnóstico.

Cada RNF é treinada *offline* uma única vez, utilizando os graus de associação fornecidos pela modelagem difusa, descrita no capítulo anterior. Na construção deste conjunto de treinamento considerou-se vários padrões associados às ocorrências de defeitos envolvendo os componentes supervisionados. Esses padrões de alarmes também incluem situações nas quais os dispositivos de proteção não atuam corretamente. Assim, para cada padrão de alarme, a modelagem difusa fornece um grau de pertinência para cada componente monitorado. Deste modo são construídos os pares entradas/saídas desejadas, os quais são utilizados para o treinamento das redes. O processo de construção dos conjuntos de treinamento pode ser ilustrado pela Figura 5.3.

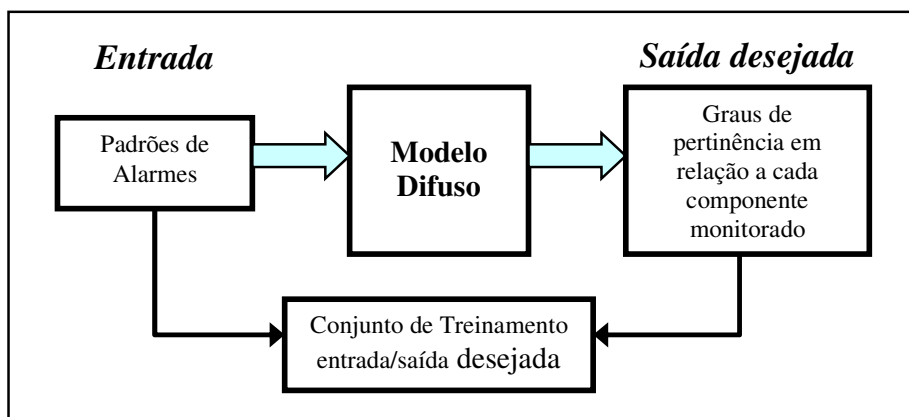


Figura 5.3 - Construção do conjunto de treinamento

Para a obtenção das saídas desejadas, ou seja, os graus de pertinência em relação aos componentes supervisionados, utilizou-se o Modelo *Hamacher*, o qual pela análise feita no capítulo anterior, fornece os melhores resultados para a localização de defeitos em sistemas de potência. As entradas são vetores cujos elementos são binários, assumindo valor igual a 1 nas posições referentes aos alarmes ativados e igual a 0 nas demais.

5.4 Classificação em Tempo-Real

Uma vez treinadas, as RNFs podem ser utilizados para obtenção de diagnósticos em tempo real. As ações a serem tomadas quando um conjunto de alarmes é recebido no Centro de Operação podem ser resumidas como se segue:

- (i) Selecionar as RNFs para os quais no mínimo um dos alarmes recebidos é uma variável de entrada (excluídas as variáveis que representam informações externas);
- (ii) Testar as RNFs selecionados; e
- (iii) Produzir um diagnóstico baseado na análise dos graus de pertinência fornecidos pelas RNFs.

No passo (i) pode-se observar que as RNFs cujos alarmes recebidos correspondem apenas às variáveis que representam a informação externa, não serão selecionadas. Isto ocorre porque neste caso pode-se garantir que o defeito não envolveu nenhum componente por ela supervisionado. É importante também ressaltar que cada vetor de entrada contém elementos iguais a 0 (zero) nas posições referentes aos alarmes não recebidos e iguais a 1 nas posições referentes aos alarmes recebidos após um distúrbio.

O diagrama de blocos da Figura 5.4 ilustra a seqüência descrita acima.

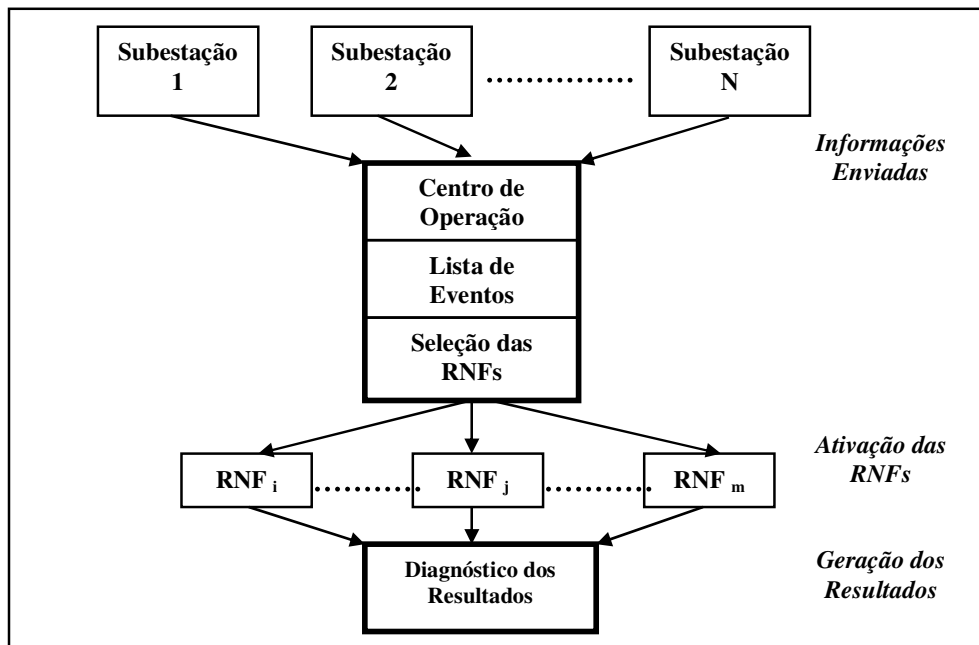


Figura 5.4 - Fluxograma de Operação

No caso de falhas de dispositivos de proteção, uma área maior no sistema será desconectada e é esperado que mais RNFs tenham que ser ativada.

O diagnóstico final será obtido através da análise dos graus de pertinência fornecidos pelas redes *neuro-fuzzy*. Dos resultados apresentados pelas redes, assume-se que o componente defeituoso é aquele que fornece o maior grau de pertinência.

5.5 Índices de Desempenho

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

- **Diagnóstico correto (%)** - casos no qual o componente defeituoso foi identificado corretamente.

$$DC (\%) = \frac{NDC}{NC} \times 100 \quad (5.1)$$

onde:

DC (%) - percentual de diagnósticos corretos

NDC - número total de diagnósticos corretos

NC - número total de casos testados

- **Diagnóstico incorreto (%)** - casos nos quais a identificação do componente defeituoso não foi correta.

$$DI (\%) = \frac{NDI}{NC} \times 100 \quad (5.2)$$

onde:

DI (%) - percentual de diagnósticos incorretos

NDI - número total de diagnósticos incorretos

Os fluxogramas apresentados nas Figuras 5.5 e 5.6 resumem os procedimentos de construção das redes e de teste e validação da metodologia. Estes procedimentos foram utilizados para a obtenção dos resultados que serão apresentados no capítulo seguinte.

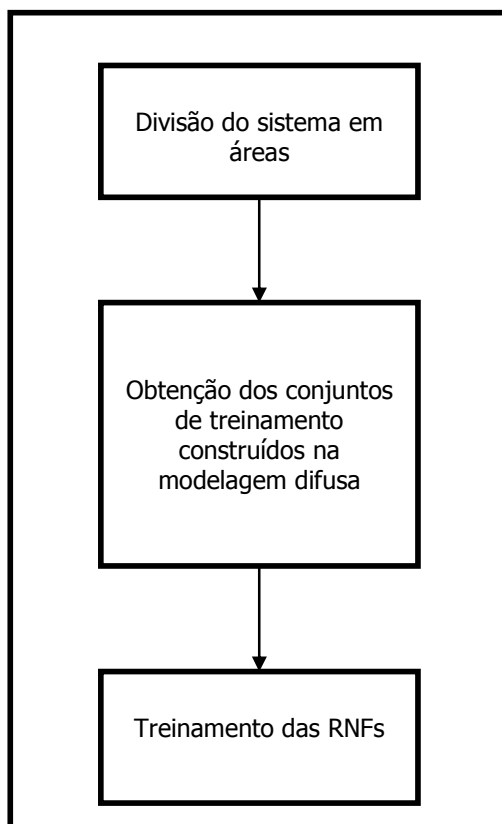


Figura 5.5 - Construção das redes.

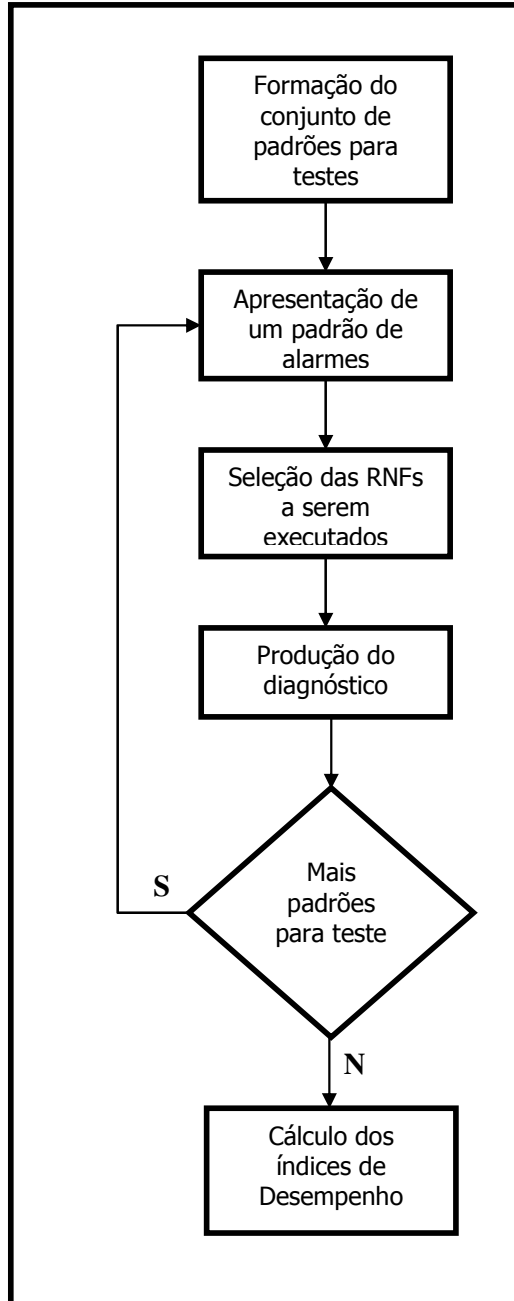


Figura 5.6 - Teste e validação da metodologia.

5.7 Conclusões

Este capítulo apresentou uma metodologia para a localização de defeitos em sistemas de potência através do emprego de Redes *Neuro-Fuzzy*. A estratégia local adotada consiste em dividir o sistema em áreas. A descomposição do sistema visa reduzir a dimensão do problema, reduzindo o número de variáveis de entrada para cada rede.

Os passos para construção das redes e para a sua utilização em tempo-real foram apresentados. Aspectos como seleção das variáveis de entrada, obtenção das saídas desejadas e construção do conjunto de treinamento foram discutidos. Foram apresentados ainda critérios para a obtenção de um diagnóstico para o problema a partir da análise dos graus de pertinência fornecidos pelas redes. Também foram propostos índices de desempenho para avaliar a metodologia proposta.

O próximo capítulo apresenta resultados de simulações realizadas com um sistema teste de 7 barras e com parte do sistema Light.

TESTES E RESULTADOS

6.1 Introdução

Neste capítulo serão apresentados e discutidos os resultados de simulações realizadas, utilizando a metodologia proposta para o sistema de 7 barras e para parte do sistema Light.

Deve-se enfatizar que são usadas entradas binárias, assumindo-se que sob condições normais de operação, quando nenhum alarme está ativado, todas as variáveis de entrada possuem valor igual a zero. Quando da ocorrência de um distúrbio, alarmes são enviados ao centro de operação e as variáveis de entrada associadas aos mesmos são ativadas, fazendo-se iguais a 1.

O número de neurônios de saída para cada rede *neuro-fuzzy* corresponde ao número de componentes supervisionados.

6.1.1 Treinamento das RNFs

O conjunto de treinamento para cada rede contém exemplares que representam diversos padrões de alarme, incluindo casos nos quais o sistema de proteção apresentou falhas. Esses exemplares foram obtidos com ajuda do especialista de proteção e de casos históricos da operação do sistema.

Como foi mencionado anteriormente, a saída de cada neurônio fornece o grau de pertinência do padrão de alarme para os componentes monitorados. As saídas-alvo

fornecidas pela modelagem difusa foram usadas para cada neurônio de saída durante a fase de treinamento, sendo obtidas utilizando o modelo Hamacher, conforme apresentado no capítulo 4.

A implementação das redes neurais foi realizada utilizando-se rotinas do Neural Network Toolbox, ferramenta disponível no programa Matlab versão 5.1. As camadas de entrada e de saída de cada rede foram definidas em função dos números de variáveis e dos componentes supervisionados. Dentre as arquiteturas investigadas, aquelas com apenas uma camada oculta apresentaram os melhores resultados. O número de neurônios na camada oculta foi estabelecido de modo a que a razão entre o número de variáveis de entrada e o número de conexões (neurônios na camada oculta) estivesse entre 1,7 e 2,2, minimizando, assim, a possibilidade de super-especialização da rede [DB94].

O algoritmo de treinamento adotado foi o da retropropagação de erros (*backpropagation*), tendo sido utilizada uma taxa de aprendizado adaptativa. O modelo dos neurônios utilizou como função de ativação a função **logsigmóide**. O erro alvo foi de 0,01, tendo sido alcançado após 10000 épocas em média, sendo uma época um lote de padrões (cujo tamanho é pré-definido) extraído aleatoriamente do conjunto de treinamento. Durante o treinamento também foi utilizado o termo *momentum* igual a 0,9, com o qual a rede apresentou bons resultados.

O número de padrões de treinamento utilizado para cada rede nos sistemas de 7 barras e Light está ilustrado nas Tabelas 6.1 e 6.2, respectivamente. Também são apresentadas as arquiteturas adotadas.

Tabela 6.1 - Número de casos para treinamento - sistema 7 barras

<i>Sistema 7 barras</i>		<i>Arquitetura</i>		
<i>Rede Neuro-Fuzzy</i>	<i>Nº de casos para treinamento</i>	<i>Nº de entradas</i>	<i>Neurônios da camada escondida</i>	<i>Neurônios de saída</i>
RNF ₁	82	34	20	5
RNF ₂	137	40	20	5
RNF ₃	111	35	20	5

Tabela 6.2 - Número de casos para treinamento - sistema Light

<i>Sistema Light</i>		<i>Arquitetura</i>		
<i>Rede Neuro-Fuzzy</i>	<i>Nº de casos para treinamento</i>	<i>Nº de entradas</i>	<i>Neurônios da camada escondida</i>	<i>Neurônios de saída</i>
RNF ₁	176	48	24	4
RNF ₂	15	8	4	1
RNF ₃	152	38	20	2
RNF ₄	33	18	10	1
RNF ₅	182	48	25	4
RNF ₆	175	48	25	4
RNF ₇	125	62	30	4
RNF ₈	14	8	4	1
RNF ₉	84	28	15	2

Após o treinamento, as redes foram testados para um conjunto de padrões de alarme que incluíram casos com ruídos, perda de dados, situações de falha no sistema de proteção e outros casos que não fizeram parte do conjunto de treinamento. Estes padrões de alarme foram apresentados às redes e as saídas calculadas forneceram o grau de pertinência entre os componentes e os padrões de alarme para defeitos no sistema elétrico de potência.

6.2 Testes com o Sistema de 7 Barras

A metodologia proposta foi testada para o sistema elétrico de 7 barras. O algoritmo proposto foi testado para 40 padrões de alarme inéditos e alguns destes testes são agora apresentados para ilustrar a metodologia empregada.

Caso 1: Defeito na barra A sem reconhecimento da informação de abertura do disjuntor A-E

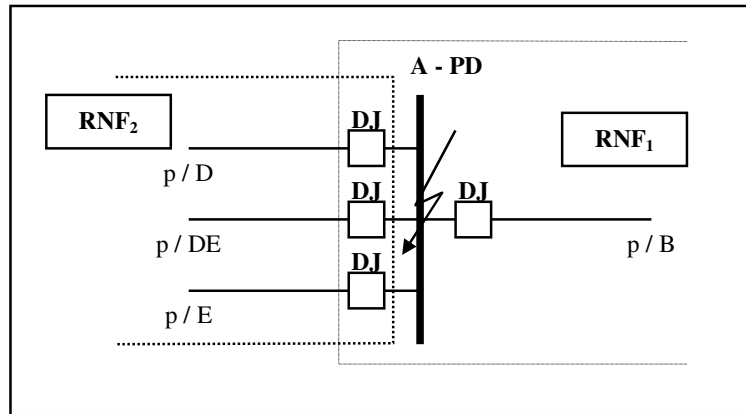


Figura 6.1 - Defeito na Barra A

Alarmes ativados:

- 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. Entre os alarmes ativados existem variáveis de entrada para as RNF₁ e RNF₂, responsáveis pela localização de defeitos nas áreas 1 e 2, respectivamente. De acordo com a metodologia proposta estas redes são selecionados, e os resultados obtidos são apresentados na Tabela 6.3.

Tabela 6.3 - Caso 1 (7 barras) - Graus de pertinência obtidos

RNF ₁					RNF ₂				
(1)	(2)	(3)	(4)	(5)	(1)	(2)	(3)	(4)	(5)
A-B	B-C	Barra A	Barra B	Barra C	A-D	A-D-E	A-E	Barra D	Barra E
0,1195	0,0327	0,9713	0,0161	0,0000	0,0807	0,2224	0,0212	0,2132	0,0000

Os resultados apresentados na Tabela 6.3 mostram que a RNF₁ identificou corretamente a localização do defeito na Barra A. Pode também ser notado que a RNF₂

forneceu graus de pertinência muito pequenos com respeito ao grau de pertinência da Barra A apresentado pela RNF_1 . A precisão da classificação foi preservada mesmo na ausência da informação de abertura do disjuntor da Linha A-E. É importante notar que essa situação pode refletir dois diferentes cenários: a informação do disjuntor não está disponível devido a problema de comunicação ou a linha A-E está fora de serviço. Este último ilustra uma habilidade em lidar com diferentes topologias da rede elétrica. Assim, segundo o processo de diagnóstico apresentado na seção 5.5, a Barra A é identificada como o componente com defeito.

Caso 2: Defeito na Barra C com falha do disjuntor da linha C-F

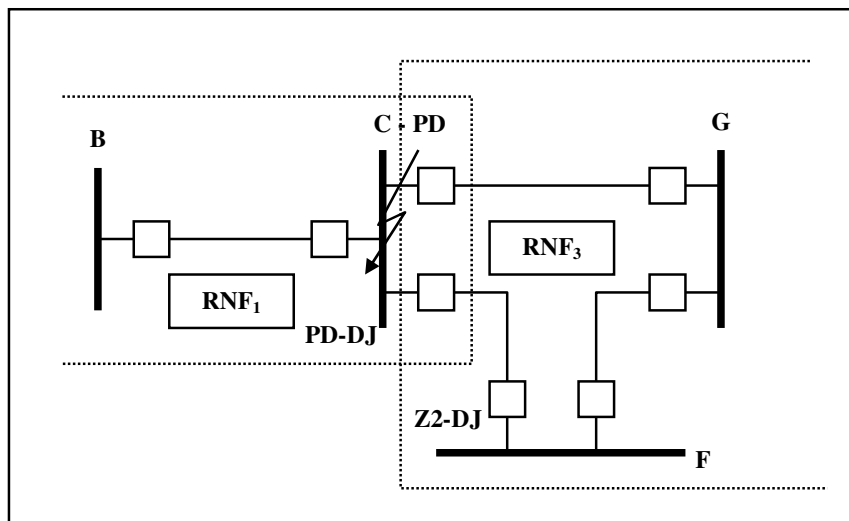


Figura 6.2 - Defeito na Barra C

Alarmes ativados:

- Barra C: PD e DJ
- Linha C-F terminal F: Z2, DJ

Nesta situação não houve atuação do disjuntor da linha C-F, no terminal C, atuando a proteção de retaguarda temporizada do terminal remoto F da linha. De acordo com a metodologia proposta a RNF_1 e a RNF_3 são selecionados. Os resultados da execução dessas redes estão resumidas na Tabela 6.4.

Tabela 6.4 - Caso 2 (7 barras) - Graus de pertinência obtidos

RNF ₁					RNF ₃				
(1)	(2)	(3)	(4)	(5)	(1)	(2)	(3)	(4)	(5)
A-B	B-C	Barra A	Barra B	Barra C	C-F	C-G	F-G	Barra F	Barra G
0,0704	0,0789	0,0000	0,0000	0,9637	0,1358	0,1700	0,0000	0,0000	0,0000

Os resultados apresentados na Tabela 6.4 mostram que a RNF₁ identificou corretamente a localização do defeito na barra C, enquanto a RNF₃ forneceu graus de pertinência menores que a dada pela RNF₁. Portanto, de acordo com o processo de diagnóstico mostrado na seção 5.5, identifica-se o defeito na barra C.

Caso 3: Defeito na linha B-C com falha da proteção do terminal C

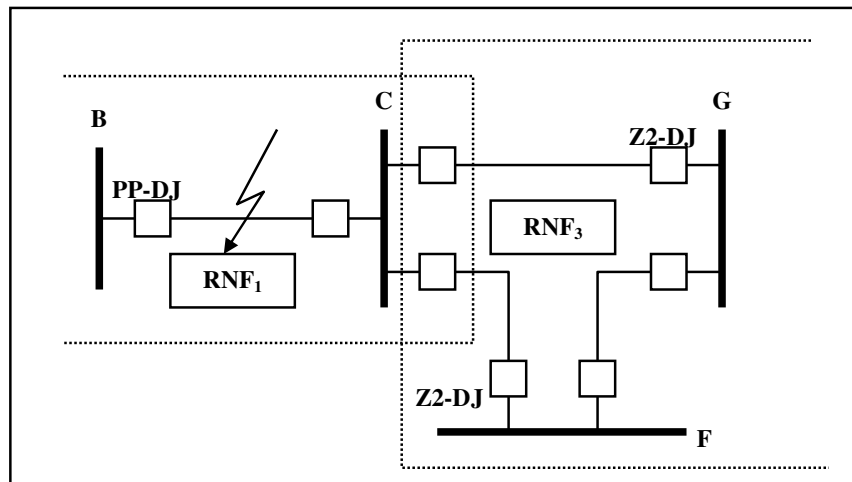


Figura 6.3 - Defeito na Linha B-C

Alarmes ativados:

- Linha B-C terminal B: PP, DJ
- Linha C-F terminal F: Z2, DJ
- Linha C-G terminal G: Z2, DJ

Neste caso ocorreu falha de proteção do terminal C da linha B-C, tendo atuado as proteções de retaguarda dos terminais remotos das linhas C-F e C-G. De acordo com a

metodologia proposta as RNF₁ e RNF₃ são selecionadas. Os resultados obtidos após a execução do metodologia, são apresentados na Tabela 6.5.

Tabela 6.5 - Caso 3 (7 barras) - Graus de pertinência obtidos

RNF ₁					RNF ₃				
(1)	(2)	(3)	(4)	(5)	(1)	(2)	(3)	(4)	(5)
A-B	B-C	Barra A	Barra B	Barra C	C-F	C-G	F-G	Barra F	Barra G
0,0000	0,8734	0,0000	0,0000	0,4232	0,4273	0,4923	0,0000	0,0000	0,0045

Os resultados da Tabela 6.5 mostram que a RNF₁ sinalizou corretamente o defeito na linha B-C, enquanto que a RNF₃ forneceu graus de pertinência menores que a dada pela RNF₁. Este caso apresenta um cenário onde houve falta de proteção cuja causa pode ser uma abertura do circuito de disparo (*trip*), bobina de abertura do disjuntor queimada ou o mais improvável uma falha de coordenação da proteção.

Caso 4: Defeito na barra C com falha dos disjuntores correspondentes

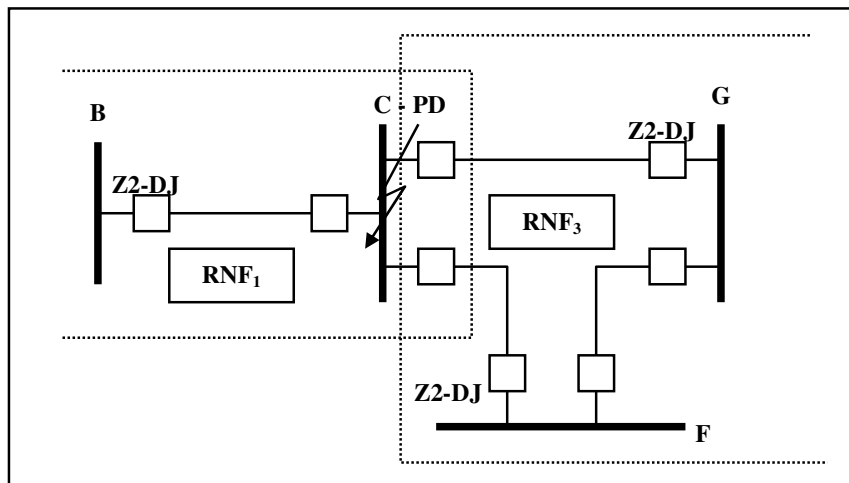


Figura 6.4 - Defeito na Barra C

Alarmes ativados:

- Barra C: PD
- Linha B-C terminal B: Z2, DJ
- Linha C-F terminal F: Z2, DJ
- Linha C-G terminal G: Z2, DJ

Neste caso ocorreu falha de proteção dos disjuntores associados à barra C, tendo atuado as proteções de retaguarda dos terminais remotos das linhas B-C, C-F e C-G. De acordo com a metodologia proposta as RNF₁ e RNF₃ são selecionadas. Os resultados obtidos após a execução do metodologia, são apresentados na Tabela 6.6.

Tabela 6.6 - Caso 4 (7 barras) - Graus de pertinência obtidos

RNF ₁					RNF ₃				
(1)	(2)	(3)	(4)	(5)	(1)	(2)	(3)	(4)	(5)
A-B	B-C	Barra A	Barra B	Barra C	C-F	C-G	F-G	Barra F	Barra G
0,0042	0,2932	0,0377	0,0000	0,7104	0,6620	0,6890	0,0415	0,0000	0,0000

Os resultados da Tabela 6.6 mostram que a RNF₁ sinalizou corretamente o defeito na barra C, enquanto que a RNF₃ forneceu graus de pertinência para a linha C-F e C-G um tanto perto do fornecido pela RNF₁. Pode-se concluir que o defeito localiza-se na barra C.

Caso 5: Defeito na linha C-G com falha da proteção do terminal C

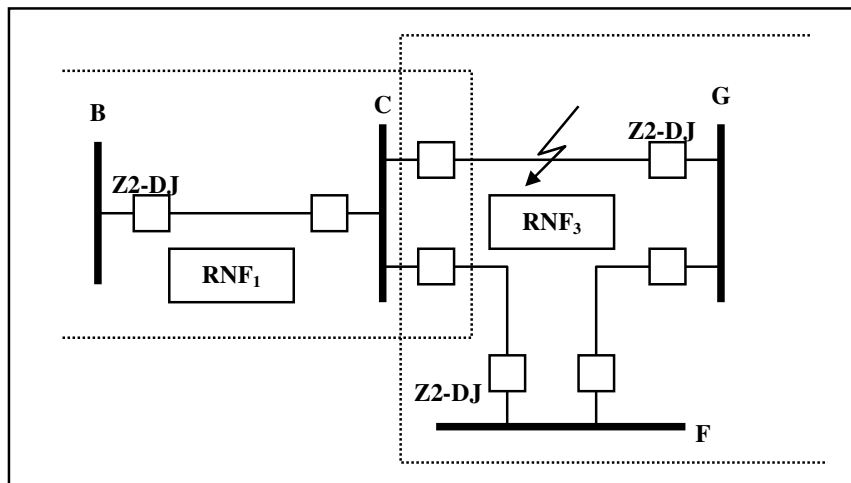


Figura 6.5 - Defeito na Linha C-G

Alarmes ativados:

- Linha B-C terminal B: Z2, DJ
- Linha C-F terminal F: Z2, DJ
- Linha C-G terminal G: Z2, DJ

Neste caso ocorreu um defeito na linha C-G e a proteção do terminal C não operou, vindo a atuar a proteção de 2ª linha dos terminais remotos da linha B-C e C-F. De acordo com a metodologia proposta as RNF₁ e RNF₃ são selecionadas. Os resultados obtidos após a execução do metodologia, são apresentados na Tabela 6.7.

Tabela 6.7 - Caso 5 (7 barras) - Graus de pertinência obtidos

RNF ₁					RNF ₃				
(1)	(2)	(3)	(4)	(5)	(1)	(2)	(3)	(4)	(5)
A-B	B-C	Barra A	Barra B	Barra C	C-F	C-G	F-G	Barra F	Barra G
0,0218	0,1350	0,1354	0,0000	0,3503	0,6620	0,6890	0,0415	0,0000	0,0000

Os resultados da Tabela 6.7 mostram que a RNF₃ apresentou graus de pertinência um tanto próximos entre as linhas C-F e C-G, com uma vantagem pequena da linha C-G, enquanto que a RNF₁ forneceu graus de pertinência menores que a dada pela RNF₃. Pode-se concluir que o defeito localiza-se na linha C-G.

A tabela 6.8 apresenta o desempenho global do método para várias simulações com o sistema elétrico de 7 barras. Como pode ser observado, o método proposto apresentou um excelente desempenho. Os casos analisados são inéditos (não apresentados durante o treinamento), e estão associados a falhas dos dispositivos de proteção ou perda de sinais de alarmes importantes.

Tabela 6.8 - Desempenho global para o sistema 7 barras

<i>Número de padrões de alarmes testados</i>	92
Diagnósticos Corretos - DC	96,74%
Diagnósticos Incorretos - DI	3,26%

É também importante salientar que o esforço computacional para a tarefa de localização, através das RNFs treinadas, pode ser considerado desprezível.

6.3 Testes com o Sistema Light

O método foi também testado em parte do sistema da Light. O modelo proposto foi submetido a 195 padrões de alarme inéditos. Assim como para o sistema 7 barras, são apresentados a seguir alguns testes escolhidos para ilustrar a metodologia empregada.

Caso 1: Defeito na Linha FCN-GRA-2

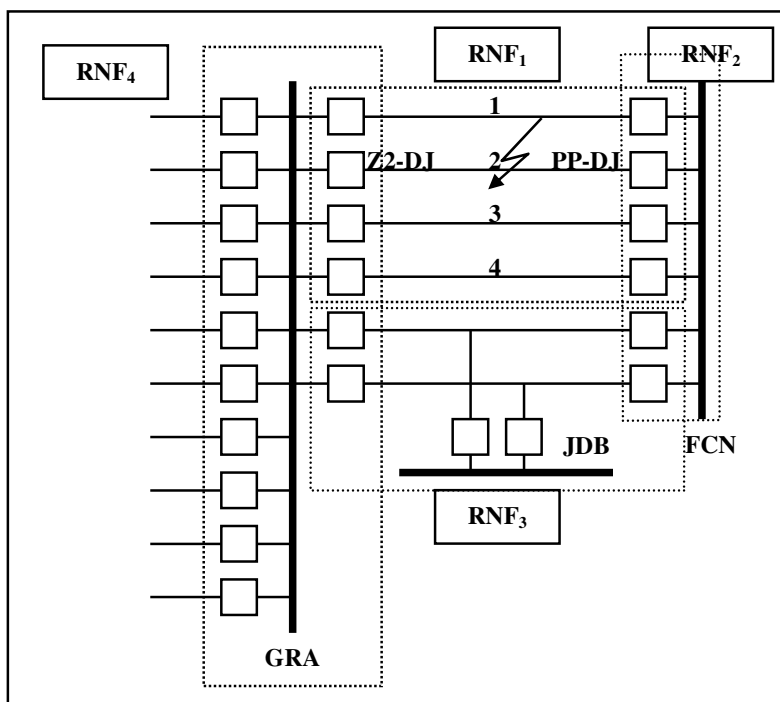


Figura 6.6 - Defeito na Linha FCN-GRA-2

Alarmes ativados:

- Linha FCN-GRA-2 terminal GRA: Z2 e DJ
- Linha FCN-GRA-2 terminal FCN: PP e DJ

De acordo com a metodologia proposta as RNFs selecionadas foram as RNF₁, RNF₂, RNF₃, e RNF₄. Os resultados obtidos após a execução destas redes são apresentados na Tabela 6.9.

Tabela 6.9 - Caso 1 (Light) - Graus de pertinência obtidos

RNF ₁				RNF ₂	RNF ₃		RNF ₄
(1)	(2)	(3)	(4)	(1)	(1)	(2)	(1)
FCN-GRA 1	FCN-GRA 2	FCN-GRA 3	FCN-GRA 4	Barra FCN	FCN-GRA-JDB 1	FCN-GRA-JDB 2	Barra GRA
0,0027	0,7485	0,0002	0,0051	0,3747	0,0240	0,0523	0,0583

Pode-se concluir que RNF₁ localizou corretamente o defeito na linha FCN-GRA-2. As demais RNFs apresentaram graus de pertinência menores. Portanto o diagnóstico indica defeito na linha FCN-GRA-2.

Caso 2: Defeito na linha FCN-GRA-2 com falha do disjuntor do terminal GRA

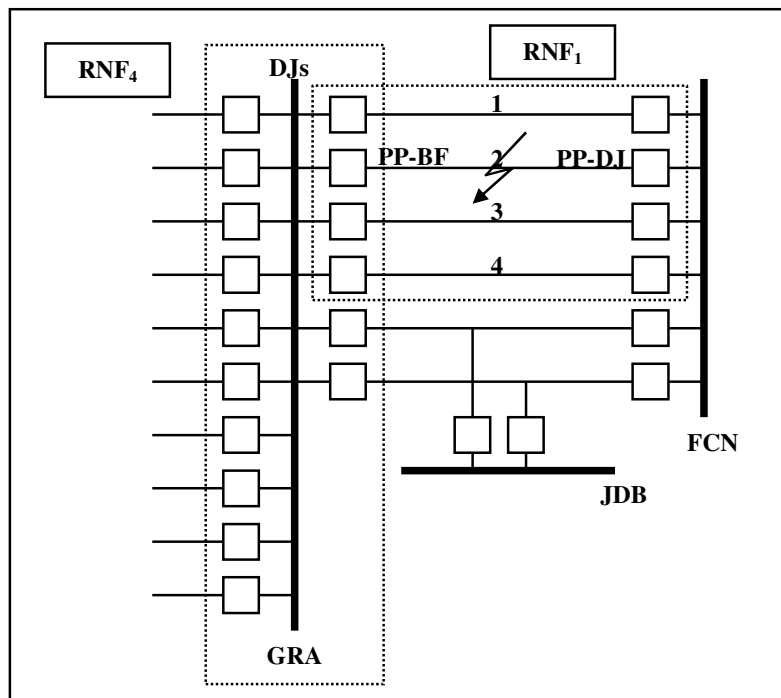


Figura 6.7 - Defeito na Linha FCN-GRA-2

Alarmes ativados:

- Linha FCN-GRA-2 terminal FCN: PP e DJ
- Linha FCN-GRA-2 terminal GRA: PP e BF
- Barra GRA: DJ's (todos os disjuntores da barra exceto da linha FCN-GRA-2)

Neste caso, atuaram os relés da proteção principal em ambos terminais, porém houve falta na abertura do disjuntor do terminal de GRA. Com o intuito de eliminar o defeito que ocorreu na atuação da proteção para falha de disjuntor, abrindo todos os disjuntores da Barra GRA. De acordo com a metodologia proposta as RNFs selecionadas foram as RNF₁, RNF₄, RNF₅, RNF₆, RNF₇. Os resultados obtidos após a execução destas redes são apresentados na Tabela 6.10.

Tabela 6.10 - Caso 2 (Light) - Graus de pertinência obtidos

RNF ₁				RNF ₄	RNF ₅			
(1)	(2)	(3)	(4)	(1)	(1)	(2)	(3)	(4)
FCN-GRA 1	FCN-GRA 2	FCN-GRA 3	FCN-GRA 4	Barra GRA	TSU-GRA 1	TSU-GRA 2	TSU-GRA 3	TSU-GRA 4
0,0000	0,9676	0,0017	0,0015	0,0178	0,0501	0,0400	0,0000	0,1443

RNF ₆				RNF ₇			
(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)
CCD-GRA 1	CCD-GRA 2	CCD-GRA 3	CCD-GRA 4	CCD-JP-GRA 1	CCD-JP-GRA 2	JP-VVQ 1	JP-VVQ 2
0,1610	0,0921	0,0086	0,1308	0,0232	0,0583	0,0004	0,0000

Os resultados mostraram que a RNF₁ identificou corretamente o componente defeituoso e que as demais RNF's forneceram graus de pertinência muito menores à oferecida pela RNF₁. O diagnóstico final, portanto, indica defeito na linha FCN-GRA-2.

Caso 3: Defeito na linha TSU-GRA-1 com falha de proteção do terminal TSU

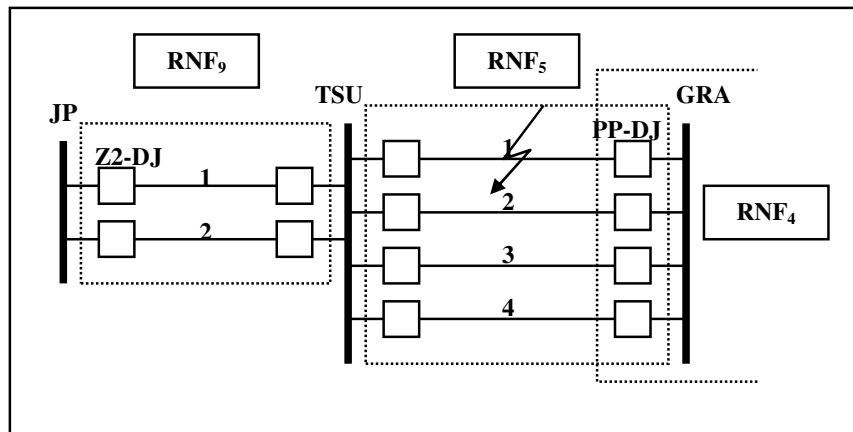


Figura 6.8 - Defeito na Linha TSU-GRA-1

Alarmes ativados:

- Linha TSU-GRA - 1 terminal GRA: PP e DJ
- Linha TSU-GRA- 2, 3 e 4 terminal TSU: Z2 e DJ
- Linha TSU-JP-1 e 2 terminal JP: Z2 e DJ

Neste caso ocorreu um defeito na linha TSU-GRA-1 e a proteção do terminal TSU não operou, vindo a atuar a proteção de 2ª linha dos terminais remotos de GRA e JP. De acordo com a metodologia proposta RNF₄, RNF₅ e RNF₉ foram selecionados. Os resultados obtidos após a execução das redes são apresentados na Tabela 6.11.

Tabela 6.11 - Caso 3 (Light) - Graus de pertinência obtidos

RNF₄	RNF₅				RNF₉	
(1)	(1)	(2)	(3)	(4)	(1)	(2)
Barra GRA	TSU-GRA 1	TSU-GRA 2	TSU-GRA 3	TSU-GRA 4	TSU-JP 1	TSU-JP 2
0,4288	0,9768	0,5658	0,5681	0,5711	0,7267	0,5542

Os resultados mostraram que a RNF₅ diagnosticou corretamente o defeito, e as outras RNFs mostraram graus de pertinência menores. Assim, pode-se diagnosticar finalmente que o defeito ocorreu na linha TSU-GRA-1.

Caso 4: Defeito na Barra FCN com falha do disjuntor da Linha FCN-GRA-2

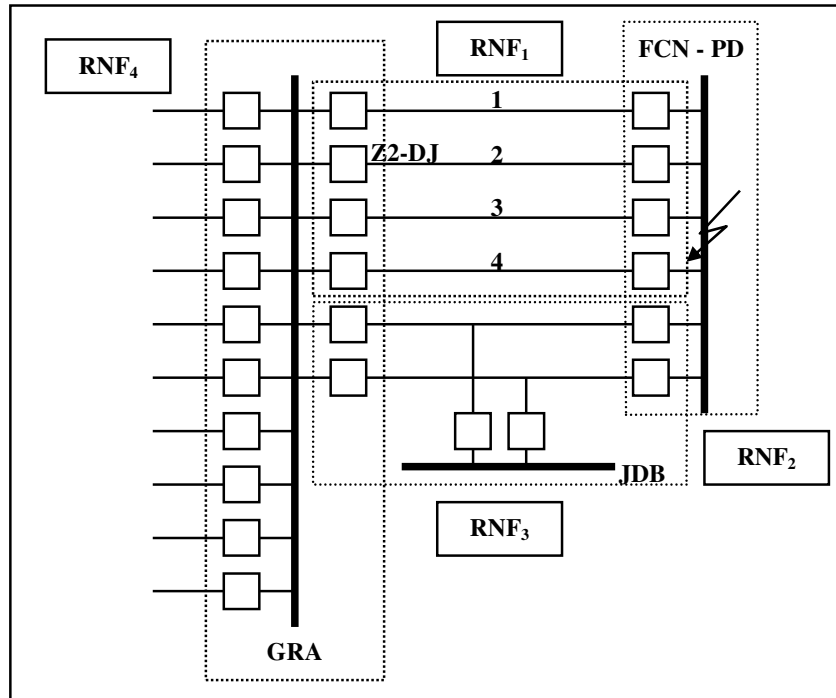


Figura 6.9 - Defeito na Barra FCN

Alarmes ativados:

- Barra FCN: PD e DJs
- Linha FCN-GRA-2 terminal GRA: Z2 e DJ

Neste caso, ocorreu uma falha na abertura do disjuntor da linha FCN-GRA-2, assim para minimizar os danos a proteção de retaguarda da linha FCN-GRA-2. Com o intuito de eliminar o defeito ocorreu a proteção de retaguarda da mesma linha. De acordo com a metodologia proposta as RNFs selecionadas foram as RNF₁, RNF₂, RNF₃, e RNF₄. Os resultados obtidos após a execução destas redes são apresentados na Tabela 6.13.

Tabela 6.12 - Caso 4 (Light) - Graus de pertinência obtidos

RNF ₁				RNF ₂	RNF ₃		RNF ₄
(1)	(2)	(3)	(4)	(1)	(1)	(2)	(1)
FCN-GRA 1	FCN-GRA 2	FCN-GRA 3	FCN-GRA 4	Barra FCN	FCN-GRA-JDB 1	FCN-GRA-JDB 2	Barra GRA
0,3038	0,3388	0,3021	0,3052	0,9750	0,0577	0,0766	0,0583

Os resultados mostraram que a RNF₂ identificou corretamente o componente defeituoso e que as demais RNF's forneceram graus de pertinência muito menores à oferecida pela RNF₂. O diagnóstico final, portanto, indica defeito na linha Barra FCN.

Caso 5: Defeito na linha TSU-GRA-1 com atuação indevida da proteção da linha GRA-FCN-2

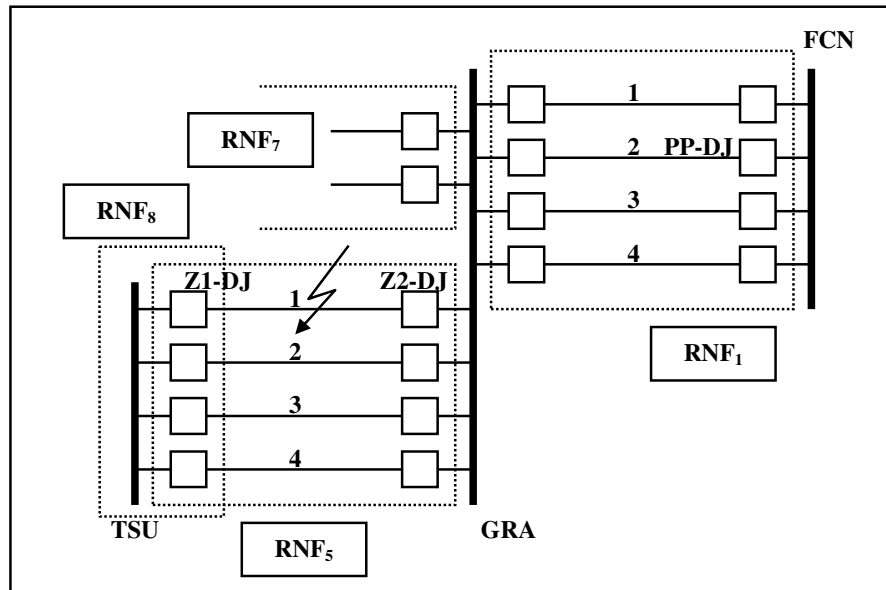


Figura 6.10 - Defeito na Linha TSU-GRA-1

Alarmes ativados:

- Linha TSU-GRA-1 terminal TSU: Z1 e DJ
- Linha TSU-GRA-1 terminal GRA: Z2 e DJ
- Linha FCN-GRA-2 terminal FCN: PP e DJ

Neste caso ocorreu uma atuação indevida do terminal remoto de uma linha adjacente. De acordo com a metodologia proposta a RNF₁, RNF₂ e RNF₅ foram selecionadas. Os resultados obtidos após a execução destas redes são apresentados na Tabela 6.13.

Tabela 6.13 - Caso 5 (Light) - Graus de pertinência obtidos

RNF ₁				RNF ₂	RNF ₅			
(1)	(2)	(3)	(4)	(1)	(1)	(2)	(3)	(4)
FCN-GRA 1	FCN-GRA 2	FCN-GRA 3	FCN-GRA 4	BARRA FCN	TSU-GRA 1	TSU-GRA 2	TSU-GRA 3	TSU-GRA 4
0,2653	0,2558	0,0071	0,0000	0,3747	0,8681	0,0007	0,0000	0,0000

Os resultados mostraram que a RNF₅ identificou corretamente o componente faltoso. A rede RNF₁ e RNF₂ forneceram graus de pertinência baixos com respeito a RNF₁. Conforme o critério da seção 5.5, o diagnostico final indica um defeito na linha TSU-GRA-1.

Caso 6: Defeito na Linha FCN-GRA-JDB-1 com falha da proteção do terminal FCN

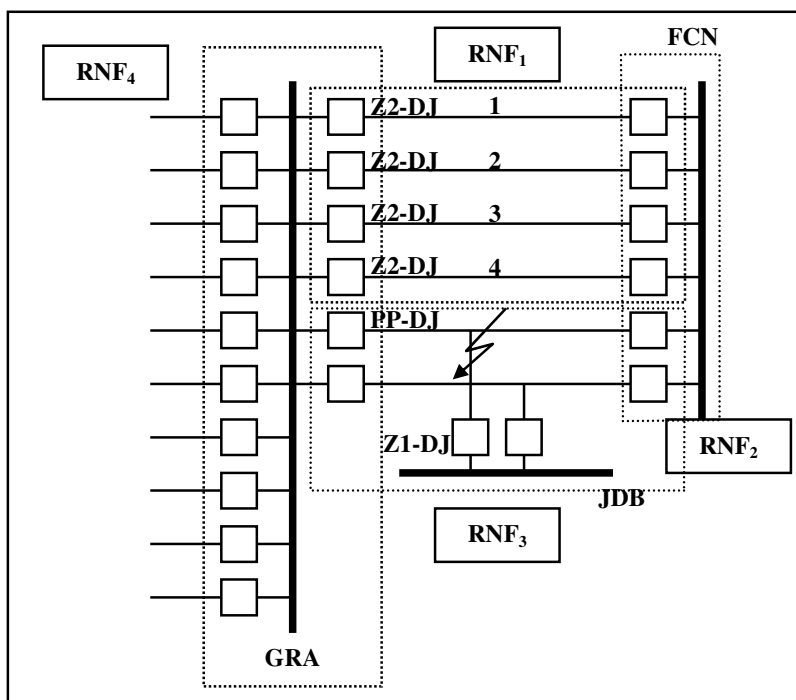


Figura 6.11 - Defeito na Linha FCN-GRA-JDB-1

Alarmes ativados:

- Linha FCN-GRA-JDB-1 terminal GRA: PP e DJ
- Linha FCN-GRA-JDB-1 terminal JDB: Z1 e DJ
- Linha FCN-GRA- 1, 2, 3 e 4 terminal GRA: Z2 e DJ
- Linha FCN-GRA-JDB-2 terminal GRA e JDB: Z2 e DJ

Neste caso ocorreu uma falha no terminal FCN da linha, sendo o defeito eliminado pelas proteções de retaguarda dos terminais remotos das linhas adjacentes. De acordo com a metodologia proposta as RNFs selecionadas foram as RNF₁, RNF₂, RNF₃, e RNF₄. Os resultados obtidos após a execução destas redes são apresentados na Tabela 6.14.

Tabela 6.14 - Caso 6 (Light) - Graus de pertinência obtidos

RNF ₁				RNF ₂	RNF ₃		RNF ₄
(1)	(2)	(3)	(4)	(1)	(1)	(2)	(1)
FCN-GRA 1	FCN-GRA 2	FCN-GRA 3	FCN-GRA 4	Barra FCN	FCN-GRA-JDB 1	FCN-GRA-JDB 2	Barra GRA
0,7962	0,8463	0,6049	0,7489	0,3263	0,9765	0,7533	0,4467

Os resultados mostraram que a RNF₃ diagnosticou corretamente o componente faltoso. As demais redes forneceram graus de pertinência menores. Conforme o critério da seção 5.5, o diagnostico final indica que o defeito está na linha FCN-GRA-JDB-1.

Caso 7: Defeito na Linha FCN-GRA- 4 com ausência de sinal

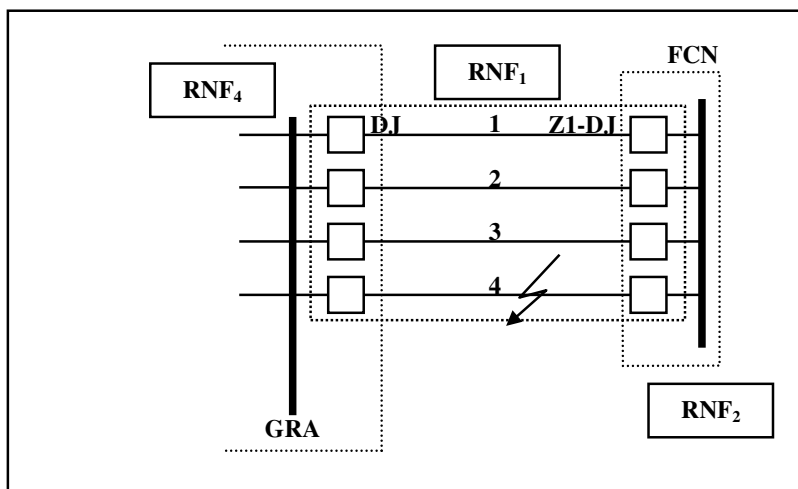


Figura 6.12 - Defeito na Linha FCN-GRA-4

Alarmes ativados:

- Linha FCN-GRA-4 terminal FCN: Z1 e DJ
- Linha FCN-GRA-4 terminal GRA: DJ

Neste caso houve uma ausência de sinal do relé relacionados ao terminal GRA. De acordo com a metodologia proposta as RNFs selecionadas foram as RNF₁, RNF₂, RNF₃, e RNF₄. Os resultados obtidos após a execução destas redes são apresentados na Tabela 6.15.

Tabela 6.15 - Caso 7 (Light) - Graus de pertinência obtidos

RNF ₁				RNF ₂	RNF ₃		RNF ₄
(1)	(2)	(3)	(4)	(1)	(1)	(2)	(1)
FCN-GRA 1	FCN-GRA 2	FCN-GRA 3	FCN-GRA 4	Barra FCN	FCN-GRA-JDB 1	FCN-GRA-JDB 2	Barra GRA
0,0000	0,0000	0,1081	0,8942	0,3664	0,1024	0,0000	0,5724

Neste caso, é identificado corretamente o defeito pela RNF₁. Assim pode-se concluir que o diagnóstico final indica uma falha do componente FCN-GRA-4.

Caso 8: Defeito na Linha FCN-GRA- 1 com atuação indevida da proteção principal de uma linha adjacente

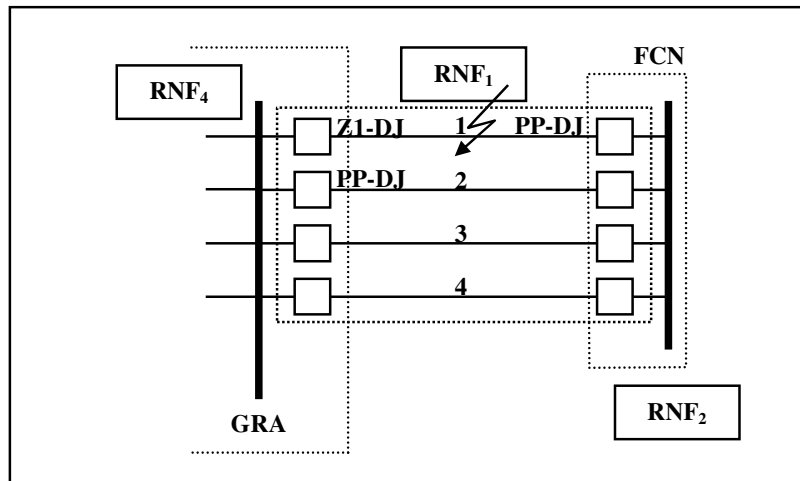


Figura 6.13 - Defeito na Linha FCN-GRA-1

Alarmes ativados:

- Linha FCN-GRA-1 terminal FCN: PP e DJ
- Linha FCN-GRA-1 terminal GRA: Z1 e DJ
- Linha FCN-GRA-2 terminal GRA: PP e DJ

Neste caso houve uma atuação indevida da linha adjacente FCN-GRA-1. De acordo com a metodologia proposta as RNFs selecionadas foram as RNF₁, RNF₂, RNF₃, e RNF₄. Os resultados obtidos após a execução destas redes são apresentados na Tabela 6.16.

Tabela 6.16 - Caso 8 (Light) - Graus de pertinência obtidos

RNF ₁				RNF ₂	RNF ₃		RNF ₄
(1)	(2)	(3)	(4)	(1)	(1)	(2)	(1)
FCN-GRA 1	FCN-GRA 2	FCN-GRA 3	FCN-GRA 4	Barra FCN	FCN-GRA-JDB 1	FCN-GRA-JDB 2	Barra GRA
0,8536	0,3525	0,0000	0,0000	0,4476	0,0435	0,0284	0,2915

Neste caso, é identificado corretamente o defeito pela RNF₁. Assim pode-se concluir que o diagnóstico final indica uma falha do componente FCN-GRA-1.

Caso 9: Defeito na Barra TSU com falha do disjuntor da linha TSU-JP-1

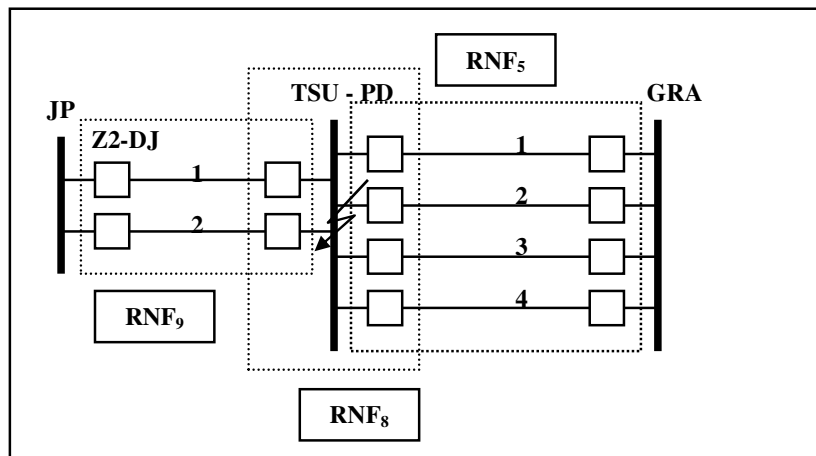


Figura 6.14 - Defeito na Barra TSU

Alarmes ativados:

- Barra TSU: PD e DJs
- Linha TSU-JP-1 terminal JP: Z2

Neste caso ocorreu um falha de um disjuntor da barra. De acordo com a metodologia proposta RNF₅, RNF₈, e RNF₉ foram selecionados. Os resultados obtidos após a execução das redes são apresentados na Tabela 6.17.

Tabela 6.17 - Caso 9 (Light) - Graus de pertinência obtidos

RNF ₅				RNF ₈	RNF ₉	
(1)	(2)	(3)	(4)	(1)	(1)	(2)
TSU-GRA 1	TSU-GRA 2	TSU-GRA 3	TSU-GRA 4	Barra TSU	TSU-JP 1	TSU-JP 2
0,0528	0,0000	0,0000	0,0022	0,9537	0,3394	0,3038

A RNF₈ forneceu um grau de pertinência alto para a Barra TSU. Assim pode-se concluir que o diagnóstico final é uma falha da Barra TSU.

Caso 10: Defeito na linha TSU-GRA-4 com falha da proteção em ambos os terminais

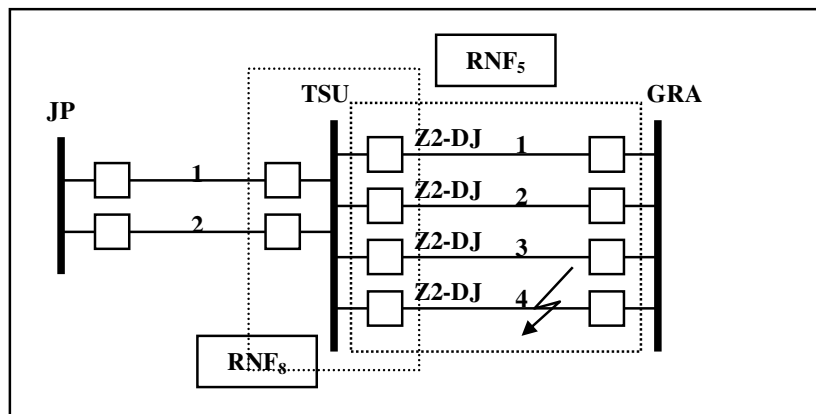


Figura 6.15 - Defeito na Linha TSU-GRA-4

Alarmes ativados:

- Linha GRA-TSU-1,2, 3 e 4 terminal TSU: Z2 e DJ
- Linha GRA-CCD-JP-1 e 2 terminais JP e CCD: Z2 e DJ
- Linha GRA-CCD- 1, 2, 3 e 4 terminal CCD: Z2 e DJ

Neste caso ocorreu um defeito na linha TSU-GRA-4, com falha no terminal GRA, sendo o defeito eliminado pelas proteções de retaguarda dos terminais remotos das linhas CCD-GRA e GRA-CCD-JP além dos terminais TSU das linhas TSU-GRA-1, 2 e 3. De

acordo com a metodologia proposta RNF₅, RNF₆, RNF₇ e RNF₈ foram selecionados. Os resultados obtidos após a execução das redes são apresentados na Tabela 6.18.

Tabela 6.18 - Caso 10 (Light) - Graus de pertinência obtidos

RNF ₅				RNF ₆			
(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)
TSU-GRA 1	TSU-GRA 2	TSU-GRA 3	TSU-GRA 4	GRA-CCD 1	GRA-CCD 2	GRA-CCD 3	GRA-CCD 4
0,9410	0,9237	0,9459	0,9185	0,2049	0,2563	0,1658	0,6405

RNF ₇				RNF ₈
(1)	(2)	(3)	(4)	(1)
CCD-JP-GRA 1	CCD-JP-GRA 2	JP-VVQ 1	JP-VVQ 2	Barra TSU
0,7495	0,7497	0,4279	0,1612	0,1770

Os resultados mostraram que a RNF₅ forneceu graus de pertinência maiores que as outras RNFs. Porém, neste caso pode-se diagnosticar que o defeito não foi corretamente localizado.

Entretanto, os graus de pertinência obtidos para os componentes TSU-GRA-1, TSU-GRA-2, TSU-GRA-3 e TSU-GRA-4 são muito próximos. É possível portanto estabelecer um critério de diagnóstico que observe um "empate" entre dois ou mais graus de pertinência. Para isto pode-se utilizar uma medida de distância entre as estimativas obtidas e compará-la com uma tolerância pré-especificada. A observação de um "empate" implicaria em uma nova classe de diagnóstico, que seria o Diagnóstico Indeterminado. Como subproduto deste diagnóstico tem-se um conjunto de elementos suspeitos. Para certos padrões de alarme tal diagnóstico é desejável, sendo o melhor que pode ser obtido. Esta classe de diagnóstico não foi considerada neste trabalho, embora na implementação seja trivial.

A tabela 6.19 apresenta o desempenho global do método para varias simulações com o sistema elétrico Light. Como pode ser observado, o método proposto apresentou

também um desempenho excelente, especialmente considerando a complexidade do sistema em questão.

Tabela 6.19 - Desempenho global para o sistema Light

<i>Número de padrões de alarmes testados</i>	140
Diagnósticos Corretos - DC	95%
Diagnósticos Incorretos - DI	5%

Como foi dito para o sistema de 7 barras, o esforço computacional para a tarefa de localização neste sistema complexo, através das RNFs treinadas, pode ser considerado desprezível.

O número de Diagnósticos Incorretos pode ainda ser reduzido se a obtenção de Diagnósticos Indeterminados, mencionado acima, for considerada.

CONCLUSÕES E TRABALHOS FUTUROS

7.1 Conclusões

A necessidade de preservar a continuidade de serviço e garantir a qualidade do fornecimento de energia aos consumidores conectados a um sistema de energia elétrica torna essencial a rapidez e a precisão na identificação de equipamentos defeituosos, após a ocorrência de distúrbios.

A obtenção de diagnósticos por operadores do sistema pode ser bastante complicada, mesmo quando se utilizam esquemas de hierarquização na apresentação dos alarmes recebidos e outras estratégias de interface. Esta dificuldade se deve ao fato de que, na ocorrência de distúrbios, o volume de informações a analisar pode ser muito grande. Além disso, a ocorrência de falhas na atuação do sistema de proteção pode tornar o problema ainda mais complexo. Aplicações de sistemas inteligentes, tais como sistemas especialistas e redes neurais, foram propostas ao longo da última década para o diagnóstico de defeitos em sistemas de potência. Dentre os problemas associados a estas aplicações, pode-se destacar a dificuldade em se tratar sistemas de grande porte e também padrões corrompidos (devido a falhas de comunicação e ruídos), que representam falhas no sistema de proteção.

Este trabalho apresentou uma metodologia que permite uma identificação rápida de equipamentos defeituosos em sistemas de potência, após a ocorrência de distúrbios. Esta metodologia é baseada na utilização de redes *neuro-fuzzy*, os quais permitem a introdução do conhecimento qualitativo sobre o problema e ao mesmo tempo apresenta características de robustez, tolerância a falhas e generalização. A utilização de diversas redes se deve ao fato de que a identificação de um componente defeituoso requer o conhecimento de apenas

um conjunto parcial de alarmes, em geral na vizinhança do componente. Assim, os sistemas para validação do modelo apresentado foram divididos em áreas, cada área englobando um conjunto de componentes. A cada área foi associada uma rede neural, que tem a função de supervisionar cada componente e fornecer, em caso de distúrbios, os graus de pertinência do padrão de alarme para os componentes monitorados. O modelo de rede neural utilizado foi o perceptron de múltiplas camadas, sendo o treinamento das redes realizado *offline*. Após a ocorrência de um distúrbio, as redes são testadas para os alarmes recebidos de modo a fornecer resultados em tempo-real. O diagnóstico final é obtido comparando os graus de pertinência das diferentes redes ativadas durante o distúrbio.

A metodologia proposta foi testada para um sistema de 7 barras e para o sistema da Light. Os resultados obtidos indicaram um excelente desempenho do método, tendo sido possível obter identificações corretas para padrões não utilizados durante o processo de treinamento, incluindo situações nas quais existe falha do sistema de proteção, ruídos, etc. É importante notar que, uma vez treinadas, as redes apresentam um tempo de execução que pode ser considerado desprezível.

7.2 Contribuições deste Trabalho

Este trabalho:

- apresentou uma modelagem difusa para a localização de defeitos em sistemas de potência, o qual foi aproveitado para o treinamento das redes *neuro-fuzzy*.
- abordou o problema de localização de defeitos como um problema de reconhecimento de padrões, tendo sido apresentados procedimentos *offline* para a construção de redes *neuro-fuzzy* capazes de identificar componentes submetidos a um defeito no sistema, a partir da observação do estado de relés de proteção e disjuntores.
- Apresentou uma metodologia que é capaz de permitir a introdução do conhecimento qualitativo sobre o problema tratado (lógica fuzzy) e ao mesmo tempo apresentar características de robustez, tolerância a falhas e generalização.

7.3 Propostas Para Trabalhos Futuros

Tendo em vista a continuação deste trabalho, pode-se sugerir a investigação dos seguintes tópicos:

- outros critérios para divisão do sistema em áreas, definição dos componentes supervisionados e informações externas observadas, visando reduzir ainda mais as taxas de erro de classificação.
- análise de outras famílias paramétricas para a modelagem difusa.
- exploração de outras arquiteturas e métodos de treinamento para a rede neural utilizada.
- alterações nos diagramas Sagitais para melhor representar as relações *fuzzy* entre padrões de alarme e componentes do sistema.

Apêndice A

MODELAGEM DIFUSA

A.1 Descrição

A tarefa de escolher o parâmetro adequado em cada modelo *fuzzy* baseia-se principalmente na simulação de casos nos dois sistemas testados. Essas simulações utilizaram diversos padrões de alarme no sistema. Nesta apêndice mostra-se alguns exemplares de simulação para os dois sistemas testados. Os resultados foram obtidos utilizando diferentes valores do parâmetro em cada modelo proposto.

A.2 Sistema de 7 barras

A Tabela A.1 mostra alguns exemplares de simulação para o sistema de 7 barras, cujos resultados serão apresentados a seguir para ilustrar as análises realizadas.

Tabela A.1 - Simulação de casos para o sistema de sete barras.

Tipo de Simulação	Alarmes Ativados
1.- Defeito na linha A-B	Terminal A - Z1 e DJ Terminal B - Z2 e DJ
2.- Defeito na Barra B	Barra B - PD e DJS
3.- Defeito na linha A-D com falha da proteção do terminal A	Terminal D - PP e DJ Terminal D - Z2 e DJ (Linha A-D-E) Terminal E - Z2 e DJ (Linha A-D-E) Terminal E - Z2 e DJ (Linha A-E) Terminal B - Z2 e DJ (Linha A-B)
4.- Defeito na linha A-D-E com falha da proteção do terminal A	Terminal D - PP e DJ Terminal E - Z1 e DJ Terminal D - Z2 e DJ (Linha A-D) Terminal E - Z2 e DJ (Linha A-E) Terminal B - Z2 e DJ (Linha A-B)
5.- Defeito na linha A- E com falha da proteção do terminal A	Terminal E - PP e DJ Terminal D - Z2 e DJ (Linha A-D-E) Terminal E - Z2 e DJ (Linha A-D-E) Terminal D - Z2 e DJ (Linha A-D) Terminal B - Z2 e DJ (Linha A-B)
6.- Defeito na Barra B com atuação indevida da proteção do terminal remoto da linha A-B	Barra B - PD e DJS. Terminal A - PP e DJ (Linha A-B)

A partir das informações sobre a atuação dos relés e disjuntores fornecidas pela simulação de casos, como na Tabela A.1, pode-se proceder a obtenção das relações fuzzy com os componentes do sistema, utilizando os respectivos diagrama Sagitais. A seguir, para cada modelo são mostrados os resultados dos casos, descritos na Tabela A.1, tendo em conta variações no valor do parâmetro do modelo.

Modelo Hamacher: Para este modelo foram testados diferentes valores do parâmetro γ . A seguir são mostrados alguns dos resultados do diagnóstico difuso, com seus respectivos valores de γ . Deve-se ter em conta que os resultados são graus de pertinência do padrão de alarmes para as classes (componentes do sistema).

Tabela A.2 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma = 3$.

Casos	$\gamma = 3$ e $\gamma' = 2$ ($\gamma' = \gamma - 1$)											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,8615	0,0000	0,0000	0,0000	0,3031	0,3031	0,3031	0,3031	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,9036	0,0000	0,0000	0,0000
3	0,9093	0,0000	0,0000	0,0000	0,9739	0,9171	0,9093	0,9008	0,0000	0,0000	0,3031	0,3031
4	0,8062	0,0000	0,0000	0,0000	0,8062	0,9921	0,8062	0,7894	0,0000	0,0000	0,0000	0,0000
5	0,9093	0,0000	0,0000	0,0000	0,9093	0,9171	0,9739	0,9008	0,0000	0,0000	0,3031	0,3031
6	0,5000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,9036	0,0000	0,0000	0,0000

Tabela A.3 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma = 4$.

Casos	$\gamma = 4$ e $\gamma' = 3$ ($\gamma' = \gamma - 1$)											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,8639	0,0000	0,0000	0,0000	0,2740	0,2740	0,2740	0,2740	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,9110	0,0000	0,0000	0,0000
3	0,9150	0,0000	0,0000	0,0000	0,9785	0,9230	0,91500	0,9063	0,0000	0,0000	0,2740	0,2740
4	0,8054	0,0000	0,0000	0,0000	0,8054	0,9942	0,8054	0,7873	0,0000	0,0000	0,0000	0,0000
5	0,9150	0,0000	0,0000	0,0000	0,9150	0,9230	0,9785	0,9063	0,0000	0,0000	0,2740	0,2740
6	0,4746	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,9110	0,0000	0,0000	0,0000

Tabela A.4 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma = 5$.

Casos	$\gamma = 5$ e $\gamma' = 4$ ($\gamma' = \gamma - 1$)											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,8641	0,0000	0,0000	0,0000	0,2500	0,2500	0,2500	0,2500	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,9155	0,0000	0,0000	0,0000
3	0,9174	0,0000	0,0000	0,0000	0,9810	0,9256	0,9174	0,9084	0,0000	0,0000	0,2500	0,2500
4	0,8016	0,0000	0,0000	0,0000	0,8016	0,9953	0,8016	0,7823	0,0000	0,0000	0,0000	0,0000
5	0,9174	0,0000	0,0000	0,0000	0,9174	0,9256	0,9810	0,9084	0,0000	0,0000	0,2500	0,2500
6	0,4516	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,9155	0,0000	0,0000	0,0000

Foi possível concluir que os resultados obtidos com os diferentes valores para o parâmetro γ são competitivos, com leve vantagem para $\gamma=5$.

Modelo Yager: Para este modelo foram testados diferentes valores do parâmetro p . A seguir são mostrados alguns dos resultados do diagnóstico difuso, com seus respectivos valores de p .

Tabela A.5 - Resultados do diagnóstico difuso com o modelo Yager para $p = 1$.

Casos	$p = 1$											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	1,0000	0,0000	0,0000	0,0000	0,2500	0,2500	0,2500	0,2500	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	1,0000	0,0000	0,0000	0,0000
3	1,0000	0,0000	0,0000	0,0000	1,0000	1,0000	1,0000	1,0000	0,0000	0,0000	0,2500	0,2500
4	0,8000	0,0000	0,0000	0,0000	0,8000	1,0000	0,8000	0,7500	0,0000	0,0000	0,0000	0,0000
5	1,0000	0,0000	0,0000	0,0000	1,0000	1,0000	1,0000	1,0000	0,0000	0,0000	0,2500	0,2500
6	0,5000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	1,0000	0,0000	0,0000	0,0000

Tabela A.6 - Resultados do diagnóstico difuso com o modelo Yager para $p = 2$.

Casos	$p = 2$											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,9235	0,0000	0,0000	0,0000	0,4592	0,4592	0,4592	0,4592	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,9670	0,0000	0,0000	0,0000
3	0,9394	0,0000	0,0000	0,0000	1,0000	0,9600	0,9394	0,9183	0,0000	0,0000	0,4592	0,4592
4	0,8196	0,0000	0,0000	0,0000	0,8196	1,0000	0,8196	0,7953	0,0000	0,0000	0,0000	0,0000
5	0,9394	0,0000	0,0000	0,0000	0,9394	0,9600	1,0000	0,9183	0,0000	0,0000	0,4592	0,4592
6	0,6394	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,9670	0,0000	0,0000	0,0000

Tabela A.7 - Resultados do diagnóstico difuso com o modelo Yager para $p = 3$.

Casos	$p = 3$											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,8721	0,0000	0,0000	0,0000	0,5093	0,5093	0,5093	0,5093	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8773	0,0000	0,0000	0,0000
3	0,8257	0,0000	0,0000	0,0000	0,9010	0,8422	0,8257	0,8085	0,0000	0,0000	0,5093	0,5093
4	0,7553	0,0000	0,0000	0,0000	0,7553	1,0000	0,7553	0,7346	0,0000	0,0000	0,0000	0,0000
5	0,8257	0,0000	0,0000	0,0000	0,8257	0,8422	0,9010	0,8085	0,0000	0,0000	0,5093	0,5093
6	0,6729	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8773	0,0000	0,0000	0,0000

Foi possível concluir que os resultados para $p=2$ e $p=3$ são competitivos com leve vantagem para $p=2$.

Modelo Dubois & Prade: Neste modelo foram testados diferentes valores do parâmetro α . A seguir são mostrados alguns dos resultados do diagnóstico difuso, com seus respectivos valores de α .

Tabela A.8 - Resultados do diagnóstico difuso com o modelo D&P para $\alpha = 0,80$.

Casos	$\alpha = 0,80$											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,8813	0,0000	0,0000	0,0000	0,4812	0,4812	0,4812	0,4812	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8875	0,0000	0,0000	0,0000
3	0,8705	0,0000	0,0000	0,0000	0,9470	0,8814	0,8705	0,8586	0,0000	0,0000	0,4812	0,4812
4	0,8003	0,0000	0,0000	0,0000	0,8003	0,9796	0,8003	0,7819	0,0000	0,0000	0,0000	0,0000
5	0,8705	0,0000	0,0000	0,0000	0,8705	0,8814	0,9470	0,8586	0,0000	0,0000	0,4812	0,4812
6	0,7000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8875	0,0000	0,0000	0,0000

Tabela A.9 - Resultados do diagnóstico difuso com o modelo D&P para $\alpha = 0,90$.

Casos	$\alpha = 0,90$											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,8815	0,0000	0,0000	0,0000	0,4278	0,4278	0,4278	0,4278	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,9000	0,0000	0,0000	0,0000
3	0,8629	0,0000	0,0000	0,0000	0,9383	0,8722	0,8629	0,8529	0,0000	0,0000	0,4278	0,4278
4	0,7844	0,0000	0,0000	0,0000	0,7844	0,9784	0,7884	0,7687	0,0000	0,0000	0,0000	0,0000
5	0,8629	0,0000	0,0000	0,0000	0,8629	0,8722	0,9383	0,8529	0,0000	0,0000	0,4278	0,4278
6	0,6222	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,9000	0,0000	0,0000	0,0000

Tabela A.10 -Resultados do diagnóstico difuso com o modelo D&P para $\alpha = 0,95$.

Casos	$\alpha = 0,95$											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,8578	0,0000	0,0000	0,0000	0,4053	0,4053	0,4053	0,4053	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8806	0,0000	0,0000	0,0000
3	0,8631	0,0000	0,0000	0,0000	0,9369	0,8716	0,8631	0,8541	0,0000	0,0000	0,4053	0,4053
4	0,7813	0,0000	0,0000	0,0000	0,7813	0,9743	0,7813	0,7669	0,0000	0,0000	0,0000	0,0000
5	0,8631	0,0000	0,0000	0,0000	0,8631	0,8716	0,9369	0,8541	0,0000	0,0000	0,4053	0,4053
6	0,5895	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8866	0,0000	0,0000	0,0000

Segundo os resultados obtidos, foi possível concluir que $\alpha = 0,95$ e $\alpha = 0,90$ foram competitivos, com leve vantagem para o parâmetro $\alpha = 0,95$.

Modelo Dombi: Para este modelo foram testados diferentes valores do parâmetro λ . A seguir são mostrados alguns dos resultados do diagnóstico difuso, com seus respectivos valores de λ .

Tabela A.11 -Resultados do diagnóstico difuso com o modelo Dombi para $\lambda = 0,20$.

Casos	$\lambda = 0,20$											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,7741	0,0000	0,0000	0,0000	0,0496	0,0496	0,0496	0,0496	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8072	0,0000	0,0000	0,0000
3	0,9821	0,0000	0,0000	0,0000	0,9946	0,9826	0,9821	0,9816	0,0000	0,0000	0,0496	0,0496
4	0,9294	0,0000	0,0000	0,0000	0,9294	0,9959	0,9294	0,9270	0,0000	0,0000	0,0000	0,0000
5	0,9821	0,0000	0,0000	0,0000	0,9821	0,9826	0,9946	0,9816	0,0000	0,0000	0,0496	0,0496
6	0,0866	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8141	0,0000	0,0000	0,0000

Tabela A.12 -Resultados do diagnóstico difuso com o modelo Dombi para $\lambda = 0,40$.

Casos	$\lambda = 0,40$											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,7777	0,0000	0,0000	0,0000	0,2262	0,2262	0,2262	0,2262	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8072	0,0000	0,0000	0,0000
3	0,9059	0,0000	0,0000	0,0000	0,9491	0,9083	0,9059	0,9034	0,0000	0,0000	0,2262	0,2262
4	0,8257	0,0000	0,0000	0,0000	0,8257	0,9615	0,8257	0,8201	0,0000	0,0000	0,0000	0,0000
5	0,9059	0,0000	0,0000	0,0000	0,9059	0,9083	0,9491	0,9034	0,0000	0,0000	0,2262	0,2262
6	0,3474	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8072	0,0000	0,0000	0,0000

Tabela A.13 - Resultados do diagnóstico difuso com o modelo Dombi para $\lambda = 0,60$.

Casos	$\lambda = 0,60$											
	Linha							Barra				
	A-B	B-C	C-F	C-G	A-D	A-D-E	A-E	A	B	C	D	E
1	0,7810	0,0000	0,0000	0,0000	0,3402	0,3402	0,3402	0,3402	0,0000	0,0000	0,0000	0,0000
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8005	0,0000	0,0000	0,0000
3	0,8427	0,0000	0,0000	0,0000	0,8965	0,8467	0,8427	0,8386	0,0000	0,0000	0,3402	0,3402
4	0,7702	0,0000	0,0000	0,0000	0,7702	0,9221	0,7702	0,7629	0,0000	0,0000	0,0000	0,0000
5	0,8427	0,0000	0,0000	0,0000	0,8427	0,8467	0,8965	0,8386	0,0000	0,0000	0,3402	0,3402
6	0,4850	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,8005	0,0000	0,0000	0,0000

Com estes resultados, foi possível concluir que para $\lambda = 0,40$, o modelo apresenta uma melhor representação do problema.

A.3 Sistema Light

A Tabela A.14 mostra alguns exemplares de simulação para o sistema Light, cujos resultados serão apresentados a seguir para ilustrar as análises realizadas.

Tabela A.14 - Simulação de casos para o sistema Light.

Tipo de Simulação	Alarmes Ativados
1.- Defeito na linha TSU-JP-2	Terminal TSU - Z2 e DJ Terminal JP - PP e DJ
2.- Defeito na linha TSU-JP-1 com falha do disjuntor do terminal TSU	Terminal TSU - Z1 e BF Terminal JP - Z2 e DJ
3.- Defeito na linha FCN-GRA-JDB-1 falha da proteção do terminal FCN	Terminal GRA -PP e DJ Terminal JDB - PP e DJ Terminal GRA - Z2 e DJ (Linha FCN-GRA-1,2,3,4) Terminal GRA - Z2 e DJ (Linha FCN-GRA-JDB-2)
4.- Defeito na linha FCN-GRA-JDB-2 com falha do disjuntor do terminal GRA	Terminal FCN - Z2 e DJ Terminal GRA - Z1 e BF Terminal JDB - Z2 e DJ Barra GRA - DJs
5.- Defeito na linha GRA-TSU-1 com falha da proteção do terminal TSU	Terminal GRA - PP e DJ Terminal GRA - Z2 e DJ (Linha GRA-TSU-2,3,4) Terminal JP - Z2 e DJ (Linha TSU-JP-1,2)
6.- Defeito na linha GRA-TSU-1 e atuação indevida da proteção do terminal remoto TSU-JP-1	Terminal TSU - Z2 e DJ Terminal GRA - Z1 e DJ Terminal JP - Z2 e DJ (Linha TSU-JP-1)

A partir das informações sobre a atuação dos relés e disjuntores fornecidas pela simulação de casos, como na Tabela A.14, pode-se proceder a obtenção das relações fuzzy

com os componentes do sistema, utilizando os respectivos diagrama Sagitais. A seguir, para cada modelo são mostrados os resultados dos casos, descritos na Tabela A.14, tendo em conta variações no valor do parâmetro do modelo.

Modelo Hamacher: Para este modelo foram testados diferentes valores do parâmetro γ . A seguir são mostrados alguns dos resultados do diagnóstico difuso, com seus respectivos valores de γ . Deve-se ter em conta que os resultados são graus de pertinência do padrão de alarmes para as classes (componentes do sistema).

Tabela A.15 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma=3$.

Casos	$\gamma=3$ e $\gamma'=2$ ($\gamma'=\gamma-1$)											
	Linha										Barra	
	GRA-TSU-1	GRA-TSU-2	GRA-TSU-3	GRA-TSU-4	TSU-JP-1	TSU-JP-2	FCN-GRA-JDB-1	FCN-GRA-JDB-2	FCN-GRA-1	FCN-GRA-2	GRA	TSU
1	0,0000	0,0000	0,0000	0,0000	0,3031	0,7530	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2	0,3031	0,3031	0,3031	0,3031	0,8629	0,3031	0,0000	0,0000	0,0000	0,0000	0,0000	0,3031
3	0,3031	0,3031	0,3031	0,3031	0,0000	0,0000	0,9988	0,9237	0,9220	0,9220	0,9207	0,0000
4	0,5898	0,5898	0,5898	0,5898	0,0000	0,0000	0,5898	0,9990	0,5898	0,5898	0,5898	0,0000
5	0,9886	0,9292	0,9292	0,9292	0,9292	0,9292	0,0000	0,0000	0,0000	0,0000	0,0000	0,9253
6	0,9336	0,5898	0,5898	0,5898	0,3387	0,3031	0,0000	0,0000	0,0000	0,0000	0,3031	0,3031

Tabela A.16 - Resultados do diagnóstico difuso com o modelo Hamacher para $\gamma=4$.

Casos	$\gamma=4$ e $\gamma'=3$ ($\gamma'=\gamma-1$)											
	Linha										Barra	
	GRA-TSU-1	GRA-TSU-2	GRA-TSU-3	GRA-TSU-4	TSU-JP-1	TSU-JP-2	FCN-GRA-JDB-1	FCN-GRA-JDB-2	FCN-GRA-1	FCN-GRA-2	GRA	TSU
1	0,0000	0,0000	0,0000	0,0000	0,2740	0,7477	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2	0,2740	0,2740	0,2740	0,2740	0,8619	0,2740	0,0000	0,0000	0,0000	0,0000	0,0000	0,2740
3	0,2740	0,2740	0,2740	0,2740	0,0000	0,0000	0,9992	0,9271	0,9257	0,9257	0,9242	0,0000
4	0,5699	0,5699	0,5699	0,5699	0,0000	0,0000	0,5699	0,9994	0,5699	0,5699	0,5699	0,0000
5	0,9913	0,9248	0,9248	0,9248	0,9248	0,9248	0,0000	0,0000	0,0000	0,0000	0,0000	0,9233
6	0,9422	0,5699	0,5699	0,5699	0,3088	0,2740	0,0000	0,0000	0,0000	0,0000	0,2740	0,2740

3	3	3	3	3	3	3	3	4	4	4	4	4	4	4	4	4
3	4	5	6	7	8	9	0	1	2	3	4	5	6	7	8	
D	D	D	D	D	D	D	D	Z	Z	D	P	Z	Z	D	P	
J	J	J	J	J	J	J	J	1	2	J	D	1	2	J	D	
Terminal																
FCN		GRA		FCN		GRA		FCN		GRA		FCN		GRA		
Linha FCN-GRA-1				Linha FCN-GRA-2				Linha FCN-GRA-3				Linha FCN-GRA-4				
Adj. GRA								Adj. FCN								

Tabela B.5 - Variáveis de entrada da RNF₂ - Área 2

1	2	3	4	5	6	7
P	D	D	D	D	D	D
D	J	J	J	J	J	J
Barra FCN						
Linha FCN-GRA-1						
Linha FCN-GRA-2						
Linha FCN-GRA-3						
Linha FCN-GRA-4						
Linha FCN-GRA-JDB-1						
Linha FCN-GRA-JDB-2						

Tabela B.6 - Variáveis de entrada da RNF₃ - Área 3

1	2	3	4	5	6	7	8	9	1	1	1	1	1	1	1	1	1	2	2	2	2	2	2	2	2	3	
P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	D	D	D	D
P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F	J	J	J	J
Terminal FCN			Terminal GRA			Terminal JDB			Terminal FCN			Terminal GRA			Terminal JDB			Terminal									
FCN			GRA			JDB			FCN			GRA			JDB			FCN			GRA			JDB			
Linha FCN-GRA-JDB-1									Linha FCN-GRA-JDB-2									Linha FCN-GRA-JDB-1			Linha FCN-GRA-JDB-2						

3	3	3	3	3	3	3	3
1	2	3	4	5	6	7	8
Z	Z	D	P	Z	Z	D	P
1	2	J	D	1	2	J	D
Adj. FCN				Adj. FCN			

3	3	3	3	3	3	3	3	4	4	4	4	4	4	4	4	4	4	
3	4	5	6	7	8	9	0	1	2	3	4	5	6	7	8			
D	D	D	D	D	D	D	D	Z	Z	D	P	Z	Z	D	P			
J	J	J	J	J	J	J	J	J	1	2	J	D	1	2	J	D		
Terminal																		
GRA		CCD		GRA		CCD		GRA		CCD		GRA		CCD		Adj. GRA		
Linha GRA-CCD-1				Linha GRA-CCD-2				Linha GRA-CCD-3				Linha GRA-CCD-4				Adj. CCD		

Tabela B.10 - Variáveis de entrada da RNF₇ - Área 7

1	2	3	4	5	6	7	8	9	0	1	1	1	1	1	1	1	1	2	2	2	2	2	2	2	2	2	3	3	3		
P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	Z	Z	B	
P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F
Terminal GRA			Terminal CCD			Terminal JP			Terminal CCD			Terminal GRA			Terminal JP			Terminal JP			Terminal VVQ										
Linha GRA-CCD-JP-1									Linha GRA-CCD-JP-2									Linha JP-VVQ-1													

3	3	3	3	3	3	3	3	4	4	4	4	4	4	4	4	4	4	5	5	5	5	5	5	5	5	5	5	5	6	6	6		
P	Z	Z	B	P	Z	Z	B	D	D	D	D	D	D	D	D	D	D	Z	Z	D	P	Z	Z	D	P	Z	Z	D	P	Z	Z	D	P
P	1	2	F	P	1	2	F	J	J	J	J	J	J	J	J	J	J	1	2	J	D	1	2	J	D	1	2	J	D	1	2	J	D
Terminal JP		Terminal VVQ		Terminal														Adj. GRA			Adj. CCD			Adj. JP									
Linha JP-VVQ-2				Linha GRA-CCD-JP-1				Linha GRA-CCD-JP-2				Linha JP-VVQ-1		Linha JP-VVQ-1		Adj. GRA			Adj. CCD			Adj. JP											

Tabela B.11 - Variáveis de entrada da RNF₈ - Área 8

1	2	3	4	5	6	7
P	D	D	D	D	D	D
D	J	J	J	J	J	J
Barra TSU						
Linha GRA-TSU-1						
Linha GRA-TSU-2						
Linha GRA-TSU-3						
Linha GRA-TSU-4						
Linha TSU-JP-1						
Linha TSU-JP-2						

Tabela B.12 - Variáveis de entrada da RNF₉ - Área 9

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	P	Z	Z	B	D	D	D	D	Z	Z	D	P	Z	Z	D	P
P	1	2	F	P	1	2	F	P	1	2	F	P	1	2	F	J	J	J	J	1	2	J	D	1	2	J	D
Terminal TSU				Terminal JP				Terminal TSU				Terminal JP				Terminal				Adj. TSU				Adj. JP			
TSU		JP		TSU		JP		TSU		JP		TSU		JP													
Linha TSU-JP-1								Linha TSU-JP-2								Linha TSU-JP-1				Linha TSU-JP-1							

REFERÊNCIAS

- [A66] I. Aleksander, "*Self-adaptative universal logic circuits*", *Electronic Letters*, 2:231, 1966.
- [AEPDM89] M. Aggoune, M.A. El-Sharkawi, D.C. Park, M.J. Damborg, R.J. Marks II, "*Preliminary Results on Using Artificial Neural Networks for Security Assessment*", *IEEE Proc. of 1989 PICA*, pp. 252-258, Seattle, Washington, USA May, 1989.
- [AG94] R. Andrews, S. Geva, "*Rule extraction from a constrained error backpropagation MLP*", In *Proceeding of the 5th Australian Conference on Neural Networks*, pages 9-12, Brisbane, Australia, 1994.
- [AIS95] A.P. Alves da Silva, A.H.F. Insfran, P.M. da Silveira, G. Lambert-Torres, "*Neural networks for fault location on substations*", 1995 IEEE, PES Summer Meeting, July 23-27, 1995, Portland, OR.
- [AS93] K.H. Abdul-Rahman, S.M. Shahidehpour, "*A Fuzzy-Based optimal reactive power control*", *IEEE Transaction on Power Systems*, Volume 8, N° 2, May 1993. Pages 662-670.
- [BNW98] P. Bauer, S. Nouak, R. Winkler, "*A brief course in fuzzy logic and fuzzy control*" [online] <<http://www.flll.unilinz.ac.at/fuzzy/introduction.html>>, April 1998.
- [BSA83] A.G. Barto, R.S. Sutton, C.W. Anderson, "*Neuronlike adaptative elements that can solve difficult learning problems*", *IEEE Transactions on Systems, Man and Cybernetics*, SMC-13:834-846, 1983.
- [C77] A.C. Caminha, "*Introdução à Proteção dos Sistemas Elétricos*", Edgard Blücher, 1977.
- [C89a] E.H.P. Chan, "*Application of neural networks computing in intelligent alarm processing*", *Proceedings of the IEEE Power Industry Computer Application Conference*, Seattle, WA, 1989, pp. 246-251.

[C89b] G. Cybenko, "*Approximation by superposition of a sigmoid function*", Mathematics of Control, Signal and Systems, 2:303-314, 1989.

[C93] J.L. Chen, "*A Fuzzy Expert System for Fault Diagnosis in Electric Distribution System*", 1993 Canadian Conference on Electrical and Computer Engineering, pp. 14-17, 1993, Vancouver, Canada.

[C96a] M.-y. Chow, "*Fuzzy Systems*", in CRC Press Industrial Electronics Handbook, D. Irwin, 1996.

[C96b] M.-y. Chow, "*Fuzzy Logic Based Control*", in CRC Press Industrial Electronics Handbook, D. Irwin, 1996.

[CAT98] A.C. Carvalho, P.B. Antônio, B.L. Teresa, "*Fundamentos de Redes Neurais Artificiais*", 11^a Escola de Computação, 1998.

[CD91] CIGRE TF 38-06-02, Convener - T. Dillon, "*Survey on expert systems in alarm handling*", Electra, N° 139, pp. 133-147, 1991.

[CG88] G. A. Carpenter, S. Grossberg, "*The ART of adaptive pattern recognition by a self-organizing neural network*", Computer, 21:77-88, 1988.

[CL90] D. Chui, M.A. Laughton, "*Power System Control Using Fuzzy Reasoning*", Proceeding of the 10th Power System Computation Conference, Graz, Australia, Aug. 1990.

[CNH91] K. Choi, K. Nimbly, J. Hasagawa, "*Fuzzy Decision Making of Deicing Countermeasures Against Snow Accretion*", 1991 Expert System Applications to Power Systems, Tokyo/Kobe, April 1991, pp. 433-438.

[CP97] H. Chow, J.K. Park, "*An Expert System for Fault Section Diagnosis of Power Systems Using Fuzzy Relations*", IEEE Transactions on Power Systems, vol. 12, N° 1, February 1997.

[CS96] M. Craven, J. Shavlik, "*Extracting tree-structured representations of trained networks*". In D.S. Touretzky, M.C. Mozer, and M.E. Hasselmo, editors, *Advances in Neural Information Processing Systems*, pages 37-45. MIT Press. Denver, 1996.

[CT93] M.L. Chen, S.N. Talukdar, "*Causal Nets for Diagnosis*," in *Proceedings of 4th Symposium on Expert System Application to Power Systems*, Jan. 1993, Melbourne, Australia, pp. 379-386.

[CT96] M.-y. Chow, H. Tram, "*Applications of Fuzzy Logic Technology for Spacial Load Forecasting*", *IEEE Transactions on Power Systems*, 1996.

[D87] H.E.D. Dijk, "*Exformer: An Expert System Stabilizer for Transformer Fault Diagnosis*", *Proceeding of the 9th Power System Computation Conference*, Lisbon, Sept. 1987, pp. 715-721.

[DB94] H. Demuth, M. Beale, "*Neural Network Toolbox-Matlab*", 3rd Ed. Natick (USA), The Mathworks, Inc. 1994.

[DP80] D. Dubois, H. Prade, "*Fuzzy Sets and Systems: Theory and Applications*", Academic Press, New York, 1980.

[DP95] D. Dubois e H. Prade, "*Possibility Theory*", Plenum Press, New York, 1988.

[DV83] J. Dombi e Z. Vas, "*Basic theoretical treatment of fuzzy connectives*", *Acta Cybernet.*, vol. 6, pp. 191-201, 1983.

[DZ89] A.K. David, R.D. Zhao: "*An Expert System with Fuzzy Sets for Optimal Planning*", *IEE Trans. on Power Systems*, Vol. 4, N° 3, Aug. 1989.

[E79] E. Economakos, "*Application of Fuzzy Concepts to Power Demand Forecasting*", *IEEE Trans. SMC*, Vol. 9, 1979, pp. 651-657.

- [EMDACA90] M.A. El-Sharkawi, R.J. Marks, M.J. Damborg, L.E. Atlas, D.A. Cohn, M.E. Aggoune, "Artificial Neural Networks as Operator Aid for on-line Static Security Assessment of Power Systems", *Proc. of 10th PSCC*, pp. 895-901, Graz., Austria, Aug. 1990.
- [F75] K. Fukushima, "Cognitron: a self-organizing multilayered neural network", *Biol. Cybern.*, 23:121-134, 1975.
- [F84] S.J. Farlow, "Self-organizing Methods in Modelling", Maral Dekker, 1984.
- [G76] S. Grossberg, "Adaptative pattern clasification and universal recoding: II. feedback, expectation, olfaction, illusions ", *Biol. Cybern.*, 23:187-202, 1976.
- [GKY95] George J. Klir, Bo Yuan, "Fuzzy Sets amd Fuzzy Logic: Theory and Aplications", Prentice Hall, 1995.
- [H49] D.O. Hebb, "The Organization of Behavior", Wiley, 1949.
- [H82] J.J. Hopfield, "Neural networks and physical systems with emergent collective properties", *Proc. Nat. Acad. Sci.*, 79:2554-8, 1982.
- [H90] Y.Y. Hsu, "Design of Fuzzy Power System Stabilizers for Multi-Machine Power Systems", *IEE Proceeding*, Pt. C, Vol. 137, N° 3, May 1990.
- [H94] S. Haykin, "Neural Networks - A Comprehensive Foundation", Prentice-Hall, 1994.
- [H98] M.E., El-Hawary, editor, "Fuzzy System Theory in Electrical Power Engineering", *IEEE press*, 1998.
- [HC91] Y.Y. Hsu, C.H. Cheng, "Load Frequency Control Using Fuzzy Logic", *IASTED Power High Tech '91*, Tainan, Taiwan, Mar. 1991.

[HH92] E. Handschin, W. Hoffmann, "*Integration of an expert system for security assessment into an energy management system*", *Electrical Power & Energy Systems*, vol. 14, N° 2/3, April/June 1992.

[HKH94] E. Handschin, D. Kuhlmann, W. Hoffmann, "*Fault diagnosis in electrical energy systems using device-specific artificial neural networks*", *Engineering Intelligent Systems*, Vol. 2, December, 1994, pp. 255-262.

[HL86] M.F. Hebb, Jr., J.T. Logan, "*Protective Relay Modernization Program Releases Latent Transmission Capacity*", *AIEE District Conference Paper 55-354*, 1986.

[HSB93] H.J. Haubrich, T.H. Seitz, A. Bovy, "*Fuzzy Sets in Reliability Analysis of Power Distribution Systems*", *1993 Expert System Applications to Power Systems*, Melbourne, Jan. 1993, pp. 212-217.

[IIKT91] A. Ishigame, T. Imoto, S. Kawamoto, T. Tanihuchi, "*Fuzzy and Optimal Control for Stabilizing Power Systems*", *Electrical Engineering in Japan*, Vol. 111, N° 2, 1991.

[JDS91] A.G. Jongepier, H.E. Dijk, L. van der Sluis, "*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.

[JVP93] P. Jervanhaura, P. Verho, J. Partanen, "*Using Fuzzy Sets to Model the Uncertainty in the Fault Location Process of Distribution Networks*", *IEEE/PES 1993 Summer Meeting*, Vancouver, B.C., Canada, July 18-22 1993, 93 SM 4168 PWRD.

[K74] T. Kohonen, "*An adaptive associative memory principle*", *IEEE Transactions on Computers*, C-23: 444-445, 1974.

[K89] T. Kohonen, "*Self-Organization and Associate Memory*", Springer-Verlag, Berlin, 3 edition, 1989.

[KF88] G.J. Klir, T.A. Folger, *"Fuzzy Sets, Uncertainty, and Informations"*, Prentice Hall, Englewood Cliffs-New Jersey, 1988.

[KH93] H.C. Kuo, Y.Y. Hsu, *"Distribution System Load Estimation and Service Restoration Using a Fuzzy Set Approach "*, 1992 IEEE/PES Winter Meeting, 93 WM 086-9 PWRD, Columbus, Feb. 1993.

[KIBEC91] A.B.R. Kumar, A. Ipakchi, V. Brandwajn, M.A. El-Sharkawi, G. Cauley, *"Neural Networks for Dynamic Security Assessment of Large-Scale Power Systems "*, Proc. of 'ANNP '91, pp. 65-71, Seattle, WA, July, 1991.

[KK91] R. Karunakaran, G.G. Karady, *"Artificial neural networks as a dispatcher's aid in alarm processing"*, Proceedings of the Third International Forum on Applications of Neural Networks to Power Systems, Seattle, W.A., July 23-26, 1991, pp. 169-173.

[KP91] K. Kim, J. Park, *"Application of Hierarchical neural networks 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.

[KW92] D.S. Kirschen, B.F. Wollenberg, *"Intelligent alarm processing in power systems"*, Proceedings of IEEE, vol. 80, N° 5, May 1992, pp. 663-672.

[L88] R. Linsker, *"Self-organization in perceptual network"*, Computer 21(3):105-117, 1988.

[L92] D.T. Lee, et al. *"Adaptative Power System Control with Neural Networks"*, Proc. of IJCNN '92, pp. 838-843, Baltimore, MD, Jun. 1992.

[L95] C. T. Lin, *"A neural fuzzy control system with structure and parameter learning"*, Fuzzy Sets and Systems, (70): 183-212., 1995.

[LLH92] C.E. Lin, J.M.Ling, C.L. Huang, *"An Expert System for Transformer Fault Diagnosis and Maintenance Using Dissolved Gas Analysis"*, 1992 IEEE/PES Winter Meeting, 92 WM 243-6 PWRD, New York, July 1992.

- [LS93] K.D. Labuda, S.M. Shahidehpour, *"A Fuzzy Multi-Objective Approach to Power System State Estimation"*, 1993 Expert Systems Applications to Power Systems, Melbourne, Jan. 1993, pp. 218-223.
- [LT87] C.C. Liu, K.L. Tomsovic, *"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 1987.
- [M61] M.L. Minsky, *"Steps towards artificial intelligence"*, In proc. of the Institute of radio Engineers 49, pp. 8-32, 1961.
- [M91] H. Matsumoto, et al., *"An Expert System Based on Fuzzy Reasoning for Startup Scheduling and Operation Support in Fossil Power Plants"*, IEEE/PES 1991 Winter Meeting, 91 WM 127-1 EC, 1991, New York.
- [M91a] V. Miranda, *"Using Fuzzy Reliability Indices in a Decision Aid Environment for Establishing Interconnection and Switching Location Policies"*, Proceedings CIRED '91, AIM-IEE, s.6.21, Liege, Belgium, April 1991.
- [MM89] V. Miranda, M.A. Matos, *"Distribution System Planning with Fuzzy Models and Techniques"*, Proceeding of CIRED 1989, Brighton, Aug, 1989.
- [MMH91] M.A.M. Hassan, O.P. Malik, G.S. Hope, *"A Fuzzy Logic Based Stabilizer for a Synchronous Machine"*, IEEE Trans. on Energy Conversion, Vol. 6, N° 3, Sept. 1991.
- [MMT95] J. Momoh, X. Ma, K. Tomsovic, *"Overview and Literature Survey of Fuzzy Set Theory in Power Systems"*, IEEE Transactions on Power Systems, Vol. 10, N° 3, Aug. 1995, pp. 1676-1690.
- [MP43] W.S. McCulloch, W. Pitts, *"A logical calculus of the ideas immament in nervous activity"*, Bulletin of Mathematical Biophysics, 5:115-133, 1943.

- [MP69] M. Minsky, S. Papert, *"Perceptrons: na introduction to computacional geometry"*, MIT Press, Massachusetts, 1969.
- [MS92] V. Miranda, J.T. Saraiva: *"Fuzzy Modeling of Power System Optimal Power Flow"*, IEEE Trans. on Power Systems, Vol. 7, N° 2, May 1992.
- [MS92a] A.V. Machias, G.D. Shikos, *"Fuzzy Risk Index of Wind Sites"*, 1992 IEEE/PES Wniter Meeting, 92 WM 023-2 EC, New York, Jan. 1992.
- [MSSC01] M. M. Meza, J.C. S. Souza, M. Th. Schilling, M.B. Do Coutto Filho, *"Exploring Fuzzy Relations For Alarm Processing And Fault Location In Electrical Power Systems"*, Proceeding do IEEE Porto PowerTech 2001. Porto, Portugal.
- [MT89] H. Mori, S. Tsuzuki, *"Power System Topological Observability Analysis Using a Neural Network Model"*, Proc. of ESAP'91, pp. 385-391, Seattle, WA, July, 1989.
- [N93] K. Nishimura, et al., *"Aplication of neural Network to Operation of Power Generating Units "*, Proc. of ANNPS'93, pp. 104-107, Yokoyama, Japan, April 1993.
- [NAT93] M. Nerezian, G. Anderson, K. Tomsovic, *"Power System Damping Control Design with Fuzzy Logic"*, 1993 Expert System Applications to Power Systems, Melbourne, Jan. 1993, pp. 406-411.
- [P81] Power Protection, The Electricity Council, Peter Peregrinus Ltd., UK, 1981.
- [P98] A.G. Phadke, J.S. Thorp, *"Computer relaying for power systems"*, Research Studies Press Ltd., Somerset, England, 1998.
- [PB91] M. Pfau-Wagenbauer, H. Brugger, *"Model and rule based intelligent alarm processing"*, Proceedings of the Third Symposium on Expert Systems Application to Poer Systems, April 1-5, 1991, Tokyo-Kobe, Japan, pp. 27-32.

- [PG92] L. Pau, T. Gotzche, "*Explanation facility for neural networks*". *Journal of Intelligent and robotic Systems*", 5:193-206, 1992.
- [R58] F. Rosenblatt, "*The perceptron: A probabilistic model for information storage and organization in the brain*", *Psychol. Ver.*, 65:386-408, 1958.
- [R62] F. Rosenblatt, "*Principles of Neurodynamics: Perceptrons and the theory of brain mechanisms*", Spartan Books, New York, 1962.
- [R95] S. Rementeria, et al, "*Expert systems & Neural networks in power grid fault diagnosis: an empirical comparison*", *Engineering Intelligent system*, vol. 3, N° 1, pp. 33-44, March 1995.
- [R98a] R. Guerra, "*Projeto e simulação do controle de atitude autônomo de satélites usando lógica nebulosa*", Master's Thesis, Instituto Nacional de Pesquisas Espaciais - INPE, São José dos campos-SP, março 1998.
- [R98b] M.C. Russell, "*The Art & Science of Protective Relaying*", GE, 1998.
- [R99] M.A.P. Rodrigues, "*Localização de defeitos em sistemas de potência utilizando redes neurais* ", Dissertação de mestrado, CAA-UFF, Maio 1999.
- [RHW86] D.E. Rumelhart, G.E. Hinton, R.J. Williams, "*Learning representations by back-propagating errors*", *Nature*, 323:533-536, 1986.
- [RSSC99] M. A. P. Rodrigues, J.C. S. Souza, M. Th. Schilling, M.B. Do Coutto Filho, "*Fault Diagnosis in Electrical Power Systems using Artificial Neural Networks*", *Proceeding do IEEE Budapest PowerTech*, BPT99-79-23, Budapest, Hungria, Agosto de 1999.
- [S88] R.S. Sutton, "*Learning to predict by the method of temporal differences*", *Machine Learning*, 3:9-44, 1988.

- [SC91] K.S. Swarup, H.S. Chandrasekharaiah, "*Fault Detection and Diagnosis of Power Systems Using Artificial Neural Networks*", in Proceedings of the 1st International Forum on Applications of Neural Networks to Power Systems, 1991, Seattle, W.A., U.S.A., pp. 102-106.
- [SC97] S. Sandri, C. Correa, "*Lógica Nebulosa*", Instituto Nacional de Pesquisas Espaciais - INPE, São José dos campos-SP, Agosto1997.
- [SK92] Y.Y. Shu, H.C. Kuo, "*Fuzzy Set Based Contingency Ranking*", IEEE Trans. on Power Systems, Vol. 7, N° 3, Aug. 1992.
- [SLA96] J.C.S. Souza, A.M. Leite da Silva, A.P. Alves da Silva, "*Data Debugging for Real-Time Power System Monitoring Based on Pattern Analysis*", IEEE Trans. on Power Systems, Vol. 11, pp. 1592-1599, August 1996.
- [SLA98] J.C.S. Souza, A.M. Leite da Silva, A.P. Alves da Silva, "*Online Topology Determination and Bad Data Supression in Power System Operation Using Artificial Neural Networks*", IEEE Trans. on Power Systems, Vol. 13, N° 3, pp. 796-803, August 1998.
- [SRSC01] J.C.S. Souza, M.A.P. Rodrigues, M. Th. Schilling, M.B. Do Coutto Filho, "*Fault Location in Electrical Power Systems Using Intelligent Systems Techniques*", IEEE Transactions on Power Delivery, N° 1, January 2001, pp. 59-67.
- [STOAM91] L.E.B. Da Silva, G.L. Torres, G. Oliver, G.E. April, D. Mukhedar, "*A Fuzzy-Forth Rule Base Production System for Power Converter Control*", 1991 Expert System Applications to Power Systems, Tokyo/Kobe, Japan, April 1991, pp. 447-454.
- [T92] K. Tomsovic, "*A Fuzzy Linear Programming Approach to the Reactive Power/Voltage Control Problem*", IEEE Trans. on Power Systems, Nov. 7, N° 1, Feb. 1992, pp.287.

[TI88] Y. Terasawa, S. Iwamoto: "*Optimal Power Flow Using Fuzzy Mathematical Programming*", Electrical Engineering in Japan, Vol. 108, N° 3, 1988, pp. 46-54.

[TL91] K. Tomsovic, J.M. Ling, "*A Proposed Fuzzy Set and Measurement Approach to Monitoring and Control of Real Power*", IASTED Power High Tech '91, Taiwan, Mar. 91.

[TSM89] G.L. Torres, L.E.B. Da Silva, D. Mukhedkar, "*Fuzzy Load Management in Distribution Systems*", IASTED Power High Tech '89, Valencia, Spain, June 1989, pp. 425-430.

[TSM91] G.L. Torres, L.E.B. Da Silva, D. Mukhedkar, "*A Fuzzy Knowledge Base for Load Forecasting*", 1991 Expert System Applications to Power Systems, Tokyo/Kobe, April 1991, pp. 439-446.

[TTI93] K. Tomsovic, M. Tapper, T. Ingvarec, "*A Fuzzy Information Approach to Integrating Different Transformer Diagnostic Methods*", IEEE Transactions on Power Delivery, Vol. 8, N° 3, July 1993, pp. 1638-1646.

[W74] P. Werbos, "*Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*", PhD Thesis, Harvard University, 1974.

[W76] Westinghouse Electric Corporation - Applied Protective Relaying, A Silent Sentinels Publication, Newark, NJ, 1976.

[WE92] S. Weerasooriya, M.A. El-Sharkawi, "*Toward static security assessment of large scale power systems using neural networks* ", IEE proceeding-C Generation, Transmissão, and Distribution, vol./issue 139/1, pp. 64-70, January, 1992.

[WE93] S. Weerasooriya, M.A. El-Sharkawi, "*Dynamic Security Assessment of Power Systems Using Neural Networks* ", International Conference on Expert System Applications for the Electric Power Industry, Phoenix, Arizona, December 8-10, 1993.

[WH60] B. Widrow, M.E. Hoff, "*Adaptative switching circuits*", Institute of Radio Engineers, Western Electronic Show and Convention, 1960.

[WM92] L. Wang, J.M. Mendel, "Generating fuzzy rules by learning from examples", IEEE Transactions on Systems, Man, and Cybernetics., 22(6):1414-1427., Novembro/Dezembro 1992.

[XZL90] J. Xu, S. Zhang, Y. Liu, "Fuzzy Diagnosis Method in Machinery Condition Monitoring and Failure Diagnosis", Proceedings of the 2nd International Machinery Monitoring and Diagnostic Conference, Los Angeles, Sept. 1990, pp. 227-233.

[Y80] R.R. Yager, "On a general class of fuzzy connectives", Fuzzy Sets Systems, vol. 4, pp. 235-242, 1980.

[Z65] L.A. Zadeh, "Fuzzy sets", Fuzzy Sets, Information and Control, vol. 8, pp. 338-353, 1965.

[Z78] L.A. Zadeh, "Fuzzy sets as a basis for a theory of possibility", Fuzzy Sets and Systems, vol. 1, pp. 3-28, 1978.

[Z85] H.J. Zimmermann, "Fuzzy Set Theory and its Applications", Boston, Kluwer, 1985.

[ZDF93] Q. Zhou, J. Davidson, A.A. Fouad, "Application of Artificial Neural Networks in Power System Security and Vulnerability Assessment ", IEEE PES 1993 Winter Meeting, Paper N° 93 WM183-4-PWRS, Columbus, Ohio, USA, Jan. 1993.