



Pontifícia Universidade Católica de Minas Gerais
Programa de Pós-Graduação em Engenharia Elétrica

**PROPOSTA DE UM SISTEMA DE MONITORAMENTO E
DIAGNÓSTICO DE DISJUNTOR UTILIZANDO
INTELIGÊNCIA COMPUTACIONAL**

José Eduardo Nogueira da Silva Filho

BELO HORIZONTE

2007

FICHA CATALOGRÁFICA

Elaborada pela Biblioteca da Pontifícia Universidade Católica de Minas Gerais

S586p

Silva Filho, José Eduardo Nogueira da

Proposta de um sistema de monitoramento e diagnóstico de disjuntor
utilizando inteligência computacional / José Eduardo Nogueira da Silva Filho.
Belo Horizonte, 2007.

136f. : il.

Orientador: Pyramo Pires da Costa Júnior

Dissertação (Mestrado) – Pontifícia Universidade Católica de Minas Gerais.
Programa de Pós-Graduação em Engenharia Elétrica.

1. Disjuntores elétricos. 2. Sistemas difusos. 3. Monitoramento – Controle
automático. I. Costa Júnior, Pyramo Pires da. II. Pontifícia Universidade
Católica de Minas Gerais. Programa de Pós-Graduação em Engenharia Elétrica.
III. Título.

CDU: 621.316.57

José Eduardo Nogueira da Silva Filho

**PROPOSTA DE UM SISTEMA DE MONITORAMENTO E
DIAGNÓSTICO DE DISJUNTOR UTILIZANDO
INTELIGÊNCIA COMPUTACIONAL**

Dissertação apresentada ao programa de pós-Graduação em Engenharia Elétrica, da Pontifícia Universidade Católica de Minas Gerais com requisito parcial para a obtenção do grau de Mestre em Engenharia Elétrica.

Orientador: Professor Dr. Pyramo Pires da Costa Júnior

**BELO HORIZONTE
2007**

Aos meus avós

Adir Dias (*in memoriam*) e Maria de Lourdes

AGRADECIMENTOS

Ao orientador, professor Dr. Pyramo Pires da Costa Junior, pelo apoio, motivação e grande participação no desenvolvimento desta dissertação.

Aos professores e integrantes do Programa de Pós-Graduação em Engenharia Elétrica da PUC-MG pela oportunidade da realização do curso de Mestrado.

Aos colegas de curso e integrantes do grupo de Sistemas de Diagnóstico de Falhas, Michel Hell, Daniel Leite, Daniel Furtado e Luiz Secco pela amizade e troca de experiências, e ao aluno de iniciação científica Lucas pela ajuda no desenvolvimento do trabalho.

Ao pessoal da Engenharia de Manutenção da Companhia Energética de Minas Gerais (CEMIG) Álvaro Jorge, Neynard, Marcelo Alexandre e Marcos Aurélio pelo apoio, esclarecimentos e contribuição durante a elaboração da dissertação.

À Coordenação de Aperfeiçoamento Pessoal de Nível Superior (CAPES) pelo fomento.

Aos meus pais José Eduardo e Waldira por me apoiarem durante toda a minha vida acadêmica e suportarem os momentos de ausência.

Aos meus irmãos Pedro e Marina e aos familiares pelo incentivo.

Aos amigos Tony, Michel, Testone, Mário, Mayco, Ramon e Thiago pelos momentos de descontração que em muito me ajudaram.

Em especial, à Hamanda pelo companheirismo e apoio desde o começo do curso.

*“A mente que se abre a uma nova idéia
jamais voltará ao seu tamanho original”*

Albert Einstein

RESUMO

Neste trabalho é apresentada uma proposta para o monitoramento de disjuntores de alta tensão sem a necessidade de alterações nas suas características construtivas, levando-se em consideração as principais causas de falhas nesses equipamentos. A proposta também consiste em utilizar sinais disponíveis nas subestações, com o intuito de realizar um monitoramento de baixo custo sem a alteração da confiabilidade do equipamento, e possibilitar a indicação do estado das principais partes funcionais dos disjuntores e de seus componentes mais susceptíveis às falhas.

É ainda proposto, o uso de técnicas de inteligência computacional para construção de um sistema especialista com o objetivo de diagnosticar faltas (defeitos) nos disjuntores, através dos sinais a serem monitorados. Inicialmente foi abordado o Sistema de Inferência Fuzzy como uma possível técnica a ser utilizada na construção do sistema. Posteriormente, foram estudados o Sistema de Inferência Fuzzy Neuro-Adaptativo, o algoritmo Fuzzy C-Means, as Relações de Equivalência Fuzzy, as RNA(s): Modelo de Kohonen, *Perceptron* de Múltiplas Camadas e Rede Neural Fuzzy como possíveis técnicas a serem utilizadas na construção e implementação do sistema especialista. Realizaram-se simulações do sistema de diagnóstico utilizando-se estas técnicas. A partir dos resultados obtidos, concluiu-se que as técnicas Rede Neural Fuzzy, Sistema de Inferência Fuzzy e o modelo de Kohonen obtiveram os maiores percentuais de acertos sendo que o modelo de Kohonen apresentou o menor custo computacional.

Com base nos resultados dos estudos realizados, verificou-se a viabilidade da construção e da implementação de um sistema de diagnóstico de disjuntor utilizando as técnicas de inteligência computacional. Tal sistema pode ser utilizado para auxiliar as equipes de manutenção das concessionárias de energia elétrica, possibilitando a adoção de uma manutenção preditiva e proativa, com conseqüente redução de custo, redução das paradas desnecessárias e ao mesmo tempo aumentando a confiabilidade e a segurança do sistema elétrico.

ABSTRACT

In this work, a propose of a high voltage circuit breaker monitoring system is presented. The propose considers the main causes of failures in the equipment, moreover, the monitoring does not require circuit breaker constructive features changes. Aiming at a low cost monitoring without equipment reliability changes, the system deals with the substation available signals in a non-intrusive manner. It provides the health condition of the circuit breakers main functional parts and their components.

Also, this work proposes the usage of soft-computing techniques for the creation of an expert system. The aim of the expert system is exactly to detect faults and show the components diagnosis after algorithms processing. The expert system is based on: Fuzzy Inference System; Adaptive Neural-Fuzzy Inference System; Fuzzy C-Means Algorithm; Fuzzy Equivalence Relation; Kohonen Fuzzy Neural Network; Multi-Layer Perceptron Neural Network and Fuzzy Neural Network.

From simulations of the diagnosis system, one may conclude that: the Fuzzy Neural Network, the Fuzzy Inference System and the Kohonen Model got the greatest results in terms of correct diagnosis (performance); the Kohonen model presented the fastest training time.

The propose for real implementing of the circuit breakers diagnosis system was then analyzed. The power deliver substation maintenance team could utilize such system, and it could provide preventive and proactive maintenance. The system could bring lower costs, reduce idling periods, avoid unnecessary disconnections, and increase system reliability. Also, the people availability to the maintenance could be scheduled.

LISTA DE FIGURAS

FIGURA 2.1: Principais partes funcionais de um disjuntor de alta tensão	21
FIGURA 2.2: Origem das falhas em disjuntores.....	24
FIGURA 2.3: Diagrama dos sinais propostos a serem monitorados	29
FIGURA 2.4: Estrutura de um sistema de monitoramento e formas dos sinais monitorados	30
FIGURA 2.5: Estrutura do sistema de monitoramento instalado na ETEO.....	31
FIGURA 3.1: Fluxograma de diagnóstico para disjuntores com acionamento hidráulico.....	43
FIGURA 3.2: Fluxograma de diagnóstico para disjuntores com acionamento a mola.	44
FIGURA 3.3: Estrutura do sistema de monitoramento e diagnóstico proposto	45
FIGURA 3.4: Estrutura conceitual de diagnóstico de faltas baseado em modelo.....	47
FIGURA 3.5: Estrutura básica do sistema de diagnóstico utilizando redes neurais	50
FIGURA 3.6: Arquiteturas de redes neurais utilizadas para o diagnóstico de faltas	51
FIGURA 3.7: Estrutura do software DataEngine.....	55
FIGURA 3.8: Diferença entre a abordagem clássica e a abordagem fuzzy	58
FIGURA 3.9: Função de pertinência trapezoidal	59
FIGURA 3.10: Função de pertinência triangular	59
FIGURA 3.11: Função de pertinência gaussiana	60
FIGURA 3.12: Função de pertinência sigmoidal	60
FIGURA 3.13: Variáveis lingüísticas.....	61
FIGURA 3.14: Diagrama de blocos de um Sistema de Inferência Fuzzy	63
FIGURA 3.15: Sistema de Inferência Fuzzy de Mamdani.....	64
FIGURA 3.16: Métodos de defuzzificação.....	65
FIGURA 3.17: Sistema de Inferência Fuzzy de Takagi e Sugeno	67
FIGURA 3.18: Estrutura da rede ANFIS	68
FIGURA 3.19: Aplicação do Fuzzy C-means para determinação dos grupos (clusters)	72
FIGURA 3.20: Ilustração da árvore de cluster ou dendograma do exemplo dado.....	80
FIGURA 3.21: Agrupamento de dados pelo método de relações de equivalência fuzzy	80
FIGURA 3.22: Diagrama ilustrativo de mapa de Kohonen	82
FIGURA 3.23: Diagrama ilustrativo da camada de Kohonen.....	83

FIGURA 3.24: Estrutura de uma rede neural perceptron de múltiplas camadas	85
FIGURA 3.24: Estrutura básica de uma rede neural fuzzy	89
FIGURA 4.1: Funções de pertinência das variáveis do disjuntor do tipo FA1	93
FIGURA 4.2: Funções de pertinência das variáveis do disjuntor do tipo LTB.....	93
FIGURA 4.3: Estrutura do Sistema de Inferência Fuzzy para o disjuntor do tipo FA1	94
FIGURA 4.4: Processo de inferência fuzzy	95
FIGURA 4.5: Estrutura construída para o ANFIS	98
FIGURA 4.6: Resultados obtidos pelo algoritmo Fuzzy C-means	101
FIGURA 4.7: Ilustração do dendograma do exemplo dado..	105
FIGURA 4.8: Estrutura da Rede Neural Kohonen Fuzzy	109
FIGURA 4.9: Estrutura da Rede MLP para o diagnóstico de disjuntores.....	112
FIGURA 4.10: Estrutura da Rede Neural Fuzzy para o diagnóstico de disjuntores	115
FIGURA 5.1: Oscilografia da corrente de interrupção e tempos relacionados a abertura.	123
FIGURA 5.2: Estrutura básica do sistema proposto	124

LISTA DE TABELAS

TABELA 2.1: Tipos de mecanismos para abertura e fechamento do disjuntor	22
TABELA 2.2: Estatística de causas de falhas em disjuntores	26
TABELA 3.1: Sinais propostos a serem monitorados e indicação de defeitos	40
TABELA 3.2: Código para cada diagnóstico possível	41
TABELA 3.3: Valores limites das variáveis do disjuntor do tipo FA1 da Lorenzetti	42
TABELA 3.4: Valores limites das variáveis do disjuntor do tipo LTB da ABB	42
TABELA 3.5: Amostra de dados em um conjunto X	78
TABELA 4.1: Número de amostras geradas para cada tipo de falta do disjuntor FA1	91
TABELA 4.2: Número de amostras geradas para cada tipo de falta do disjuntor LTB	92
TABELA 4.3: Resultados obtidos pelo Sistema de Inferência Fuzzy (FIS)	96
TABELA 4.4: Resultados obtidos pelo Sistema de Inferência Fuzzy Neuro-Adaptativo	99
TABELA 4.5: Resultados obtidos pelo Fuzzy C-means	102
TABELA 4.6: Amostras de dados relacionadas ao disjuntor FA1	104
TABELA 4.7: Resultados obtidos pela Relação de Equivalência Fuzzy	106
TABELA 4.8: Resultados obtidos pela Rede Neural Kohonen Fuzzy	110
TABELA 4.9: Parâmetros usados na rede neural MLP	113
TABELA 4.10: Resultados obtidos pela Rede Neural MLP	114
TABELA 4.11: Resultados obtidos pela Rede Neural FNN	116
TABELA 4.12: Resumo dos resultados obtidos para o diagnóstico do disjuntor FA1	118
TABELA 4.13: Resumo dos resultados obtidos para o diagnóstico do disjuntor LTB	118

LISTA DE SIGLAS E DEFINIÇÕES

- **ABNT** – Associação Brasileira de Normas Técnicas
- **ANFIS** - Adaptative Neuro-Fuzzy Inference System
- **CEMIG** – Companhia Energética de Minas Gerais
- **CIGRÉ** – Conseil International des Grands Réseaux Electriques
- **ETEO** - Empresa de Transmissão de Energia do Oeste Paulista
- **FCM** – Fuzzy C-Means
- **FDI** – Fault Detection and Isolation
- **FFT** – Fast Fourier Transform
- **FIS** – Fuzzy Inference System
- **FNN** – Fuzzy Neural Network
- **IEC** – International Electrotechnical Commission
- **IEEE** – Institute of Electrical and Electronic Engineers
- **MLP** – Multi Layer Perceptron
- **PCA** – Principal Components Analysis
- **PLC** – Programmable Logic Controller
- **RNA** – Rede Neural Artificial
- **SOM** – Self-Organizing Map
- **UHF** – Ultra High Frequency

SUMÁRIO

1. CONSIDERAÇÕES INICIAIS	13
1.1 Introdução	13
1.2 Objetivo	15
1.3 Relevância	16
1.4 Escopo	17
1.5 Metodologia.....	17
1.6 Estrutura do trabalho	19
 2. ESTADO DA ARTE	 20
2.1 Disjuntores de Alta tensão	20
2.2 Estatística de Falhas em Disjuntores de Alta Tensão.....	23
2.3 Técnicas de Monitoramento e Diagnóstico em Disjuntores.....	26
 3. PROPOSTA DE UM SISTEMA DE MONITORAMENTO E DIAGNÓSTICO DE DISJUNTORES	 36
3.1 Proposta para o Monitoramento dos Disjuntores	37
3.2 Inteligência Computacional na Detecção de Faltas	46
3.2.1 Lógica Fuzzy	56
3.2.2 Sistema de Inferência Fuzzy (FIS)	62
3.2.3 Sistema de Inferência Fuzzy Neuro-Adaptativo	66
3.2.4 Clusterização Fuzzy	70
3.2.4.1 Fuzzy C-means.....	71
3.2.4.2 Relações de Equivalência Fuzzy.....	76
3.2.5 Mapa Auto Organizável de Kohonen.....	81
3.2.6 Rede Perceptron de Múltiplas Camadas	84
3.2.7 Sistemas Neuro-fuzzy e Redes Neurais Fuzzy (FNN)	87

4. IMPLEMENTAÇÃO DAS TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL NO SISTEMA DE DIAGNÓSTICO.....	90
4.1 Formação da Base de Dados	91
4.2 Técnicas de Inteligência Computacional Aplicadas no Diagnóstico de Falhas de Disjuntores de Alta Tensão.....	92
4.3 Sistema de Inferência Fuzzy (FIS) Aplicado ao Diagnóstico de Falhas de Disjuntores de Alta Tensão.....	92
4.4 Sistema de Inferência Fuzzy Neuro-Adaptativo (ANFIS) Aplicado ao Diagnóstico de Falhas de Disjuntores de Alta Tensão	97
4.5 Fuzzy C-means Aplicado ao Diagnóstico de Falhas em Disjuntores de Alta Tensão.....	99
4.6 Relações de Equivalência Fuzzy Aplicada ao Diagnóstico de Falhas em Disjuntores de Alta Tensão.....	102
4.7 Modelo de Kohonen Aplicado ao Diagnóstico de Falhas em Disjuntores de Alta Tensão	106
4.8 Rede Neural Perceptron Multicamada Aplicada ao Diagnóstico de Falhas em Disjuntores de Alta Tensão.....	110
4.9 Rede Neural Fuzzy Aplicada ao Diagnóstico de Falhas em Disjuntores de Alta Tensão	114
4.10 Análise Comparativa dos Resultados Obtidos pelas Técnicas Propostas a Serem Utilizadas para o Diagnóstico de Disjuntores	116
5. CONCLUSÕES E PROPOSTA PARA A CONTINUIDADE DO TRABALHO	120
5.1 Conclusões	121
5.2 Proposta para Continuidade de Trabalho	122
REFERÊNCIAS	126
ANEXO I – RELAÇÃO MAX-MIN TRANSITIVA	132
ANEXO II – ALGORITMO DE RETROPROPAGAÇÃO (BACKPROPAGATION).....	134

1. CONSIDERAÇÕES INICIAIS

1.1 Introdução

As atuais exigências de mercado e a visão de mercado futuro têm levado as grandes concessionárias de energia elétrica a investirem em pesquisa, com o objetivo de assegurar a qualidade da energia entregue, a performance do sistema elétrico e, ao mesmo tempo, reduzir custos de operação. Uma das formas de alcançar este objetivo é a implantação de programas de manutenção preditiva em equipamentos instalados nas subestações, ou seja, uma manutenção baseada na condição de operação desses equipamentos.

Ressalta-se que dentre os equipamentos, tais como transformadores, geradores e disjuntores inerentes ao sistema elétrico, deve-se dar atenção destacada aos disjuntores, que atuam como elementos de chaveamento de linhas de transmissão e distribuição. Responsáveis pela proteção e por manobras na reconfiguração dos sistemas elétricos ocupam, portanto, um nível de importância relevante dentre os mesmos.

Neste contexto, o constante monitoramento dos disjuntores torna-se essencial para uma correta avaliação do seu estado operativo, tendo como finalidade aumentar a confiabilidade do sistema e reduzir custos de operação.

É fato indiscutível que os disjuntores estão entre os equipamentos de maior complexidade dentre aqueles em uso em sistemas de potência. Esta complexidade está presente na concepção do disjuntor, seja na sua câmara de extinção e suas diversas tecnologias de princípio de extinção do arco (gás SF₆, óleo mineral, ar comprimido, vácuo e sopro magnético), seja no seu sistema de acionamento em suas múltiplas formas e princípios (acionamento a mola, ar comprimido, hidráulico e solenóide), cuja tarefa é movimentar massas, às vezes gigantescas, em alguns milissegundos, com todos os problemas dinâmicos e inerciais daí decorrentes. Além disso, menciona-se seu sistema de comando e supervisão que tem o objetivo de assegurar

condições adequadas de operação para o equipamento, dentro de normas de segurança. Pode-se dizer, então, que, de maneira geral, os disjuntores se constituem dos seguintes subconjuntos principais: (1) unidade de comando, (2) sistema de acionamento ou mecanismo de operação e (3) unidades interruptoras. (COLOMBO, 1986)

Técnicas de monitoramento, bem como métodos de identificação e localização de defeitos em disjuntores, estão sendo objeto de pesquisa desde o final da década de 80, com: (LAI et al., 1988) e (GOTO et al., 1989), até datas recentes com: (KIM et al., 2002), (DEWULF et al., 2003) e (SERNA, 2005), onde, estes últimos, desenvolveram sistemas de monitoramento completos, capazes de acessar os componentes dos subconjuntos principais dos disjuntores, possibilitando, assim, a determinação das condições de operação dos mesmos. A concepção desses sistemas, porém, varia de acordo com o fabricante de disjuntores e com as diferentes tecnologias de interrupção e acionamento, o que, às vezes, torna-os complexos e economicamente inviáveis à maior parte dos disjuntores, ficando restritos àqueles instalados em pontos críticos do sistema elétrico.

Com base no exposto, evidencia-se a necessidade do desenvolvimento do estudo de uma metodologia para a implementação de um sistema de monitoramento para auxiliar a equipe de manutenção na determinação das condições de operações e projeção de vida útil dos disjuntores que seja eficiente e, ao mesmo tempo, de baixo custo de implementação.

Assim, fez-se uma pesquisa junto à concessionária local e verificou-se que subestações automatizadas, como algumas existentes nas concessionárias de energia elétrica, dispõem de dispositivos chamados relés digitais responsáveis pela percepção da corrente de falta (curto-circuito) na linha de transmissão, bem como pelo comando de atuação (operação) dos disjuntores, caso alguma corrente de falta venha a ocorrer. Esses dispositivos são capazes de registrar e oscilografar correntes de falta, assim como o tempo de atuação do disjuntor. O monitoramento desses valores é de grande importância na obtenção da condição de operação dos disjuntores e pode ser realizado com recursos já existentes em algumas subestações.

Alguns disjuntores já vêm de fábrica com sensores incorporados, como é o caso do disjuntor FA1 da Lorenzetti. Este disjuntor possui na câmara de extinção, um sensor de pressão

do gás SF₆ e um sensor de pressão do óleo no seu sistema de acionamento. O monitoramento dessas variáveis, também, é de grande importância na obtenção da condição de operação dos disjuntores e pode ser realizado sem alteração nas características construtivas dos mesmos.

A partir destas informações associadas às dos fabricantes de disjuntores, verifica-se que se pode propor a elaboração de um mecanismo de inferência, a partir do qual pode-se estruturar um sistema especialista para auxiliar na determinação das condições de operação dos disjuntores. Na construção desse sistema, podem ser utilizadas técnicas FDI¹ qualitativas tais como Lógica Fuzzy, Redes Neurais e Sistemas Híbridos (Neuro-fuzzy) como ferramentas para auxiliar na classificação de faltas e tomada de decisões, uma vez que tais técnicas têm-se mostrado eficientes em problemas de classificação de padrões, associados à aplicação de detecção de faltas em processos não lineares e com incertezas.

1.2 Objetivo

O objetivo geral deste trabalho é propor uma metodologia para o desenvolvimento de um sistema de monitoramento para determinar as condições de operação dos disjuntores, levando-se em consideração a disponibilidade de informações inerentes ao centro de operação do sistema de energia elétrica sem a necessidade de alteração física nos disjuntores através do uso de técnicas de inteligência computacional baseadas em modelos qualitativos, que possibilitam reunir um universo de variáveis e inferir diagnósticos importantes sobre o objeto de interesse, para que, posteriormente, seja implementado.

¹ Do inglês Fault Detection and Isolation

1.3 Relevância

Os disjuntores de alta tensão são os principais dispositivos de segurança de um sistema elétrico de potência. Normalmente, eles são sujeitos às freqüentes operações de abertura e fechamento, tornando-se suscetíveis à ocorrência de falhas, devido ao processo natural de envelhecimento e aos esforços aos quais eles são submetidos com o passar dos anos.

As concessionárias de energia elétrica têm-se deparado com a crescente carga de trabalho de manutenção nesse tipo de equipamento, associada à decrescente disponibilidade de recursos. Especificamente em relação aos disjuntores, as práticas de manutenção correntes são usualmente baseadas em intervalos de tempo fixos entre as inspeções dos mesmos, ou pelos valores determinados pelos contadores de operação do equipamento. Quando uma inspeção é levada a cabo, o disjuntor é retirado de serviço para a realização de testes que tipicamente consistem da verificação de tempos de abertura e de fechamento, percurso e velocidade do mecanismo de operação e testes dielétricos de forma geral. Associadas a esse tipo de procedimento, pode-se enumerar algumas desvantagens:

- O elevado custo, sempre exigindo vários homens-hora para inspeção do equipamento;
- O planejamento baseado em intervalos de tempo fixos ou números de manobras acumuladas pode resultar em testes desnecessários ou mesmo o contrário, isto é, inspeções realizadas quando o equipamento já se encontra deteriorado.

Dentro do objetivo apresentado, tem-se que o monitoramento e a determinação do estado operativo dos disjuntores instalados nos sistemas elétricos de potência podem possibilitar:

- A antecipação e prevenção da reconfiguração do sistema elétrico de potência;
- A redução de custos e paralisações desnecessárias;
- O auxílio nos planejamentos e procedimentos de manutenção;
- O aumento da vida útil do equipamento;
- O aumento da confiabilidade e segurança do sistema elétrico.

1.4 Escopo

O escopo deste trabalho se resume no desenvolvimento de um estudo e metodologia para a implementação de um sistema para auxiliar na determinação das condições de operação dos disjuntores, através da análise do contexto no qual eles estão inseridos, aliada às especificações de projeto e às facilidades permitidas pelas novas tecnologias de monitoramento, utilizando técnicas FDI baseadas em modelos qualitativos para a construção de um sistema especialista, e variáveis já monitoradas e disponíveis no centro de operação da concessionária de energia elétrica.

1.5 Metodologia

A escolha dos sinais propostos a serem monitorados teve como base resultados de pesquisas estatísticas como a do CIGRÉ 13.06, que relata os componentes dos disjuntores responsáveis pelas falhas mais frequentes, estudos junto à concessionária de energia elétrica local (CEMIG), verificando-se os sinais que podem ser obtidos (monitorados) com recursos já existentes nas subestações, e estudos do funcionamento e da concepção do disjuntor, indicando os sinais possíveis de se monitorar sem a necessidade de alteração nas características construtivas do mesmo.

As simulações do sistema especialista (sistema de diagnóstico) foram realizadas através da aplicação das técnicas de Fuzzy C-means, Modelo de Kohonen, Relações de Equivalência Fuzzy, Sistema de Inferência Fuzzy (FIS²), Rede Neural Perceptron de Múltiplas Camadas (MLP³), Sistema de Inferência Fuzzy Neuro-adaptativo e Redes Neurais Fuzzy. As simulações foram realizadas com base em dados gerados, referentes às variáveis propostas a serem monitoradas, tomando-se como faixas de valores limites áqueles contidos nos manuais e catálogos dos fabricantes e através do estudo dos guias IEEE Std. C37.10-1995 e IEEE Std.

² Do inglês Fuzzy Inference System

³ Do inglês Multi Layer Perceptron

C37.10.1-2000, onde o primeiro trata de procedimentos referentes à investigação de diagnóstico de falhas em disjuntor, e o segundo trata de procedimentos referentes ao monitoramento de disjuntores.

Com isso, o trabalho foi dividido em seis fases, ordenadas cronologicamente a seguir:

Primeira fase: Esta fase constituiu no estudo e no levantamento bibliográfico das técnicas de monitoramento e diagnóstico de disjuntores que vêm sendo abordadas desde o final da década de 80, bem como na obtenção de informações de pesquisas relacionadas à estatística de falhas e guias padrões regulamentados pelo IEEE.

Segunda fase: Estudo dos mecanismos de funcionamento dos vários tipos de disjuntores.

Terceira fase: Esta fase constituiu-se numa revisão teórica dos princípios das técnicas de inteligência computacional tais como: Lógica Fuzzy, Redes Neurais e Sistemas Neuro-Fuzzy, a serem utilizadas no sistema especialista que determinará a condição de operação dos disjuntores a partir das variáveis propostas a serem monitoradas.

Quarta fase: Levantamento de informações junto à concessionária local relativas aos sinais que podem ser monitorados com recursos já existentes nas subestações e à faixa de valores nominais de atuação dos componentes do disjuntor, a partir do estudo de manuais e catálogos.

Quinta fase: Simulação das técnicas FDI propostas a serem utilizadas, a partir de dados gerados.

Sexta fase: Redação do relatório final da pesquisa em forma de dissertação.

1.6 Estrutura do trabalho

Este trabalho está organizado da seguinte forma:

- No Capítulo 1, foi feita uma breve introdução do problema proposto, bem como a apresentação da relevância, do escopo, dos objetivos e da metodologia deste trabalho;
- No Capítulo 2, é apresentada uma introdução que envolve os conceitos e o funcionamento dos mecanismos dos disjuntores, resultados de pesquisas de estatística de falhas e a revisão das técnicas de monitoramento e diagnóstico de disjuntores.
- No Capítulo 3, é apresentada a proposta de desenvolvimento de um sistema de monitoramento e diagnóstico de disjuntores, bem como os fundamentos teóricos sobre as técnicas de inteligência computacional propostas a serem aplicadas na construção do sistema especialista.
- No Capítulo 4, é apresentado o modo como as técnicas de inteligência computacional FDI baseadas em modelos qualitativos podem ser utilizadas na detecção de defeitos nos disjuntores, bem como os resultados das simulações realizadas.
- No Capítulo 5, são apresentadas as conclusões do trabalho, bem como a proposta de continuidade do mesmo.

2. ESTADO DA ARTE

2.1 Disjuntores de Alta tensão

Esta subseção fornece uma breve introdução da função e do funcionamento dos disjuntores de alta tensão, e é principalmente focada aos leitores que não estão familiarizados com esse tipo de equipamento, com o objetivo de explicar as principais propriedades e os desafios associados a eles. Uma abordagem mais detalhada sobre o assunto pode ser encontrada em (MILACH, 1993) e (COLOMBO, 1986).

Os disjuntores são dispositivos de chaveamento elétrico que devem ser capazes de conduzir, interromper e estabelecer correntes na rede de energia elétrica, incluindo as altas correntes de falta (curto-circuito). São freqüentemente instalados ao tempo, permanecendo meses no estado estacionário ligado, conduzindo a corrente nominal sob condições climáticas das mais variadas, proporcionando, às vezes, variações de temperatura de dezenas de graus centígrados, agentes atmosféricos agressivos a vários de seus componentes e outras condições adversas. Mesmo sob essas condições, quando requisitados a operar, eles devem estar prontos para mudar o seu estado de fechado para o aberto interrompendo, assim, o fluxo de corrente no sistema elétrico no qual ele está inserido, ou de aberto para fechado restabelecendo o fluxo de corrente do sistema, em questão de milisegundos, atendendo todos os requisitos preestabelecidos por normas e padrões internacionais como aqueles estabelecidos pela (INTERNATIONAL STANDARDS IEC 56, 1987).

Por definição, os disjuntores de alta tensão são projetados a operar em linhas de transmissão com classe de tensão acima de 63 kV, e interromper correntes de falta na escala de 40 – 63kA, às vezes correntes superiores a 100kA caracterizando-se, assim, como os principais dispositivos de segurança do sistema elétrico, prevenindo contra e danos a outros equipamentos. No entanto, a demanda na sua confiabilidade é alta, pois, o funcionamento inadequado deste dispositivo pode causar danos incalculáveis no sistema elétrico.

Os disjuntores são constituídos de três subconjuntos principais que caracterizam seu funcionamento, como mostrado a seguir:

1. Unidades interruptoras: também chamadas de câmaras de extinção, é onde ocorre a extinção do arco voltaico produzido durante a interrupção de corrente e podem ser de diversas tecnologias: gás SF₆, óleo mineral, vácuo, ar comprimido ou sopro magnético;

2. Sistema de acionamento ou mecanismo de operação: é o subconjunto constituído de componentes que possibilitam o armazenamento da energia necessária à operação mecânica do disjuntor, bem como à liberação dessa energia através de mecanismos apropriados, quando enviado o comando de abertura e fechamento do mesmo e pode ser de diversas formas: acionamento a mola, a ar comprimido, hidráulico ou por solenóide;

3. Unidade de comando e circuitos auxiliares: constituída dos elementos de comando, controle e supervisão do disjuntor.

A figura 2.1 ilustra o modo como estão divididas as principais partes do disjuntor.




FIGURA 2.1: Principais partes funcionais de um disjuntor de alta tensão
Fonte: (STANEK, 2000)

Os interruptores contêm componentes que trabalham em alta tensão conectados diretamente na rede de energia elétrica. Normalmente, existem dois grupos de contatos, um que assegura a passagem da corrente quando o disjuntor está na posição “fechado” e outro que conduz a corrente no momento da abertura do disjuntor (corrente de arco). A extinção do arco ocorre em meio isolante, como mencionado anteriormente. Esse meio pode conter o gás SF₆, o óleo mineral, vácuo, ou ar comprimido. No caso de disjuntores isolados a SF₆, durante a interrupção da corrente, esse gás é soprado contra o arco elétrico formado entre as partes dos contatos, com a finalidade de extingui-lo pelo seu resfriamento. A pressão do sopro necessária para a extinção do arco pode ser gerada por compressão mecânica, ou pelo calor produzido pelo arco (DUFOURNET, 1995). A principal vantagem desta tecnologia é a baixa energia mecânica requerida para as partes móveis, reduzindo, assim, o desgaste nas partes mecânicas móveis dentro do disjuntor.

A energia necessária para as operações de abertura e fechamento é fornecida pelo mecanismo de operação (sistema de acionamento) através dos mecanismos de transmissão. Essa energia é acumulada em dispositivos mecânicos denominados acumuladores de energia cujas formas são apresentadas na tabela 2.1. A operação se inicia quando é energizado o circuito de abertura (ou fechamento) por ação de um relé de proteção, ou através de um dispositivo de controle. Este sinal energiza a bobina de abertura (ou fechamento) a qual possui um mecanismo que ativa um solenóide quando a mesma está totalmente energizada, liberando dessa maneira a energia armazenada no acumulador de energia e transferindo-a aos mecanismos de transmissão, os quais são responsáveis pelo movimento dos contatos, proporcionando, assim, as operações de abertura ou fechamento em alguns milisegundos.

TABELA 2.1: Tipos de mecanismos para abertura e fechamento do disjuntor

Abertura	Fechamento
Mola	Mola
Mola	Hidráulico
Mola	Solenóide
Ar comprimido	Mola
Hidráulico	Hidráulico
Ar comprimido	Ar comprimido

Os componentes dos circuitos de comando e supervisão do disjuntor têm a finalidade de assegurar a correta operação do disjuntor em termos físicos e lógicos sob todas as circunstâncias. Aquecedores com termostatos e chaves auxiliares do pressostato que mede a pressão do gás SF₆ podem ser dados como exemplos de componentes que têm a característica de assegurar a correta operação em termos físicos. Já circuitos lógicos de anti-bombeamento, que previnem contra seguidas operações de abertura e fechamento dos disjuntores, nos casos em que as bobinas de abertura e fechamento permaneçam permanentemente energizadas, podem ser dados como exemplo de componentes que asseguram o correto funcionamento do disjuntor em termos lógicos.

2.2 Estatística de Falhas em Disjuntores de Alta Tensão

Segundo o guia IEEE Std.C37.10-1995, que trata de procedimentos referente à investigação de diagnósticos e falhas em disjuntores, as ocorrências de falhas mais comuns são:

1. O disjuntor não fecha sob comando;
2. O disjuntor fecha sem ser efetuado o comando;
3. O disjuntor falha no fechar propriamente dito;
4. O disjuntor falha em se manter fechado – abertura não intencional;
5. O disjuntor não abre sob comando;
6. O disjuntor abre sem ser efetuado o comando;
7. O disjuntor falha no abrir propriamente dito;
8. O disjuntor falha em se manter aberto – fechamento não intencional.

Os fabricantes e os usuários de disjuntores de alta tensão vêm tendo um grande interesse em descobrir as causas mais comuns de falhas em seus equipamentos. Enquanto os fabricantes querem saber como melhorar seu produto, os usuários necessitam desta informação para desenvolver estratégias de manutenção.

Em vista disso, algumas pesquisas sobre o assunto foram realizadas pelo CIGRÉ. Segundo (HEISING et al., 1994), a primeira dessas pesquisas foi realizada entre os anos de 1974 e 1977, a partir de uma base de dados de observações realizadas em 20.000 disjuntores com classe de tensão superior a 63 kV. Os resultados dessa pesquisa mostraram que 70% das falhas mais freqüentes em disjuntores têm como origem fatores mecânicos, 19% são relacionadas aos circuitos de controle e auxiliares e 11% a fatores elétricos do circuito principal (componentes de alta tensão). A segunda pesquisa foi realizada entre os anos de 1988 e 1991 em 18.000 disjuntores isolados a SF₆ e classe de tensão superior a 63 kV. Os resultados dessa segunda pesquisa mostraram diferenças em relação à pesquisa anterior, como mostrado nos gráficos da figura 2.2:




FIGURA 2.2: Origem das falhas em disjuntores

As terminologias utilizadas pelo CIGRÉ têm os seguintes significados:

- **Falha Maior:** Falha completa de um disjuntor, que ocasiona o desaparecimento completo de uma ou várias de suas funções fundamentais.
- **Falha Menor:** Mudança nas características nominais de componentes ou subconjuntos do disjuntor, mas que não caracterizam uma falha maior.

Neste trabalho, a *falha maior* será tratada como uma falha no disjuntor e a *falha menor* será tratada como um defeito ou falta no mesmo.

Segundo (BRANCO, 1996), a falta (ou defeito) e a falha têm os seguintes significados:

- **Falta:** é a alteração das condições de um item, equipamento ou sistema operacional, de importância suficiente para que sua função normal não seja satisfatória. Uma falta não torna o equipamento indisponível mas, se não reparada ou se não corrigida, levará o equipamento à uma falha e à conseqüente indisponibilidade.
- **Falha:** É a perda da capacidade de um item para realizar sua função específica. É a diminuição total ou parcial da capacidade de uma peça, componente ou equipamento de desempenhar a sua função durante um período de tempo, onde o item deverá sofrer manutenção ou ser substituído. A falha leva o item ao estado de indisponibilidade.

Com relação ainda à segunda pesquisa realizada pelo CIGRÉ, a tabela 2.2, publicada no guia (IEEE Std.C37.10-1995) e aqui transcrita fornece uma visão geral dos componentes nos disjuntores responsáveis pelas falhas mais freqüentes.

TABELA 2.2: Estatística de causas de falhas em disjuntores.

Mecanismos de operação	43 – 44 %
Sistema Hidráulico, bombas, compressores, etc.	13,6–18,7 %
Acumuladores de energia;	7,2-7,6%
Elementos de controle;	9,3-11,6%
Atuadores, dispositivos de amortecimento;	5,1-8,9%
Transmissão mecânica.	1,4-3,8%
Componentes de alta tensão	21-31%
Interruptores;	9,4-14%
Interruptores auxiliares e resistores;	0,6-1,3%
Isolação.	5,7-20,9%
Circuitos de controle e auxiliares	20-29%
Circuitos de fechamento e abertura;	1,5-10%
Contatos auxiliares;	2,1-7,4%
Contatores, aquecedores, etc.	5,4-7,6%
Monitores de densidade do gás SF ₆ .	4,0-10,7%
Outras Causas	5,4-6,8%

Os resultados obtidos nessas pesquisas permitem-nos concluir que a maioria das falhas nos disjuntores estão associadas aos componentes dos mecanismos de operação e aos componentes de alta tensão, destacando-se o sistema de acionamento e o sistema de gás SF₆.

2.3 Técnicas de Monitoramento e Diagnóstico em Disjuntores

Com o propósito de conhecer os estudos referentes aos sistemas de monitoramento e diagnóstico em disjuntores de alta tensão, foram pesquisados alguns dos principais trabalhos realizados. Esta subseção busca abordar os principais pontos no que se refere a essas aplicações.

Técnicas de monitoramento, bem como métodos de identificação e localização de defeitos em disjuntores têm sido objeto de pesquisa desde o final da década de 80.

O autor (LAI et al., 1998) afirma que o mau funcionamento das partes mecânicas dos disjuntores é a principal causa de falhas e propõe técnicas não intrusivas de monitoramento, as quais podem determinar as condições mecânicas dos mesmos, coletando sinais acústicos de

vibrações durante os eventos de abertura e fechamento, através de sensores acelerômetros acoplados na parte exterior dos pólos e da caixa de comando dos disjuntores.

Os autores (DEMAJANENKO et al., 1992), (RUNDE et al., 1992) e (LEE et al., 2003) seguiram essa mesma linha de aplicação de técnicas de monitoramento de sinais acústicos, porém, utilizaram métodos diferentes para a análise dos sinais e classificação de defeitos como, por exemplo: o uso de FFT⁴ para o processamento dos sinais, distância euclidiana para o cálculo do desvio do sinal lido com o sinal de condição normal e redes neurais para a classificação dos tipos de defeitos nos disjuntores.

Essas técnicas possuem a vantagem de não modificar a estrutura do equipamento durante a medição dos sinais, porém, os testes para a implementação devem ser realizados em fábrica, com o disjuntor desenergizado, para que sejam simulados os defeitos em seus mecanismos de operação. Constatou-se também que, nas subestações onde os disjuntores estão instalados, existe a ocorrência de ruídos, os quais podem interferir fortemente na análise dos sinais.

Segundo (OHSHITA et al., 1989) e (YAMAGIA et al., 1991), as condições de operação das unidades interruptoras podem ser determinadas através do monitoramento de descargas parciais durante a condução de corrente através dos contatos principais. Essas são provocadas por partículas flutuantes no interior da câmara de extinção e/ou por contatos desgastados. Os autores (UTSUMI et al., 1993) e (OZAWA et al., 1994) utilizaram detectores de ondas eletromagnéticas (sinais UHF⁵) que são provocadas pelas descargas parciais com o intuito de detectá-las e localizá-las no interior da câmara de extinção. As desvantagens desses métodos são caracterizadas por alterarem as condições construtivas do disjuntor, diminuindo a sua confiabilidade, pois é necessário que sejam instalados sensores dentro das câmaras de interrupção dos disjuntores.

Além dos sinais comentados anteriormente, existem vários outros que podem ser monitorados para a detecção de um mau funcionamento de componentes do disjuntor, tais

⁴ Do inglês Fast Fourier Transform

⁵ Do inglês Ultra High Frequency

como: tempos de abertura e fechamento do disjuntor, pressão dos gás SF₆, tempo de operação da bomba do sistema de acionamento hidráulico, dentre outros, conforme proposto em (GOTO et al., 1989).

Fazendo-se uma correta análise desses sinais e comparando-os com as faixas de valores nominais especificadas pelos fabricantes, pode-se detectar defeitos incipientes no disjuntor e classificá-los como sendo de origem mecânica nos dispositivos de comando e de armazenamento de energia, elétrica nos circuitos principais, ou elétrica nos circuitos de controle e supervisão.

Desde então, vários trabalhos vêm sendo publicados confirmando a aplicabilidade do monitoramento desses sinais para a determinação da condição de operação dos disjuntores e relatando as novas tecnologias de monitoramento que vêm sendo introduzidas nas concessionárias de energia elétrica.

As pesquisas sobre monitoramento e diagnóstico em disjuntores de alta tensão são, na sua maioria, direcionadas a disjuntores a SF₆ devido à sua demanda. Os autores (HENSMAN e GALE, 1993), (MCLLOROY et al., 1994), (REASON, 1996), (GRIJP et al., 1996) e (KATSCHINSKI et al., 1998) propuseram ou relataram a aplicação de sistemas de monitoramento *on-line* para esse tipo de disjuntor. Na figura 2.3, é apresentada uma ilustração indicando os sinais propostos por esses autores para se efetuar o monitoramento, bem como mostrar qual subconjunto do disjuntor cada sinal pode acessar e indicar a condição de operação.




FIGURA 2.3: Diagrama dos sinais propostos a serem monitorados

Sistemas utilizando PLCs⁶ para a supervisão e monitoramento de disjuntores são mencionados por (ENGEL et al., 1999) e (SOLIS et al., 2003).

O autor (NELSON, 2001) descreve todas as precauções que devem ser tomadas no momento da instalação de um sistema de monitoramento no disjuntor, bem como menciona o detalhamento de quais equipamentos estão atualmente disponíveis para tal finalidade. Além disso, lista as informações disponíveis para determinar o que monitorar e as expectativas e benefícios como resultado da implantação de um sistema de monitoramento no disjuntor.

Os trabalhos de (POELT e HAINES, 2001), (DUPRAZ et al., 2001) e (DEWULF et al., 2003) mostram a aplicação de sistemas eletrônicos capazes de monitorar todas as funções do disjuntor, a fim de se obter diagnósticos precisos a partir da análise dos sinais monitorados. Os trabalhos do primeiro e segundo autores são exemplos desses sistemas instalados em disjuntores

⁶ Do inglês Programmable Logic Controller

da ABB de 500 kV e disjuntores da ALSTOM de 345 kV, respectivamente. Nos dois casos, faz-se menção à utilização de equipamentos específicos CMU (Condition Monitoring Unit) e CBWatch para realizar o monitoramento integral do disjuntor. A figura 2.4 ilustra um exemplo de um sistema eletrônico de monitoramento que pode ser aplicado a um disjuntor a SF₆ com o sistema de acionamento a mola carregada por motor elétrico e mostra a forma dos sinais monitorados.




FIGURA 2.4: Estrutura de um sistema de monitoramento e formas dos sinais monitorados
Fonte: (Apresentação da ABB realizada na CEMIG)

A supervisão é feita por meio de equipamentos digitais e sensores especiais que são instalados próximos ao disjuntor, os dados são coletados e processados em uma placa de aquisição de dados para, posteriormente, através de uma rede de comunicação, serem enviados a um computador central. Esse computador é integrado a um programa dedicado de supervisão que permite transformar os dados coletados pelo sistema de monitoramento em informação, continuamente calculando e apresentando o estado dos componentes do disjuntor monitorado,

na forma de curvas, gráficos ou diagramas, de maneira a possibilitar uma avaliação da condição real do disjuntor.

Milthon Serna, em sua tese de doutorado (SERNA, 2005) apresenta o desenvolvimento de um sistema de monitoramento de disjuntor e a análise das características das variáveis que são monitoradas através de sensores ligados ao disjuntor, sua aquisição e o tratamento das informações. Embora o conceito deste tipo de sistema tenha sido descrito em algumas publicações, esse trabalho contribuiu com soluções inéditas, podendo citar: o sensoriamento para a medição de corrente no circuito de comando do disjuntor; a implementação de placas de entradas analógicas para a aquisição de dados com resolução de 1ms e a utilização de ferramentas matemáticas (Transformada Wavelet e Transformada de Fourier) na análise dos tempos envolvidos na operação do disjuntor. O protótipo desse sistema foi instalado na subestação de Sumaré 440 kV da ETEO (Empresa de Transmissão de Energia do Oeste Paulista) e a arquitetura geral do sistema é mostrada na figura. 2.5:




FIGURA 2.5: Estrutura de um sistema de monitoramento instalado na ETEO
Fonte: (SERNA, 2005)

Nas pesquisas realizadas pelos grupos de trabalho CIGRÉ 23-203 (JONES et al, 1996), IEEE Std. C37.10-1995 e IEEE Std. C37.10.1-2000, são identificadas várias opções de monitoramento dos disjuntores, assim como os sinais que podem ser monitorados *on-line* e os tipos de sensores utilizados no monitoramento desses sinais. São apontadas ainda a importância de cada sinal monitorado, o esforço da aplicação de cada técnica de monitoramento, os benefícios, os custos, bem como as faltas que cada tipo de sinal pode identificar, fazendo-se uma correta análise dos mesmos. A seguir, é apresentado um resumo do que foi abordado nos trabalhos citados e em (SERNA, 2005), mostrando os sinais mais importantes a serem monitorados.

a) *Correntes das bobinas de abertura e fechamento*

A magnitude e as formas de onda das bobinas podem ser monitoradas para identificar a integridade das bobinas de abertura e fechamento, a condição dos circuitos de controle e alguma fricção ou travamento de chaves ou contatos auxiliares. O monitoramento pode ser realizado *on-line* e, para isso, normalmente se aplicam dois métodos: um através de sensores de corrente de efeito hall e outro conectando-se resistores auxiliares em série aos circuitos das bobinas, sendo que, este segundo método pode provocar atuações indevidas e, por isso, não tem sido uma prática bem aceita pelas concessionárias. Benefício – Alto e Esforço – Médio.

b) *Deslocamento dos contatos principais*

O deslocamento dos contatos pode ser medido através de sensores de percurso, sejam eles instalados na haste da coluna polar do disjuntor, ou instalados nas alavancas do mecanismo de acionamento. Assim, torna-se possível cronometrar o tempo de movimentação dos contatos a cada operação do disjuntor. Com isso, pode-se identificar alterações nas partes mecânicas do disjuntor, tais como: integridade do sistema de armazenamento de energia, condição do mecanismo de transmissão (lubrificação e corrosão), condição de hastes e posição dos contatos. Benefício – Alto e Esforço – Alto.

Entretanto, a colocação de sensores de percurso significa acrescentar um elemento a mais de risco na operação interna do disjuntor, diminuindo sua confiabilidade. Portanto, a

maneira mais recomendável de se efetuar essa medição é através de métodos não intrusivos. Nos trabalhos realizados por (SERNA, 2005) e (SHENG et al., 2005), foram apresentados métodos de obtenção dos tempos envolvidos na operação do disjuntor, através da análise das correntes de interrupção.

c) Correntes nas fases do circuito principal

A análise das oscilografias das correntes de cada fase permite identificar o instante aproximado de acontecimento da corrente de curto-circuito, o tempo total de interrupção da corrente em cada fase, além de possibilitar o cálculo do desgaste dos contatos mediante a relação (2.1). O monitoramento é *on-line* e os sinais podem ser obtidos através dos TC's (Transformadores de Corrente). Benefício – Alto e Esforço – Médio.

$$\sum_{k=1}^{k=n} \int_{ts}^{te} i(t)^2 dt \quad (2.1)$$

n – Número de operações por curto-circuito;

$i(t)$ – Corrente instantânea ;

ts – Instante da separação dos contatos;

te – Instante da extinção da corrente.

d) Pressão do gás SF_6

O bom funcionamento do sistema de gás SF_6 é de vital importância para que a corrente seja interrompida com sucesso. A variação da pressão do gás (ou densidade) pode afetar a isolamento interna diminuindo a capacidade de interrupção do disjuntor. No entanto, o monitoramento da pressão do gás permite estimar a taxa de variação do gás, podendo identificar algum vazamento e prever o momento no qual a pressão atingirá os valores limites especificados pelos fabricantes. O monitoramento é *on-line* e pode ser realizado por sensores de pressão ou densidade instalados nos pólos dos disjuntores. Benefício – Alto e Esforço – Médio.

e) *Tempos de abertura, fechamento e interrupção*

O tempo total de operação do disjuntor é compreendido entre o momento da energização da bobina até a comutação dos contatos auxiliares, estando estes sincronizados com os contatos principais. Durante o processo de abertura, existem vários estágios envolvidos, tais como: comando de abertura, ação da bobina, início da abertura dos contatos principais, arco interno, interrupção de corrente e fim da abertura dos contatos principais. Tais registros de tempo podem ser obtidos através da análise da oscilografia das correntes interrompidas, das correntes no circuito de disparo e da posição dos contatos auxiliares. O tempo de abertura é compreendido entre o instante da energização da bobina de abertura e o instante de separação dos contatos; o tempo de fechamento é compreendido entre o instante da energização da bobina de fechamento e o instante de união dos contatos; o tempo de interrupção é compreendido entre o instante da energização da bobina de abertura e o instante em que a corrente foi interrompida. Essas definições foram estabelecidas pela norma ABNT NBR-7718, (1994) relacionada a disjuntores de alta tensão. A mudança nos tempos de abertura, fechamento ou interrupção pode indicar defeitos nos mecanismos de operação do disjuntor. Benefício – Alto e Esforço – Médio.

f) *Monitoramento do sistema de acionamento*

No caso de disjuntores que utilizam a mola como acumulador de energia mecânica para a operação de abertura ou fechamento, é importante monitorar a pressão da mola. A compressão excessiva da mola pode indicar algum problema no mecanismo de compressão. Porém, não é recomendável a instalação de um sensor de pressão na mola, porque pode reduzir a confiabilidade no momento da operação. De modo alternativo, pode-se monitorar os demais componentes do sistema de compressão, como o sinal de corrente do motor no momento do carregamento da mola para casos de disjuntores com acionamento a mola carregada por motor elétrico. O monitoramento dessa variável pode identificar problemas no motor, na mola de disparo e identificar atritos no sistema de carregamento. E, para o caso de disjuntores com acionamento hidráulico (combinação óleo/N₂), o monitoramento da pressão do óleo pode registrar a variação do sistema motor-bomba durante a operação, permitindo identificar algum defeito no decorrer do processo, ou algum vazamento. Benefício - Alto e Esforço – Médio.

Uma das questões levantadas em (REASON, 1996) e (SHENG et al., 2005) é até quanto é justificado o investimento em compras de equipamento para aplicação de um sistema de monitoramento, uma vez que existem vários tipos de disjuntores e fabricantes diferentes, sendo necessários tipos diferentes de sistemas para cada tipo de disjuntor. Isto não dependeria apenas do custo de implantação do sistema comparado ao custo dos disjuntores, mas, também, dos recursos financeiros disponíveis nas concessionárias e da importância de um dado disjuntor perante o sistema elétrico.

Em vista disso e através da análise do estado da arte, procurou-se propor neste trabalho a escolha de itens para o monitoramento do disjuntor, levando-se em consideração as principais causas de falhas nos disjuntores; os itens que podem ser monitorados sem a necessidade de uma alteração nas características construtivas do equipamento e sinais que podem ser monitorados com recursos já existentes em algumas subestações; além de propor o uso de técnicas de inteligência computacional para a obtenção do diagnóstico do disjuntor através dos sinais monitorados.

A proposta para o monitoramento e os fundamentos teóricos relativos às técnicas de inteligência computacional a serem aplicadas para a detecção de faltas nos disjuntores são apresentados no capítulo 3, deste trabalho.

3. PROPOSTA DE UM SISTEMA DE MONITORAMENTO E DIAGNÓSTICO DE DISJUNTORES

A proposta para a escolha dos sinais a serem monitorados nos disjuntores e a base teórica necessária para o desenvolvimento do sistema de diagnóstico proposto são aqui apresentadas. Com a finalidade de se tratar de forma adequada os dados referentes aos sinais propostos a serem monitorados, desenvolveu-se algoritmos de classificação, utilizando a plataforma MATLAB. Esses algoritmos foram aplicados a uma base de dados gerados aleatoriamente que representam a faixa de valores relativa a esses sinais, tomando-se como exemplos dois tipos de disjuntores em situação normal e sob condição de faltas. Foram analisadas algumas técnicas de inteligência computacional que servirão de base para o desenvolvimento do sistema de diagnóstico a ser implementado, tais como: Rede Neural Kohonen Fuzzy, Fuzzy C-means, Relações de Equivalência Fuzzy, Sistema de Inferência Fuzzy (FIS), Rede Neural MLP, Sistema de Inferência Fuzzy Neuro-adaptativo e Redes Neurais Fuzzy.

3.1 Proposta para o Monitoramento dos Disjuntores

Conforme visto no capítulo anterior, existem vários sinais que podem ser monitorados para acessar a condição do disjuntor, e eles dependem essencialmente da tecnologia utilizada em cada disjuntor de acordo com o meio de extinção do arco, bem como do sistema de acionamento. Alguns sinais tais como: pressão do gás SF₆, pressão do óleo no sistema hidráulico e tensão nos circuitos de controle e auxiliares podem ser monitorados continuamente, e outros só podem ser coletados no evento de abertura ou fechamento, tais como: tempos de abertura, interrupção ou fechamento, correntes nas bobinas de abertura e fechamento, deslocamento dos contatos principais, corrente do motor e corrente de interrupção. Conforme pesquisa realizada junto à concessionária local, a maioria dos disjuntores de 138 kV instalados nas subestações possui o sistema de interrupção a SF₆ e o sistema de acionamento a mola carregada por motor elétrico, ou o sistema de acionamento hidráulico (fechamento hidráulico, abertura a mola). No entanto, a escolha dos sinais a serem monitorados baseou-se nesses dois tipos de disjuntores.

Como comentado anteriormente, os sistemas de monitoramento completos só são economicamente viáveis para disjuntores estrategicamente localizados e, para a coleta de alguns sinais, é necessária a inserção de sensores nos mecanismos de operação ou nos interruptores, o que pode diminuir a confiabilidade do equipamento. Com o intuito de se propor um monitoramento de baixo custo, que não altere a confiabilidade do equipamento e que possa identificar os principais defeitos nos disjuntores, os sinais a serem monitorados foram escolhidos levando-se em consideração os seguintes aspectos:

1. Verificação dos sinais que podem ser obtidos utilizando recursos já existentes em algumas subestações;
2. Escolha de sinais que possam identificar defeitos em componentes dos disjuntores que representam uma grande porcentagem nas causas de falhas;
3. Escolha de sinais que possam ser obtidos sem alteração nas características construtivas do equipamento.

A partir dessas considerações e com base na análise do estado da arte, observou-se que o monitoramento dos sinais descritos a seguir atende os requisitos colocados anteriormente:

1) Corrente de interrupção:

Fez-se uma pesquisa junto à concessionária local (CEMIG) e verificou-se que algumas subestações possuem relés digitais, responsáveis pela percepção de correntes de curto-circuito nas linhas de transmissão, bem como pelo comando de atuação (operação) dos disjuntores, caso alguma dessas correntes venha a ocorrer. Esses dispositivos são capazes de registrar as oscilografias dessas correntes e, a partir delas, pode-se obter o valor das correntes de curto-circuito e estimar o desgaste dos contatos de cada pólo mediante a relação (2.1).

2) Tempos de abertura e fechamento:

Os relés digitais também gravam o momento em que o disjuntor recebeu o comando de abertura ou fechamento e o momento em que o disjuntor abriu mecanicamente. A partir desses tempos e da análise das oscilografias das correntes, pode-se obter os tempos de abertura, interrupção de corrente e fechamento do disjuntor. A mudança desses tempos pode indicar um comportamento anormal do equipamento.

Nota: Na maioria das subestações, os relés digitais não monitoram a operação de fechamento do disjuntor, porém estes relés podem ser configurados para este fim, obtendo-se, assim, os tempos relacionados à operação de fechamento do equipamento.

A análise computacional das oscilografias das correntes de interrupção (registradas por relés digitais) para obtenção automática dos tempos relacionados à abertura e fechamento do disjuntor servirá como uma proposta para continuidade do trabalho, como sugerido no item 5.2 do capítulo 5.

3) Pressão do gás SF₆:

A maioria dos disjuntores com classe de tensão superior a 63 kV possui sensores capazes de medir a pressão do gás SF₆ nas câmaras de interrupção, portanto, a coleta desse sinal não alteraria a confiabilidade do disjuntor e, conforme visto nas pesquisas de estatística de

falhas, o sistema de gás SF₆ representa uma grande porcentagem das causas de falhas nos disjuntores. O monitoramento desse sinal pode ser feito continuamente e, através da análise do histórico dessa medição, pode-se estimar a taxa de variação da pressão do gás. A diminuição dessa pressão pode indicar algum vazamento do gás e o aumento pode indicar ocorrência de arco no interior da câmara provocado por desajuste, ou deformação nos contatos.

4) Pressão do óleo\N₂:

A maioria dos disjuntores com classe de tensão superior a 63 kV que possui o sistema de acionamento hidráulico (óleo/N₂) também possuem sensores capazes de medir a pressão do sistema óleo\N₂, ou, pelo menos, é possível instalar um sensor de pressão sem que seja necessária a alteração nas características construtivas do equipamento. De acordo com os resultados das pesquisas de estatísticas de falhas, conclui-se que o sistema de acionamento do disjuntor é um item importante a ser monitorado. Assim, como a pressão do gás SF₆, o monitoramento desse sinal também pode ser feito de forma contínua e pode indicar vazamentos de óleo ou N₂, ou um mau funcionamento da bomba.

5) Corrente do motor de carregamento da mola:

O sinal de corrente do motor, no momento do carregamento da mola para casos de disjuntores com acionamento a mola carregada por motor elétrico, é um sinal importante a ser monitorado, pois pode indicar causas de defeitos frequentes nos disjuntores e pode ser realizado sem alteração física no disjuntor. O seu monitoramento pode identificar problemas no motor, na mola de disparo e identificar atritos no sistema de carregamento.

Uma vez escolhidos os sinais a serem monitorados, torna-se necessário identificar os defeitos (ou faltas) associados às mudanças nas faixas de valores nominais desses sinais. Mediante o estudo do funcionamento dos disjuntores e o estudo do estado da arte das técnicas de monitoramento, construiu-se relações que permitem indicar os defeitos possíveis de se identificar através da variação da faixa de valores de cada um desses sinais. Estas relações são apresentadas na tabela 3.1.

TABELA 3.1: Sinais propostos a serem monitorados e indicação de defeitos.

Sinais	Variação dos sinais	Indicação de defeitos
Tempos de abertura (T_A) e fechamento (T_F)	Aumento de T_A	Modificação nas características do sistema de abertura (Ex: lubrificação inadequada);
	Aumento de T_A e T_F	Pressão do gás SF_6 na câmara em nível alto;
		Defeito no sistema de acionamento;
		Atritos significativos em todo comando (procurar por corrosão) ou defeito nos amortecedores.
	Diminuição de T_A	Partes mecânicas móveis podem estar danificadas dentro da câmara;
	Diminuição de T_A e T_F	Pressão do gás SF_6 na câmara em nível baixo (vazamento de gás);
	Aumento de T_A e diminuição de T_F	Defeito no sistema de desligamento, alguma mola pode estar quebrada;
Corrente de interrupção	Somatório da energia dissipada	Desgaste nos contatos principais (vida útil dos contatos);
Pressão do gás SF_6 (P_{SF6})	Diminuição de P_{SF6}	Pressão do gás SF_6 na câmara em nível baixo (vazamento de gás devido a alguma rachadura na câmara ou problemas na vedação);
	Aumento de P_{SF6}	Pressão do gás SF_6 na câmara em nível alto (pode haver a formação de arco elétrico devido a uma deformação nos contatos ou algum desajuste na posição dos mesmos);
Pressão do sistema hidráulico ($P_{O/N2}$)	Diminuição de $P_{O/N2}$	Defeito no sistema de acionamento (vazamento de óleo ou N_2 ou mau funcionamento da bomba hidráulica);
	Aumento de $P_{O/N2}$	Defeito no sistema de acionamento (problema nos circuitos de comando de comando e supervisão. Ex: defeito no pressostato);
Corrente do motor (I_{MT})	I_{MT} em nível alto	Atritos no sistema de carregamento da mola;
	I_{MT} em nível baixo	Mudanças nas características da mola de disparo;
	$I_{MT} = 0$	Problemas no motor ou no circuito de comando do motor.

Nota-se que é possível correlacionar as variáveis e inferir o defeito mais provável, como no exemplo:

Se os tempos de abertura e fechamento são altos, é possível que esteja ocorrendo um dos três defeitos relacionados ao aumento destas variáveis, conforme mostrado na TAB. 3.1, porém, se, ao mesmo tempo, for verificado a situação das variáveis: pressão do gás SF₆ e pressão do óleo (para caso de disjuntores com acionamento hidráulico) pode-se definir qual dos três defeitos é o mais provável.

A tabela 3.2 mostra todas as situações possíveis de se identificar através da relação entre as variáveis propostas a serem monitoradas:

TABELA 3.2 Código para cada diagnóstico possível

Código do defeito	Condição do equipamento (Diagnóstico)
1	Funcionamento normal
2	Modificação nas características do sistema de abertura (Ex: lubrificação inadequada);
3	Defeito no sistema de desligamento, alguma mola pode estar quebrada;
4	Partes mecânicas móveis podem estar danificadas dentro da câmara;
5	Atritos significativos em todo comando, procurar por corrosão ou defeito nos amortecedores;
6	Pressão do gás SF ₆ na câmara em nível baixo (vazamento de gás devido a alguma rachadura na câmara ou problemas na vedação);
7	Pressão do gás SF ₆ na câmara em nível alto (pode haver a formação de arco elétrico devido a uma deformação nos contatos ou algum desajuste na posição dos mesmos);
Disjuntores com acionamento hidráulico	
8	Defeito no sistema de acionamento (vazamento de óleo ou N ₂ ou mau funcionamento da bomba hidráulica);
9	Defeito no sistema de acionamento (problema nos circuitos de comando de comando e supervisão Ex: defeito no pressostato);
Disjuntores com acionamento à mola	
8	Problema no motor elétrico;
9	Mudanças na característica da mola de disparo;
10	Atritos no sistema de carregamento da mola.

Para cada defeito, associaram-se códigos a fim de facilitar a elaboração do sistema especialista e servir como saída do mesmo. Os sete primeiros defeitos são associados aos dois tipos de disjuntores (disjuntores com acionamento hidráulico e disjuntores com acionamento a mola carregada por motor elétrico), os demais são associados a cada um dos dois tipos de disjuntores, conforme indicado na tabela 3.2.

Geralmente, a faixa de valores nominais para cada variável é dada pelos fabricantes e indicam os limites inferior e superior para cada uma. Os disjuntores com acionamento hidráulico e os disjuntores com acionamento a mola carregada por motor elétrico em maior número na área de distribuição de energia da concessionária local são os disjuntores do tipo FA1 do fabricante Lorenzetti e os disjuntores do tipo LTB do fabricante ABB, respectivamente.

Em vista disso, os estudos de caso a serem apresentados no capítulo quatro são relacionados a esses dois tipos de disjuntores e os valores limites das variáveis propostas a serem monitoradas, para esses dois tipos disjuntores, especificamente são descritos nas tabelas 3 e 4 e foram retiradas de seus manuais.

TABELA 3.3 Valores limites das variáveis do disjuntor do tipo FA1 da Lorenzetti

	T_A (ms)	T_F (ms)	P_{SF6} (Mpa)	P_{O/N2} (Mpa)
Min.	35	80	0,52	31,5
Max.	40	85	0,6	33,5

TABELA 3.4 Valores limites das variáveis do disjuntor do tipo LTB da ABB

	T_A (ms)	T_F (ms)	P_{SF6} (Mpa)	I_{MT} (A)
Min.	22	38	0,62	13,6
Max.	26	42	0,7	16

onde, T_A é o tempo de abertura, T_F é o tempo de fechamento, P_{SF6} é a pressão do gás SF₆ nas câmaras de interrupção, P_{O/N2} é a pressão do óleo do sistema hidráulico e I_{MT} é a corrente do motor de carregamento da mola.

Os fluxogramas apresentados nas figuras 3.1 e 3.2 ilustram passo a passo o modo como as variáveis foram correlacionadas com o intuito de identificar a condição desses dois tipos de disjuntores.




FIGURA 3.1: Fluxograma de diagnóstico para disjuntores com acionamento hidráulico

O fluxograma da figura 3.1 representa o modo como as variáveis são relacionadas e a verificação da condição da faixa de valores de cada variável, a fim de se obter o diagnóstico específico para cada caso. As saídas representadas no fluxograma são relacionadas à cada código de defeito de acordo com a tabela 3.2. Embora o fluxograma tenha sido elaborado para o disjuntor do tipo FA1 do fabricante Lorenzetti, ele pode se estender a todos os tipos de disjuntores com características semelhantes a este, bastando apenas modificar os limites inferiores e superiores para cada variável, conforme os valores nominais especificados por cada

fabricante. Todas essas considerações também são verdadeiras para o fluxograma elaborado para o disjuntor do tipo LTB da ABB, apresentado na figura 3.2. É importante salientar que os fluxogramas de diagnóstico construídos têm caráter inovador, pois uma abordagem deste tipo, não foi encontrada ainda na literatura.




FIGURA 3.2: Fluxograma de diagnóstico para disjuntores com acionamento a mola.

Segundo (PATTON et al., 1999), técnicas FDI qualitativas tais como Lógica Fuzzy, Redes Neurais e Sistemas Neuro-Fuzzy são técnicas poderosas para auxiliar na classificação de faltas e tomada de decisões e possibilitam reunir um universo de variáveis para inferir diagnósticos importantes sobre o objeto de interesse. Neste trabalho, é proposta a utilização de

tais técnicas para a construção de um sistema especialista na tentativa de representar o conhecimento humano e diagnosticar faltas incipientes nos disjuntores, através das variáveis propostas a serem monitoradas, automatizando os fluxogramas de diagnósticos (ou árvores de faltas) construídos e apresentados nas figuras 3.1 e 3.2. Entretanto, a bibliografia tem mostrado que a quantidade de trabalhos publicados, especificamente aplicados à Engenharia Elétrica está em ascensão, todavia, não foi encontrado nenhum trabalho aplicado dessa maneira a disjuntores. A vista do exposto, procurou-se adaptar as aplicações existentes para utilizá-las na elaboração do sistema proposto, o que resultou numa importante contribuição do trabalho.

Os sinais propostos a serem utilizados como entradas do sistema são os seguintes: tempo de abertura (T_A), tempo de fechamento (T_F), pressão do gás SF_6 (P_{SF6}), pressão do sistema hidráulico (P_{O/N_2}) (para caso de disjuntores com o sistema de acionamento hidráulico) e corrente do motor (I_{MT}) (para caso de disjuntores com o sistema de acionamento a mola carregada por motor elétrico). A saída do sistema especialista será o código de um dos tipos de defeitos apresentados na tabela 3.2. Lembrando que, através do cálculo do somatório do quadrado das correntes de interrupção (equação 2.1), pode ser elaborado um sistema de alarme que indique se o valor desse somatório chegou ao valor máximo determinado pelo fabricante estimando-se assim, o desgaste nos contatos. A estrutura básica do sistema proposto para o monitoramento e diagnóstico dos disjuntores é apresentada na figura 3.3.




FIGURA 3.3: Estrutura do sistema de monitoramento e diagnóstico proposto

Como a pressão do gás SF₆ e a pressão do sistema hidráulico são sinais que devem ser monitorados continuamente e os demais só são obtidos durante a operação de abertura ou fechamento do disjuntor, os valores de P_{SF6} e P_{O/N2} que servirão de entrada no sistema especialista devem ser os últimos valores medidos antes da operação de abertura do disjuntor.

Na próxima seção, serão apresentados os fundamentos teóricos sobre as técnicas de inteligência computacional que servirão de base para a construção do sistema de diagnóstico (sistema especialista) proposto, bem como um breve histórico da aplicação de técnicas de inteligência computacional na detecção de faltas.

3.2 Inteligência Computacional na Detecção de Faltas

O desenvolvimento de técnicas de detecção e isolamento de faltas (FDI), utilizando inteligência computacional tem recebido uma grande atenção nas últimas décadas. Com o crescimento do nível de automação de processos, houve também um crescimento das exigências na implantação de sistemas automatizados com o intuito de manter um nível elevado de segurança, desempenho, confiabilidade e eficiência de tais sistemas. Com isso, as técnicas de detecção isolamento de faltas têm sido largamente implementadas nesses sistemas, a fim de realizar a detecção antecipada da falta, identificar anomalias no funcionamento do sistema e indicar o local de sua ocorrência para ajudar a evitar a saída de operação do sistema e a quebra do sistema, podendo envolver fatalidades humanas e avarias materiais. Um sistema que apresenta tais funcionalidades é chamado de *Sistema de Diagnóstico*.

A maioria dos sistemas de diagnóstico de faltas é baseada em modelos, onde os parâmetros do processo que se deseja monitorar são conhecidos, podendo-se, assim, construir o modelo matemático do mesmo. Uma vez que o modelo matemático possa representar com exatidão o comportamento do processo, torna-se possível comparar a resposta do modelo com a resposta do processo real. As inconsistências entre essas duas respostas são expressas como resíduos. Esses resíduos representam as diferenças entre a operação normal e a faltosa do processo e, normalmente, são gerados com base nas respostas obtidas a partir das entradas na

simulação do modelo analítico do processo, utilizando técnicas tais como: observadores de estado, estimação de parâmetros e equações de paridade baseada em redundância analítica (PATTON e KANGETE, 1988). Essa abordagem de sistema de identificação e isolamento de falta também é conhecida como uma abordagem quantitativa (onde se podem obter informações do processo baseado em seu modelo quantitativo) e permite identificar anomalias no funcionamento do processo, a partir da geração de resíduos e isolar a falta, ou seja, indicar o local de sua ocorrência.

Entretanto, em processos reais, as incertezas em relação ao verdadeiro comportamento do processo a ser monitorado, distúrbios e ruídos desconhecidos, imprecisão nas medições e erros na modelagem do processo dificultam a tarefa de detecção e isolamento de faltas. Em razão disso, torna-se necessário o desenvolvimento de sistemas robustos, capazes de dissociar distúrbios, ruídos, erros de modelagem ou pequenas mudanças no comportamento do sistema, das possíveis faltas. Em (GERTLER, 1998) são apresentados os conceitos básicos de redundância analítica para a geração de resíduos e exemplos de sistemas robustos de identificação e isolamento de faltas independentes da existência de ruídos, distúrbios e erros de modelagem. A estrutura básica para os sistemas de detecção e isolamento de faltas baseados em modelo é apresentada na figura 3.4.




FIGURA 3.4: Estrutura conceitual de diagnóstico de faltas baseado em modelo

Por outro lado, quando o modelo matemático não pode ser obtido, está incompleto ou pouco consistente, não representando o processo com um alto grau de confiança, ou seja, quando incertezas e não linearidades estão freqüentemente presentes, torna-se uma alternativa, a utilização de modelos mais abstratos, baseados nos aspectos qualitativos do processo, ou seja, a utilização das chamadas técnicas livres de modelo que podem representar o comportamento do processo sem a necessidade das expressões analíticas do processo (HUO et al., 2001). A modelagem qualitativa usualmente emprega a estratégia *hipótese-teste* e o modelo é útil para prever o comportamento do processo, sob condições normais de operação e sob condições de vários tipos de faltas. Essa representação qualitativa baseia-se na avaliação do conhecimento heurístico, isto é, utiliza informações a partir de observações de operadores humanos de um determinado processo e inclui associações dos sintomas com os respectivos tipos de faltas (árvore de faltas).

Tais modelos podem ser resultantes da aplicação de conjuntos de regras fuzzy que podem ser desenvolvidas para substituir o uso de um modelo matemático e efetuar o diagnóstico (DEXTER, 1995). A principal vantagem da lógica fuzzy é que ela permite que o comportamento do processo seja descrito através de relações SE / ENTÃO, construídas a partir do conhecimento que o especialista tem do processo, devido a observações na operação do mesmo. Essa categoria de sistemas baseados em conhecimento tem a característica de raciocinar sobre os dados e projetar conclusões empregando regras heurísticas. Com várias dessas regras codificadas em sua base de conhecimento, juntamente com o mecanismo chamado máquina de inferência, o sistema pode raciocinar sobre situações de um determinado problema e apresentar um conjunto de prováveis soluções. Para essa abordagem, é necessário o conhecimento sobre a estrutura do processo, do seu funcionamento e do modelo qualitativo das unidades do processo sob várias condições de faltas.

Algumas pesquisas nessa área têm sido realizadas com o uso de Redes Neurais Artificiais (RNA) com o objetivo de reproduzir o comportamento do processo a partir de um conjunto de dados históricos, constituído pelas medidas das variáveis de entrada e saída do mesmo. A principal característica das redes neurais artificiais está relacionada à sua habilidade de modelar quaisquer funções não-lineares, fornecendo um adequado fator de pesos e uma

estrutura apropriada para tal característica. Para isso, a rede neural deve estar devidamente treinada podendo, assim, modelar toda a dinâmica do processo e classificar todos os tipos de faltas.

Uma rede neural típica pode ser classificada como um sistema dinâmico que consiste em muitas unidades de processamentos (neurônios) interligados formando suas camadas. Esta forma de computação é caracterizada por estruturas que, em algum momento, lembram o cérebro humano, onde o conhecimento é adquirido através de um processo de aprendizagem e intensidade das conexões entre os neurônios, conhecidas como pesos sinápticos, utilizados para armazenar o conhecimento adquirido. A solução de problemas através dessas estruturas passa, num primeiro momento, por uma fase de aprendizagem na qual um conjunto de exemplos (massa de dados) é apresentado para a rede que extrai, automaticamente, as características necessárias para representar a informação fornecida. A extração das características do processo, a partir do treinamento com dados históricos e algoritmos de aprendizado, requer um pequeno ou nenhum conhecimento a priori do processo (HAYKIN, 2001).

Para a construção de uma rede neural devem ser tomados alguns cuidados tais como:

- Os dados utilizados para o treinamento da rede devem ser significativos, cobrir amplamente o domínio do problema e representar as diferentes situações da planta em questão;
- A topologia da rede a ser utilizada deve ser apropriada à aplicação desejada, ou seja, deve-se definir corretamente o tipo de rede a ser utilizada, o número de camadas, o número de unidades em cada camada bem como a determinação de parâmetros do algoritmo de treinamento e as funções de ativação;
- Na fase de aprendizado, com o algoritmo de treinamento escolhido, quando serão ajustados os pesos e as conexões, é importante considerar alguns aspectos tais como a inicialização da rede, o modo e o tempo de treinamento.

As redes neurais artificiais podem ser aplicadas a problemas de detecção, isolamento de faltas (FDI), utilizando diferentes abordagens. As mais utilizadas são aquelas associadas ao reconhecimento de padrões para a classificação de faltas e as que consistem nos módulos de geração de resíduos e tomada de decisão. Nesta última abordagem, num primeiro momento, o vetor residual “ r ” é gerado representando a característica de cada falta. Idealmente, o modelo da rede neural identifica todas as classes do comportamento do processo. E, num segundo momento, o processo de tomada de decisão ou classificação determina o local de ocorrência da falta através da análise do vetor residual. A figura 3.5 representa a estrutura básica de um sistema de diagnóstico de faltas utilizando redes neurais tanto para a geração de resíduos, quanto para a fase de tomada de decisão. Na figura, $u(t)$ representa a entrada do processo, $y(t)$ representa a saída do processo, $y_x(t)$ representa cada saída de cada classe da rede neural para a formação dos resíduos e $f(t)$ representa a falta diagnosticada para cada amostra de dados.




FIGURA 3.5: Estrutura básica do sistema de diagnóstico utilizando redes neurais
Fonte: (PATTON et al., 1999).

Existem várias arquiteturas de redes neurais artificiais que podem ser utilizadas para a geração de resíduos, bem como para a classificação de faltas. Segundo (PATTON et al., 1999), as redes mais usadas para estas tarefas, são as apresentadas na figura 3.6.




FIGURA 3.6: Arquiteturas de redes neurais utilizadas para o diagnóstico de faltas

Embora as técnicas apresentadas anteriormente possam ser devidamente aplicadas ou bem treinadas com dados numéricos e reproduzir as características comportamentais do sistema incluindo todas as não linearidades, é difícil incorporar às mesmas o conhecimento heurístico a partir do especialista. Outro problema que envolve a aplicação dessas técnicas é que elas não descrevem o comportamento do sistema de modo que seja compreensivo pelo operador. Com isso, o conhecimento do operador, que foi adquirido durante vários anos, não é aproveitado na

sua integridade, principalmente devido à incapacidade de tais métodos representarem informações simbólicas.

Alguns autores dizem que sistemas robustos de detecção e isolamento de faltas (FDI) devem utilizar tanto informações numéricas (quantitativas), quanto informações simbólicas (qualitativas) (ISERMANN e ULLIERU, 1993). Alguns pesquisadores têm tratado o problema exposto no parágrafo anterior combinando estimação de parâmetros ou observadores com lógica fuzzy. A idéia principal é gerar resíduos utilizando estimação de parâmetros ou observadores e atribuir, para a fase de tomada de decisão, um Sistema de Inferência Fuzzy. Com isso, tem sido possível incluir conhecimento simbólico com informação quantitativa minimizando as taxas de alarmes falsos.

Existem também métodos que empregam a combinação de técnicas da área de inteligência computacional, como lógica fuzzy e redes neurais (esquemas neuro-fuzzy ou redes neurais fuzzy). Tais esquemas são estruturas que aliam a capacidade de raciocínio de modelos fuzzy com a capacidade de aprendizado das RNAs, suportando, portanto, uma estrutura híbrida que combina conhecimento numérico, aproveitando a habilidade das redes neurais na manipulação de dados e conhecimento simbólico, representado em termos de regras heurísticas através da lógica fuzzy. Tal abordagem apresenta-se como solução para superar limitações como a incapacidade de incorporar, no treinamento das redes neurais, o conhecimento simbólico e limitações da lógica fuzzy que são dadas pelo fato de que o domínio (conhecimento) do especialista em questão, nem sempre é pensado em termos de regras, além de, em certas circunstâncias, ser difícil de ser descrito, podendo gerar especificações incorretas, pelo fato de que pode aparecer um novo tipo de falta a qual não foi considerada durante a construção das regras (PALADE et al., 2002). Essa combinação resulta no aumento de velocidade de treinamento e tolerância a erros de adaptabilidade.

O diagnóstico de faltas, utilizando as técnicas de inteligência computacional FDI, também pode ser facilmente aplicado sem o uso de resíduos para a condição de monitoramento de processos, onde o foco é o monitoramento de variáveis nas quais as mudanças em seus valores nominais podem indicar modificações irreversíveis nos processos que evoluem para

grandes faltas. Um sistema dessa natureza é, em geral, uma função de aproximação que pode sintetizar as relações entre as diferentes variáveis do processo que constituem os vetores de entrada de tal sistema e podem indicar a ocorrência de uma dada falta e a gravidade da mesma, a partir de exemplos utilizados no processo de aprendizado, ou a partir de conhecimentos declarativos construídos a partir do especialista. Esta foi a abordagem utilizada neste trabalho.

Esse problema é visto como um problema de classificação de faltas, o objetivo nesse caso é identificar a qual grupo de faltas um determinado vetor de entrada, constituído das variáveis monitoradas do processo, tem mais chance de pertencer. As técnicas utilizadas nesse caso podem ser as mesmas utilizadas na fase de tomada de decisão das técnicas descritas anteriormente.

Muitos trabalhos têm sido publicados utilizando este tipo de abordagem. (DUKARM, 1993) mostra a aplicação de um Sistema de Inferência Fuzzy com a finalidade de diagnosticar faltas incipientes em transformadores através da análise de gases dissolvidos no óleo isolante do transformador. Michel Hell, em 2002 apresentou o trabalho (HELL et al., 2002c) onde mostra a aplicação de um Sistema Inferência Fuzzy Neuro-adaptativo no processo de diagnóstico de falta em transformadores, através da análise de gases dissolvidos no óleo isolante. Ainda no mesmo período, Michel Hell apresentou mais dois trabalhos, um utilizando uma rede neural Kohonen (HELL et al., 2002b) e o outro, utilizando uma rede neural fuzzy (HELL et al., 2002a), também aplicadas no diagnóstico de faltas de transformadores através da análise de gases dissolvidos.

Uma vez que o conjunto de dados de entrada de tais sistemas é o principal objeto de análise e que, freqüentemente, esse conjunto de dados não se encontra na forma apropriada para análise devido a ruídos, distúrbios ou inconsistência na massa de dados, torna-se necessária a utilização de métodos de pré-processamento ou a aplicação de algoritmos de condicionamento de sinais para reduzir o efeito de ruídos, distúrbios e realçar as futuras faltas. Se, por exemplo, nos casos em que seja necessária a análise de sinais acústicos, é preciso filtrar esses dados para superar problemas de ruídos. Em adição a esses métodos de filtragem, algumas transformações nesses sinais como, por exemplo, a aplicação da Transformada Rápida de Fourier (FFT) pode melhorar os respectivos resultados. Tanto os métodos de filtragem de sinal, quanto a aplicação

da FFT pertencem à classe das técnicas de processamento de sinais. Essa fase de pré-processamento de dados pode incluir técnicas de processamento de sinais ou métodos estatísticos convencionais. Essas abordagens estatísticas podem ser usadas para detectar relações entre as variáveis existentes dentro de um conjunto de dados e identificar os dados que realmente interessam, ou têm uma maior relevância dentro desse conjunto, para serem utilizados na fase de classificação de faltas. (AMINIAN, 2000) desenvolveu um circuito analógico para o diagnóstico de falta baseado em redes neurais usando a decomposição *Wavelet*, Análise de Componentes Principais (PCA⁷) e normalização dos dados como pré-processamento.

Conforme visto, existem várias técnicas possíveis de serem aplicadas no desenvolvimento de um sistema especialista capaz de diagnosticar faltas em plantas e equipamentos. A maneira de construir um sistema de diagnóstico eficiente é associar as várias técnicas descritas anteriormente, e comparar os resultados para definir qual delas é mais precisa e eficiente para um caso em específico.

Em (ZIMMERMANN, 2001), é apresentada a estrutura de um *software* chamado *DataEngine* que contém métodos de processamento de sinais, análise estatística e sistemas inteligentes para a classificação de dados que, combinados, formam um poderoso sistema que pode ser utilizado em vários tipos de aplicações. A estrutura de tal sistema é apresentada na figura 3.7.

É importante salientar que, a equipe “Sistemas de Diagnóstico de Faltas” do Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica de Minas Gerais desenvolveu um sistema especialista com técnicas mencionadas anteriormente, para o diagnóstico de faltas em transformadores de potência e obtiveram resultados bastante interessantes, conforme os apresentados em (HELL et al., 2002a), (HELL et al., 2002b) e (HELL et al., 2002c).

⁷ Do inglês Principal Component Analysis




FIGURA 3.7: Estrutura do software DataEngine

O primeiro passo é configurar o software para atender a uma aplicação específica, ou seja, definir os números de entradas, saídas e o modo das interfaces. O segundo passo consiste no projeto dos classificadores que é realizado *off-line*, através de uma base de dados histórica que é, no primeiro momento, pré-processada eliminando-se inconsistências possivelmente presentes na mesma, através de técnicas de processamento de sinais ou análise estatística e, num segundo momento, essa base de dados é utilizada para projetar os classificadores (definição dos

grupos de dados, seus respectivos centros e treinamento das redes neurais). O terceiro e último passo é o tratamento de uma entrada nova de dados que pode ser realizado *on-line* ou *off-line* dependendo do tipo de aplicação. Os resultados são emitidos na forma de gráficos e relatórios. As técnicas utilizadas na fase de classificação são as seguintes: Sistema de Inferência Fuzzy (FIS), Fuzzy C-means (FCM), Rede Neural Perceptron Multicamada (MLP) e Mapa Auto-organizável de Kohonen (também conhecido como Rede Neural de Kohonen) e, no final de uma aplicação, seus resultados são comparados, podendo-se, assim, definir qual dessas técnicas teve um melhor desempenho para uma dada aplicação.

Procurou-se fazer o mesmo neste trabalho, isto é, aplicar técnicas semelhantes às descritas anteriormente no diagnóstico de disjuntores e compará-las a fim de descobrir qual delas obtém um melhor desempenho. Os fundamentos teóricos sobre as técnicas de inteligência computacional que servirão de base para a construção do sistema especialista (sistema de diagnóstico) são descritos a seguir.

3.2.1 Lógica Fuzzy

Os fundamentos da teoria dos conjuntos fuzzy foram criados por Lotfi A. Zadeh, professor da Universidade da Califórnia, em Berkeley, com a finalidade de solucionar problemas de classificações de conjuntos que não possuíam fronteiras bem definidas e que não eram passíveis de se resolver, através da lógica computacional convencional fundamentada na lógica booleana, que reconhece apenas dois valores: verdadeiro ou falso. Foi verificando-se a fragilidade de algoritmos baseados na lógica convencional de lidar com situações mais realistas que surgiu a necessidade da criação de uma teoria que tratasse de termos vagos ou imprecisos que mais se aproximasse da operação das atividades humanas. Procurando solucionar este problema, Zadeh publicou o trabalho (ZADEH, 1965) revolucionando o assunto com a criação de sistemas baseados em lógica fuzzy. Nesses sistemas, procura-se modelar a forma imprecisa de raciocínio e eles desempenham um papel essencial na notável capacidade humana de tomar

decisões racionais em ambientes de incerteza e imprecisão podendo ser aplicados em casos em que o conhecimento pode ser representado de forma simbólica.

Na teoria clássica dos conjuntos, um dado elemento pertence ou não a um determinado conjunto. Já na teoria dos conjuntos Fuzzy é proposta uma caracterização mais ampla, onde um determinado elemento possui um certo nível de pertinência (valor entre 0 ou 1) a um dado conjunto, e esse nível de pertinência é determinado por uma função de pertinência (MF⁸). Um conjunto fuzzy A , em universo de discurso U , é definido como sendo um conjunto de pares ordenados da forma:

$$A = \{(x, \mu_A(x)) / x \in U\} \quad (3.1)$$

onde $\mu_A(x)$ é a função de pertinência do conjunto A . A função de pertinência mapeia cada um dos pontos x do universo de discurso U para um grau de pertinência compreendido entre os valores 0 e 1. Um dos exemplos mais comuns de conjunto fuzzy é o conjunto de pessoas altas. Neste caso, o universo de discurso é dado pelo o que é considerado uma altura que corresponde a pessoas altas e a palavra “alta” corresponde à curva que define o grau de pertinência para uma pessoa de uma certa altura dentro do conjunto de pessoas altas. Se, por exemplo, o grupo de pessoas altas for dado por um limite bem definido (crisp) de um conjunto clássico, pode-se dizer por exemplo que todas as pessoas que têm altura igual ou superior a 1,75m são oficialmente consideradas altas. Deste modo, pessoas que diferem da altura por um fio de cabelo podem ser classificadas em conjuntos diferentes, o que é claramente um absurdo. Para este caso, é mais apropriado considerar interpretações mais subjetivas construindo conjuntos fuzzy, ou seja, definindo a curva que representa a transição do conjunto de pessoas altas para o conjunto de pessoas não altas. A FIG 3.8 ilustra claramente a diferença de uma abordagem clássica (crisp) para uma abordagem fuzzy do exemplo anterior, onde mostra que, para o caso de uma abordagem clássica, uma pessoa de 1,73m estaria classificada no conjunto de pessoas *não altas* e uma pessoa de 1,78m seria classificada no conjunto de pessoas *altas* e, para o caso de uma abordagem fuzzy, a pessoa de 1,73m teria um nível de pertinência de 0,3 no conjunto de pessoas

⁸ Do inglês Membership Function

altas, enquanto que a pessoa de 1,78m teria um nível de pertinência de 0,9 no conjunto de pessoas *altas*.




FIGURA 3.8: Diferença entre a abordagem clássica e a abordagem fuzzy.

A determinação das funções de pertinências também pode ser definida como um processo de “fuzzificação” dos valores, ou seja, o mapeamento do domínio de números crisp (em geral discretos) para o domínio fuzzy. A fuzzyficação representa que há atribuição de valores fuzzy, descrições vagas ou qualitativas, definidas por funções de pertinência das variáveis, e é uma espécie de pré-processamento de categorias ou classes das variáveis e reduz grandemente os valores a serem processados. Algumas das funções de pertinências mais usuais são mostradas, a seguir, nas formas analítica e gráfica:

a) Função trapeizodal definida como:

$$Trapeizodal(x, a, b, c, d) \rightarrow \begin{cases} 0 & \text{se } x \leq a, \\ \frac{x-a}{b-a} & \text{se } a \leq x \leq b, \\ 1 & \text{se } b \leq x \leq c, \\ \frac{d-x}{d-c} & \text{se } c \leq x \leq d, \\ 0 & \text{se } x \geq d. \end{cases}$$




FIGURA 3.9: Função de pertinência trapezoidal

b) Função triangular definida como:

$$Triangular(x, a, b, c) \rightarrow \begin{cases} 0 & \text{se } x \leq a, \\ \frac{x-a}{b-a} & \text{se } a \leq x \leq b, \\ 1 & \text{se } x = b, \\ \frac{c-x}{c-b} & \text{se } b \leq x \leq c, \\ 0 & \text{se } x \geq c. \end{cases}$$




FIGURA 3.10: Função de pertinência Triangular

c) Função gaussiana definida como:

$Gaussiana(x, c, \varphi) = e^{-\frac{1}{2}\left(\frac{(x-c)^2}{\varphi}\right)}$, onde c é o centro do conjunto (cluster) e φ é a largura do conjunto.




FIGURA 3.11: Função de pertinência gaussiana

d) Função sigmoidal definida como:

$Sigmoidal(x, a, c) = \frac{1}{1 + e^{a(x-c)}}$, a ajusta a inclinação em $x = c$.




FIGURA 3.12: Função de pertinência sigmoidal

As variáveis, cujos valores são nomes de conjuntos fuzzy, são chamadas de **variáveis lingüísticas**. Os valores de uma variável lingüística podem ser sentenças em linguagem especificada, construídas a partir de termos primários como, por exemplo: *alto*, *baixo*, *pequeno*, *médio*, *grande*. Voltando ao exemplo anterior, a altura de uma pessoa pode ser uma variável lingüística assumindo valores *baixa*, *média*, *alta*, etc. Estes valores são descritos por intermédio de conjuntos fuzzy, conforme mostrado na figura 3.13.




FIGURA 3.13: Variáveis lingüísticas.

Dentro da lógica fuzzy, também existem conceitos conhecidos como **proposições fuzzy** e **regras fuzzy**. Quando se fala, por exemplo, que a altura de uma pessoa é considerada *alta* pode-se descrever esta relação através da sentença “*altura da pessoa é alta*”, onde a “*altura da pessoa*” é uma variável lingüística e a palavra “*alta*” é um conjunto fuzzy definido num universo de discurso U , dentro da escala predeterminada de altura de pessoas. Estes tipos de relações são conhecidas como **proposições fuzzy** e podem ser combinadas por meio de diferentes operadores como, por exemplo, os conectivos lógicos E e OU e o operador de implicação SE.....ENTÃO. Este último, também é conhecido como declaração condicional ou **regra fuzzy** e pode descrever a dependência do valor de uma variável lingüística em relação ao valor de outra, como no exemplo:

$$SE (x \text{ é } A) \text{ ENTÃO } (y \text{ é } B)$$

onde A e B são variáveis lingüísticas definidas por conjuntos fuzzy dentro dos universos de discursos X e Y , respectivamente. A primeira parte da regra ($SE x \text{ é } A$) é chamada de *antecedente* ou *premissa*, e segunda parte da regra ($ENTÃO y \text{ é } B$) é chamada de *consequente* ou *conclusão*.

Quando uma declaração condicional apresenta mais de uma variável antecedente, as diversas variáveis são combinadas através do conectivo E na forma:

$$SE ((x_1 \text{ é } A_1) E (x_2 \text{ é } A_2) E \dots E (x_m \text{ é } A_m)) \text{ ENTÃO } (y \text{ é } B)$$

Várias declarações podem ser combinadas através dos conectivos OU e E, dependendo do operador de implicação:

$$\begin{aligned} &SE ((x \text{ é } A_1) \text{ ENTÃO } (y \text{ é } B_1)) \\ &OU \\ &SE ((x \text{ é } A_2) \text{ ENTÃO } (y \text{ é } B_2)) \\ &OU \\ &\vdots \\ &SE((x \text{ é } A_m) \text{ ENTÃO } (y \text{ é } B_m)) \end{aligned}$$

3.2.2 Sistema de Inferência Fuzzy (FIS)

O Sistema de Inferência Fuzzy é uma estrutura computacional que implementa um mapeamento não linear, a partir de um espaço de entrada para o espaço de saída, usando os conceitos da lógica fuzzy. Este mapeamento fornece uma base de decisões que podem ser tomadas simulando o conhecimento especialista. Tais sistemas têm sido aplicados com sucesso em uma grande variedade de campos tais como: classificação de dados, controle automático, tomada de decisões, sistemas especialistas e reconhecimento de padrões. Por causa da natureza multidisciplinar, os Sistemas de Inferência Fuzzy são associados a vários nomes diferentes

como: sistemas fuzzy baseado em regras, sistema especialista fuzzy, modelamento fuzzy, controladores fuzzy ou, simplesmente, sistema fuzzy.

O processo de inferência fuzzy envolve todos os conceitos descritos na seção anterior: funções de pertinência, operadores lógicos fuzzy e regras fuzzy SE ... ENTÃO (JANG et al., 1997). A aplicação de tal sistema consiste nas seguintes etapas:

Entrada de dados $\rightarrow$ fuzzyficação $\rightarrow$ regras de inferência $\rightarrow$ agregação $\rightarrow$ defuzzyficação $\rightarrow$ saída.

As entradas de um sistema fuzzy podem ser tanto valores fuzzy como valores crisp, porém as saídas produzidas são quase sempre um conjunto fuzzy. Em algumas situações, é necessário que a saída seja um valor crisp. Para isso, torna-se necessária a aplicação de um método de defuzzificação para obter um valor crisp que melhor represente o conjunto fuzzy. A FIG. 3.14 ilustra um sistema de inferência fuzzy com uma saída crisp.




FIGURA 3.14: Diagrama de blocos de um Sistema de Inferência Fuzzy

Em resumo, a estrutura básica de um sistema de inferência fuzzy consiste de 3 camadas conceituais:

- Uma base de dados (ou dicionário) que define as funções de pertinências usadas nas regras fuzzy.
- Uma base de regras que contém um conjunto de regras fuzzy;

- Um mecanismo de raciocínio que desenvolve o procedimento de inferência com base nas regras e fatos conhecidos, possibilitando obter uma saída razoável.

Os dois tipos de sistemas de inferência fuzzy mais usuais são os de Mamdani e Sugeno. Esses dois tipos de sistemas diferem no modo como as saídas são determinadas. O sistema de inferência fuzzy de Mamdani é o mais utilizado e foi proposto por Ebrahim Mamdani, em 1975, (MAMDANI, 1975), na tentativa de controlar uma máquina de vapor, estabelecendo um conjunto de regras lingüísticas de controle obtidas a partir do conhecimento de operadores humanos. Uma vez elaboradas as regras, elas devem ser combinadas de maneira a tomar a decisão certa. A agregação é o processo pelo qual os conjuntos fuzzy, que representam as saídas de cada regra, são combinados dentro de um único conjunto fuzzy. O processo de inferência pode ser realizado utilizando *min* e *max* para o cálculo da saída, ou utilizando *produto* e *max* ou simplesmente pela soma da saída de cada regra. A figura 3.15 mostra como as saídas de cada regra podem ser combinadas (agregadas) dentro de um único conjunto fuzzy, utilizando o método *min* e *max* para a inferência.




FIGURA 3.15: Sistema de Inferência Fuzzy de Mamdani

Para a extração de um valor crisp do resultado da agregação, é necessário aplicar um método de defuzzyficação. Em geral, existem cinco métodos de defuzzyficação, são eles: Centróide da área, Bissetor da área, Média do máximo, Menor do máximo e Maior do Máximo. Estes métodos estão descritos em (JANG et al., 1997) e podem ser visualizados na figura 3.16, onde A é um conjunto fuzzy pertencente a um universo de discurso Z e é representado por uma combinação das funções de pertinência de saída de um sistema de inferência fuzzy.




FIGURA 3.16: Métodos de defuzzyficação

Fonte: (JANG et al., 1997)

Além dos sistemas de inferências mencionados anteriormente, pode-se citar o sistema de inferência fuzzy de Sugeno também conhecido como modelo Takagi-Sugeno-Kang proposto por Takagi e Sugeno em 1985 (TAKAGI e SUGENO, 1985), similar ao modelo de Mamdani em muitos aspectos. A principal diferença entre esses dois modelos é que no modelo de Sugeno a parte conseqüente da regra pode ser uma função linear ou uma constante. Existem duas ramificações para implementar tal modelo, o modelo de Sugeno de ordem zero e o modelo de Sugeno de primeira ordem. Uma regra típica de um modelo de Sugeno de ordem zero tem a forma:

$$\text{SE } x \text{ é } A \text{ E } y \text{ é } B \text{ então } z = k$$

onde A e B são conjuntos fuzzy na parte antecedente da regra, enquanto que k é um número crisp na parte conseqüente da regra. Com isso, a saída de cada regra é uma constante, o modelo de ordem zero pode ser visto como um caso especial do sistema de inferência fuzzy de

Mamdani, em que cada conseqüente da regra é especificado por um *singleton* fuzzy. Já o modelo de Sugeno de primeira ordem pode ser escrito da seguinte forma:

$$\text{SE } x \text{ é } A \text{ E } y \text{ é } B \text{ então } z = f(x,y)$$

onde A e B são conjuntos fuzzy na parte antecedente da regra e $z = f(x,y)$ é uma função crisp na parte conseqüente da regra. Essa função geralmente é um polinômio de primeira ordem nas variáveis de entrada x e y descrito pela equação $z = px + qy + r$, onde p , q e r são constantes. Uma vez que cada regra tem uma saída crisp, a saída total é obtida via média ponderada, assim evitando consumo de tempo do processo de defuzzyficação requerido e um modelo fuzzy de Mamdani.

3.2.3 Sistema de Inferência Fuzzy Neuro-Adaptativo

Alguns dos problemas que atingem a abordagem fuzzy convencional estão relacionados à quantidade de parâmetros livres que se encontram na formação das funções de pertinência dos antecedentes e dos conseqüentes das regras fuzzy. Em outras palavras, para se criar uma regra fuzzy do tipo *SE ALGO FOR ALTO, ENTÃO A SAÍDA É BAIXA* é necessário definir que tipo de função e quais os parâmetros das funções de pertinência são mais apropriados para o caso. Assim como para a elaboração das regras, também não existe um método padrão para a determinação das funções de pertinência e, com isso, tornou-se necessário criar métodos que ajustem as funções de pertinência com a finalidade de minimizar o erro de saída ou aumentar o índice de performance.

O sistema de inferência fuzzy neuro-adaptativo (ANFIS⁹) foi proposto por Jang, em 1993, (JANG, 1993), com a finalidade de criar uma estrutura adaptável para o sistema de inferência fuzzy tradicional, implementando um sistema fuzzy Sugeno de primeira ordem,

⁹ Do inglês Adaptive Neuro-Fuzzy Inference Fuzzy

unindo a flexibilidade de um sistema fuzzy e a arquitetura de uma rede neural para sanar os problemas apresentados no parágrafo anterior.

Os sistemas ANFIS possuem uma arquitetura em rede similar à arquitetura das redes neurais artificiais, que mapeiam um conjunto de entradas em uma saída. Esse mapeamento é feito através de funções de pertinência fuzzy. Os dados de entrada são mapeados pelas funções de pertinência relacionadas à entrada e por outras funções de pertinência associadas às saídas. Todas essas funções de pertinência possuem uma série de parâmetros livres. A computação desses parâmetros é facilitada nos sistemas do tipo ANFIS pelo cálculo do vetor de gradiente do erro relacionado à saída. Em outras palavras, um sistema ANFIS computa os parâmetros das funções de pertinência fuzzy iterativamente durante a fase de treinamento calculando a resposta obtida pelo sistema e a resposta esperada. E, então, pelo cálculo do erro entre essas respostas, o sistema automaticamente se adapta modificando os parâmetros das funções de pertinência fuzzy relacionadas aos antecedentes e aos conseqüentes, obtendo, assim, uma nova resposta para o sistema. Esse procedimento é executado com os dados de treinamento até que não se tenha mais diminuição significativa do erro relativo à saída esperada.

Conforme citado anteriormente, o sistema ANFIS foi criado baseado no método de Inferência de Takagi e Sugeno descrito na seção anterior. Esse modelo de inferência para um problema com duas variáveis de entrada, x e y , é mostrado na figura 3.17.




FIGURA 3.17: Sistema de Inferência Fuzzy de Takagi e Sugeno
Fonte: (JANG, 1993)

A estrutura ANFIS proposta por Jang que executa este modelo de raciocínio adaptativo é ilustrado na figura 3.18.




FIGURA 3.18: Estrutura da rede ANFIS
Fonte: (JANG, 1993)

Camada 1: Cada nó i desta camada representa um subconjunto fuzzy da variável lingüística de entrada (A_1 e A_2 para X e B_1 e B_2 para Y) e fornece o grau de pertinência de uma dada entrada (x ou y) no i -ésimo subconjunto fuzzy, ou seja:

$$O_i^1 = \mu_{A_i}(x) \quad (3.2)$$

onde x (ou y) é a entrada do nó i e A_i é a variável lingüística (*baixo*, *alto*, etc.) associada a este nó, $\mu_{A_i}(x)$ é a função de pertinência do subconjunto i e O_i^1 representa a i -ésima saída desta camada. A função de pertinência escolhida para ilustrar o caso foi a função do tipo sino representada pela equação:

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (3.3)$$

onde onde $\{a_i, b_i, c_i\}$ é o conjunto de parâmetros dessa função. Os valores desses parâmetros vão sendo ajustados a medida que o treinamento ocorre.

Camada 2: Cada nó i desta camada tem como saída o produto de todos os sinais que entram na camada, isto é:

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2. \quad (3.4)$$

Estes nós representam o grau de ativação da i -ésima regra.

Camada 3: Cada nó i desta camada calcula a relação entre o i -ésimo valor de disparo da regra e o somatório de todos os valores de disparo da forma:

$$\overline{w_i} = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2. \quad (3.5)$$

Por conveniência, os valores das saídas dessa camada serão chamados de valores de disparo normalizados.

Camada 4: Cada nó i nesta camada executa a seguinte função:

$$O_i^4 = \overline{w_i} f_i = \overline{w_i} (p_i x + q_i + r_i) \quad (3.6)$$

onde $\overline{w_i}$ é o i -ésimo valor de disparo normalizado, calculado na camada 3, e $\{p_i, q_i, r_i\}$ é o conjunto de parâmetros desta camada. Estes parâmetros são normalmente referidos como parâmetros consequentes.

Camada 5: O único nó que forma esta camada calcula a saída geral como sendo o somatório de todos os sinais que entram na camada, isto é:

$$O_i^s = \sum_i \overline{w_i} f_i = \overline{w_i} = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (3.7)$$

Com isso, pode-se construir uma rede adaptativa que é funcionalmente equivalente a um sistema de inferência fuzzy de Sugeno de primeira ordem. Essa técnica permite que o modelo fuzzy aprenda informações a respeito de uma base de dados e calcule os parâmetros das funções de pertinência que melhor se ajustem a um conjunto de entradas e saídas. O treinamento é semelhante a um treinamento de uma rede neural, combinando algoritmos formando um treinamento híbrido conforme apresentado em (JANG, 1993).

3.2.4 Clusterização Fuzzy

A clusterização é um método para a análise exploratória de dados utilizado para auxiliar na resolução de problemas de classificação. O objetivo do processo de clusterização é agrupar um conjunto de dados (ou objetos) em diferentes grupos; esse agrupamento é tal que o grau de associação entre elementos do mesmo grupo é alto e entre elementos de grupos diferentes é baixo. Procura-se encontrar a estrutura intrínseca dos dados, organizando-os em grupos (também chamados classes ou *clusters*). O uso desse processo é apropriado quando se conhece pouco ou nada sobre a estrutura de um conjunto de dados.

Dado um conjunto finito de elementos X , o problema de clusterização em X consiste em atribuir classes aos elementos de maneira que essas classes identifiquem subgrupos naturais em X . Na análise de *cluster* clássica (*crisp*), essas classes devem formar uma partição de X ; indivíduos que pertencem ao mesmo bloco (classe) da partição estão totalmente relacionados (são indistinguíveis) e indivíduos que pertencem a blocos distintos não estão relacionados. Em outras palavras, indivíduos estão totalmente relacionados entre si ou não estão relacionados. Em muitas aplicações práticas, no entanto, uma partição *crisp* pode ser muito restritiva e inviável, devido, muitas vezes, à imprecisão ou à não completeza dos dados. Com a utilização da abordagem *fuzzy*, o problema passa então a ser caracterizado como um problema de

clusterização *fuzzy*, cujo objetivo é a obtenção de uma **partição *fuzzy*** ou, então, de uma **pseudopartição *fuzzy*** em um conjunto de dados X . Em ambos os casos, permite-se diferentes graus de relacionamento entre elementos do conjunto, sendo que um elemento pode pertencer a mais de uma classe.

Vários métodos têm sido desenvolvidos para obter tanto *clusters* convencionais (*crisp*), quanto *fuzzy* a partir de um determinado conjunto de dados. Para o caso da abordagem *fuzzy*, são utilizados, neste trabalho, o método de clusterização Fuzzy C-means, e o método de Relações de Equivalência Fuzzy, dada a relevância e aplicabilidade de tais métodos.

3.2.4.1 Fuzzy C-means

O algoritmo Fuzzy C-means (FCM) é utilizado para determinar agrupamentos e seus centros, segundo a norma euclidiana existente entre um dado e os centros dos agrupamentos. O raciocínio para entender a relação entre um dado e o agrupamento é o seguinte: quanto mais próximo do centro de um agrupamento o dado estiver, maior será seu grau de pertinência a esse agrupamento. Para a ilustração do método, é dado um conjunto de dados bidimensionais conforme apresentado na figura 3.19 (a). Aplicando-se o algoritmo Fuzzy C-means e determinando previamente o número de grupos requeridos para o agrupamento dos dados, (para este caso, estabeleceu-se que fossem calculados dois grupos para a massa de dados) os centros são calculados e, através do cálculo da distância euclidiana entre cada dado e os centros calculados, os *cluster* são obtidos, ou seja, quanto menor for a distância entre um dado e os centros, maior será o grau de pertinência ao respectivo *cluster*, assim o dado é classificado dentro do *cluster* o qual a distância ao centro for a menor, conforme mostrado na figura 3.19 (b)




FIGURA 19: Aplicação do Fuzzy C-means para determinação dos grupos (clusters)

O método de clusterização Fuzzy C-means foi proposto por (BEZDEK, 1981) e é descrito a seguir:

Dado um conjunto de dados $X = \{x_1, x_2, \dots, x_n\}$ onde x_k em geral, é um vetor de características $x_k = [x_{k1}, x_{k2}, \dots, x_{kp}] \in R^p$ para todo $k \in \{1, 2, \dots, n\}$ sendo R^p um espaço com p dimensões, o problema de clusterização *fuzzy* é encontrar uma pseudopartição *fuzzy* que representa a estrutura dos dados da melhor forma possível. Uma pseudopartição *fuzzy* de X é uma família de c subconjuntos *fuzzy* de X , denotada por $P = \{A_1, A_2, \dots, A_c\}$ que satisfaz as equações:

$$\sum_{i=1}^c A_i(x_k) = 1 \quad (3.8)$$

onde, para todo $k \in \{1, 2, \dots, n\}$ sendo que n representa o número de elementos do conjunto X . Ou seja, a soma dos graus de pertinência de um elemento em todas as famílias deve ser igual a um.

$$0 < \sum_{k=1}^n A_i(x_k) < n \quad (3.9)$$

para todo $i \in \{1, 2, \dots, c\}$ sendo que c representa o número de classes. Ou seja, a soma dos graus de pertinência de todos os elementos de uma família deve ser menor que o número de elementos existentes no conjunto universo X . Por exemplo, dado $X = \{x_1, x_2, x_3\}$ e:

$$\begin{aligned} A_1 &= 0,6/x_1 + 1/x_2 + 1/x_3, \\ A_2 &= 0,4/x_1 + 0/x_2 + 0,9/x_3, \end{aligned}$$

note que $0,6 + 0,4 = 1$, $1 + 0 = 1$ e $0,1 + 0,9 = 1$, o que satisfaz a equação (3.8) e que $0,6 + 1 + 0,1 = 1,7 < 3$ e $0,4 + 0 + 0,9 = 1,3 < 3$, o que satisfaz a equação (3.9). Portanto, $\{A_1, A_2\}$ é uma pseudopartição *fuzzy* de X .

O método Fuzzy C-means pode ser equacionado por meio de um algoritmo iterativo, baseado na minimização de um índice de desempenho, que indica a adequabilidade da pseudopartição gerada. O desempenho do algoritmo é influenciado pela escolha do número de classes c , dos centros de *cluster* iniciais, da ordem na qual os vetores são processados, da medida de distância, do critério de parada e pelas propriedades geométricas dos dados. Os conjuntos que apresentam *clusters* compactos, bem separados e com formas hiper-esféricas, são apropriados para este método, mas para encontrar agrupamentos adequados é necessário realizar extensivos testes com vários valores de c , distâncias, critérios de parada, centros de *cluster* iniciais e diferentes ordens de amostras.

Assim, o algoritmo assume como entrada os seguintes parâmetros: o número desejado de *clusters* c ; uma medida de distância $m \in (1, \infty)$, que define a distância permitida entre os pontos e os centros de *cluster*; e um número pequeno $\varepsilon > 0$, utilizado como um critério de parada, além da instanciação inicial dos graus de pertinência dos objetos a cada uma das classes e dos centros de *cluster* dessas classes. A seguir, são descritos os passos do algoritmo.

Passo 1: Considere $t = 0$ representando a iteração 0. Defina $P^{(0)}$ como uma pseudopartição $P = \{A_1, A_2, \dots, A_c\}$, atribuindo os graus de pertinência dos elementos às classes dessa pseudopartição, os quais podem ser informados ou calculados de forma aleatória.

Passo 2: No caso de $t = 0$ forneça os c centros de clusters $v^{(t)}_1, \dots, v^{(t)}_c$ iniciais. Para $t > 0$ calcule os c centros de *cluster* $V^{(t)}_1, \dots, V^{(t)}_c$ mediante a equação (3.10) para $P^{(t)}$ e o valor de m fornecido.

$$v_i = \frac{\sum_{k=1}^n [A_i(x_k)]^m x_k}{\sum_{k=1}^n [A_i(x_k)]^m} \quad (3.10)$$

A variável real $m > 1$ é chamada de **índice de fuzzificação** e é usada para definir a distância permitida entre os pontos e o centro que está sendo calculado. Quanto maior o valor de m , mais elementos do conjunto são considerados como pertencentes a uma pseudopartição. Esse parâmetro é escolhido de acordo com o problema considerado. Não existe nenhuma base teórica para uma escolha ótima do valor de m .

O vetor v_i , calculado por (3.10), visto como o centro do *cluster* A_i , é a média ponderada dos dados em A_i . O peso do dado x_k é a m -ésima potência do seu grau de pertinência ao conjunto *fuzzy* A_i .

Passo 3: Atualize $P^{(t)}$ para $P^{(t+1)}$ usando o seguinte procedimento: para cada $x_k \in X$ e para todo $i \in \{1, 2, \dots, c\}$, se $\|x_k - v_i(t)\|^2 > 0$, calcule o grau de pertinência do elemento x_k à classe A_i , pela fórmula (3.11), sendo que as classes A_i podem ser selecionadas em uma ordem pré-definida ou aleatoriamente.

$$A_i^{(t+1)}(x_k) = \left[\sum \left(\frac{\|x_k - v_i^{(t)}\|^2}{\|x_k - v_j^{(t)}\|^2} \right)^{\frac{1}{m-1}} \right]^{-1} \quad (3.11)$$

Assume-se que $\|\cdot\|$ é alguma norma indicada para o produto interno no espaço R^P e $\|x_k - v_i(t)\|^2$ representa a distância entre x_k e v_i . Através da equação (3.14), a distância de cada

elemento x_k ao centro de *cluster* v_i da pseudopartição atual A_i é comparada à distância do mesmo elemento ao centro de *cluster* v_j de todas as demais pseudopartições A_j , de modo a atribuir um grau de pertinência ao elemento x_k no *cluster* A_i que seja proporcional ao seu grau de pertinência aos demais *clusters* A_j .

Quando $\|x_i - v_i(t)\|^2 = 0$ para algum $i \in I \subseteq \{1, 2, \dots, c\}$, o que indica que x_k corresponde ao centro de *cluster* v_i , defina $A_i^{(t+1)}(x_k)$ como um número real não negativo que satisfaz (13.12) e defina $A_i^{(t+1)}(x_k) = 0$ para $i \in \{1, 2, \dots, c\} - I$.

$$\sum_{i \in I} A_i^{(t+1)}(x_k) = 1 \quad (3.12)$$

Em casos como este, quando o elemento coincide com o centro de *cluster* de uma classe A_i , o ideal seria que o algoritmo atribuisse a tal elemento o grau de pertinência máximo (1) àquela classe e o grau de pertinência mínimo (0) às demais classes. No entanto, o teste realizado pela fórmula (13.13) se torna necessário, uma vez que esse elemento pode ter sido associado a outras classes com um grau de pertinência maior que zero, se A_i não for a primeira classe selecionada pelo algoritmo. Nota-se, portanto, a influência da ordem na qual as pseudopartições são escolhidas.

Passo 4: Como critério de parada, compare $P^{(t)}$ e $P^{(t+1)}$. Se $|P^{(t)} - P^{(t+1)}| \leq \varepsilon$, então pare; caso contrário, faça $t = t + 1$ e retorne ao Passo 2.

$$|P^{(t+1)} - P^{(t)}| = \max_{i \in N_c, k \in N_c} |A_i^{(t+1)}(x_k) - A_i^{(t)}(x_k)| \quad (3.13)$$

Essa fórmula verifica se a máxima diferença entre o grau de pertinência de qualquer elemento x_k em uma dada classe A_i na iteração atual e na iteração anterior é menor que o erro definido ε , sendo isso feito para todas as classes. Em caso positivo, o algoritmo deve parar e retornar os graus de pertinências atuais de todos os elementos em todas as classes como

resultado. Note que, quanto menor o valor de ε , maior o número de passos e, conseqüentemente, mais refinada é a pseudopartição final obtida.

Ao final da última iteração do algoritmo, a pseudopartição obtida deve ser analisada segundo algum critério que expresse a idéia geral de que as associações são fortes dentro do *cluster* e fracas entre *clusters*. Este critério pode ser definido, por exemplo, em termos de índices de desempenho, tal como o índice $J_m(P)$, dado em função dos centros de *cluster* e de m pela fórmula (13.14).

$$J_m(P) = \sum_{k=1}^n \sum_{i=1}^c [A_i^{(t+1)}(x_k)]^m \|x_k - v_i\|^2 \quad (3.14)$$

Esse índice de desempenho mede, para todos os elementos, a soma das distâncias ponderadas de cada elemento a cada um dos centros de *cluster* da pseudopartição. Quanto menor o valor de $J_m(P)$, melhor a pseudopartição *fuzzy* P . Conseqüentemente, o objetivo do método de clusterização Fuzzy C-means é encontrar uma pseudopartição P que minimize o índice de desempenho $J_m(P)$. Assim, o problema de clusterização pode ser equacionado como um problema de otimização. Vários testes, utilizando diferentes valores para os parâmetros do algoritmo, podem ser feitos de forma a se obter índices de performance menores, ou seja, resultados mais adequados.

3.2.4.2 Método de Clusterização Baseado em Relações de Equivalência Fuzzy

O método de clusterização Fuzzy C-means requer, a priori, que o número de *clusters* (grupos) seja especificado. Isto é uma desvantagem deste método, pois, às vezes, não se tem conhecimento algum sobre a massa de dados a ser tratada, então, o processo de clusterização (agrupamento) de dados não requer que qualquer número de grupos seja especificado. Isso deve ser obtido, de uma maneira natural, a partir de uma estrutura de dados. Os métodos baseados em relações de equivalência fuzzy trabalham desse modo.

Uma relação de equivalência fuzzy é uma relação reflexiva, simétrica e *max-min* transitiva, (ver ANEXO I) e induz a uma partição *crisp* a cada um de seus α -cut¹⁰. O problema de clusterização fuzzy pode ser visto como um problema de identificar uma apropriada relação de equivalência sobre uma base de dados. Embora isto não seja usualmente feito de maneira direta, pode-se facilmente determinar a relação de compatibilidade fuzzy (relação que é reflexiva e simétrica) em termos de uma apropriada função de distância aplicada a uma base de dados. Então, a principal relação de equivalência fuzzy é definida como a relação *max-min* transitiva dessa relação de compatibilidade fuzzy.

Dado um conjunto de dados X , uma relação de compatibilidade fuzzy R , sobre X é definida em termos de uma apropriada função de distância. Pode-se utilizar vários tipos dessas funções, sendo uma delas a função de distância de Minkowski, definida pela equação (3.15).

$$R(x_i, x_k) = 1 - \delta \left(\sum_{j=1}^p |x_{ij} - x_{kj}|^q \right)^{\frac{1}{q}} \quad \forall (x_i, x_k) \in X \quad (3.15)$$

onde δ é uma constante que assegura que $R(x_i, x_j) \in [0, 1]$. O valor de δ deve ser o inverso da maior distância dos elementos pertencentes a X .

Em geral, R definido pela equação (3.15) é uma relação de compatibilidade, mas não necessariamente uma relação de equivalência fuzzy. É necessário, portanto, determinar a relação *max-min* transitiva de R . Isso pode ser feito através de um simples algoritmo descrito no (ANEXO I).

Para um melhor entendimento de como a relação de equivalência fuzzy pode ser aplicada para a realização de um agrupamento de uma base de dados, considera-se o seguinte exemplo retirado de (KLIR e YUAN, 1995):

¹⁰ O α -cut de um conjunto fuzzy A é um conjunto clássico definido por: $A_\alpha = \{x \mid \mu_A(x) \geq \alpha\}$.

Considerando-se uma base de dados em X constituída de cinco pontos em $\mathbb{R}^2$ conforme mostrado na tabela 3.5:

TABELA 3.5: Amostra de dados em um conjunto X

k	1	2	3	4	5
x_{k1}	0	1	2	3	4
x_{k2}	0	1	3	1	0

Num primeiro passo, utiliza-se a distância Minkowski com $q = 2$, o que equivale à distância euclidiana. Desde que a maior distância euclidiana entre os dados deste conjunto seja entre os valores x_1 e x_5 e seja igual a “4”, isto implica que $\delta = 1/4 = 0.25$. Uma vez definido o valor de δ pode-se calcular os graus de pertinência da relação de compatibilidade fuzzy R a partir da equação (13.18) por exemplo:

$$R(x_1, x_3) = 1 - 0,25((x_{11} - x_{31})^2 + (x_{12} - x_{32})^2)^{\frac{1}{2}}$$

$$R(x_1, x_3) = 1 - 0,25((0 - 2)^2 + (1 - 3)^2)^{\frac{1}{2}}$$

$$R(x_1, x_3) = 0,1$$

Repetindo esse procedimento para todos vetores $(x_i, x_k) \in X$, obtém-se a relação de equivalência fuzzy representada pela matriz:

$$R = \begin{bmatrix} 1 & 0,65 & 0,1 & 0,21 & 0 \\ 0,65 & 1 & 0,44 & 0,5 & 0,21 \\ 0,1 & 0,44 & 1 & 0,44 & 0,1 \\ 0,21 & 0,5 & 0,44 & 1 & 0,65 \\ 0 & 0,21 & 0,1 & 0,65 & 1 \end{bmatrix}$$

Nota-se que a matriz R é reflexiva e simétrica pois satisfaz as relações $R(x_i, x_k) = 1$ quando $i = k$ e $R(x_i, x_k) = R(x_k, x_i) \quad \forall x \in X$ respectivamente. Porém, essa relação

não é *max-min* transitiva. Aplica-se então ao algoritmo apresentado no (ANEXO I) e obtém-se a seguinte relação *max-min* transitiva:

$$R_T = \begin{bmatrix} 1 & 0,65 & 0,44 & 0,5 & 0,5 \\ 0,65 & 1 & 0,44 & 0,5 & 0,5 \\ 0,44 & 0,44 & 1 & 0,44 & 0,44 \\ 0,5 & 0,5 & 0,44 & 1 & 0,65 \\ 0,5 & 0,5 & 0,44 & 0,65 & 1 \end{bmatrix}$$

Essa relação induz a quatro distintas porções de seus α -cut que representam grupos similares no conjunto de dados.

$$\alpha \in [0, 0.44] : \{ \{ x_1, x_2, x_3, x_4, x_5 \} \}$$

$$\alpha \in (0.44, 0.50] : \{ \{ x_1, x_2, x_4, x_5 \}, \{ x_3 \} \}$$

$$\alpha \in (0.50, 0.65] : \{ \{ x_1, x_2 \}, \{ x_3 \}, \{ x_4, x_5 \} \}$$

$$\alpha \in (0.65, 1.00] : \{ \{ x_1 \}, \{ x_2 \}, \{ x_3 \}, \{ x_4 \}, \{ x_5 \} \}$$

Esse resultado combina com a nossa percepção visual da geometria do agrupamento nos dados (ver figura 3.21). Isto é sem duvida devido ao uso da distância *Euclidiana*. O dendograma do agrupamento dos dados utilizando a distância *Euclidiana* para esse exemplo é ilustrado na figura 3.20:




FIGURA 3.20: Ilustração da árvore de cluster ou dendograma do exemplo dado

Pode ser visto de acordo com a figura 3.21, como os dados foram agrupados para $\alpha = 0,65$:




FIGURA 3.21: Agrupamento de dados pelo método de relações de equivalência fuzzy

3.2.5 Mapa Auto Organizável de Kohonen

As redes neurais artificiais tiveram como uma das suas primeiras aplicações o reconhecimento de padrões, obtendo grande êxito por explorar as capacidades cognitivas e simular o comportamento de redes neurais naturais. Um dos paradigmas de aprendizado mais comuns no caso de reconhecimento de padrões é o supervisionado, associado a uma rede direta multi-camadas (MLP) e o algoritmo de retro-propagação (backpropagation), (ver seção 3.2.6). Contudo, o aprendizado competitivo e não supervisionado também vem demonstrando bons resultados na classificação de padrões, especialmente o modelo de Kohonen.

As redes não supervisionadas utilizam um algoritmo de aprendizado auto-organizável com o propósito de descobrir características ou padrões significativos em um conjunto de dados de entrada, sem a necessidade de um “professor”, como no caso das redes supervisionadas. Este tipo de aprendizado consiste na repetida modificação dos pesos sinápticos da rede em resposta a padrões de ativação e de acordo com regras pré-estabelecidas, até o desenvolvimento de uma configuração final.

A abordagem competitiva se caracteriza principalmente por: um conjunto de neurônios idênticos entre si, diferenciando-se apenas na distribuição aleatória de seus pesos sinápticos; existência de um limite imposto sobre a força de cada neurônio, ou seja, há um valor máximo que define a ativação de um neurônio; presença de um mecanismo que permite ao neurônio competir pelo direito de responder a um dado subconjunto da entrada, de forma que apenas um neurônio de saída esteja ativo em um instante. Este neurônio é denominado neurônio vencedor leva tudo (*winner takes all*).

O mapa auto-organizável proposto por Teuvo Kohonen (KOHONEN, 1990) foi um dos pioneiros na teoria de redes competitivas. Devido à sua popularidade, neurônios de uma rede competitiva são geralmente chamados de neurônios de Kohonen, do mesmo modo que mapas auto-organizáveis ou mapas topológicos de características auto-organizáveis também o são.

A estrutura de uma rede de Kohonen é construída em torno de uma grade uni ou bidimensional de neurônios para capturar as características importantes contidas num espaço de dados de interesse, conforme mostrado na figura 3.22. Assim, a rede fornece uma representação estrutural dos dados de entrada pelos vetores de peso dos neurônios como protótipos.

O algoritmo responsável pela formação do mapa auto-organizável, também chamado algoritmo SOM¹¹, começa inicializando os pesos sinápticos da grade aleatoriamente. Logo, nenhuma organização prévia é imposta ao mapa de características. Após essa fase, há três processos importantes para a construção do mapa: a competição, a cooperação e a adaptação.




FIGURA 3.22: Diagrama ilustrativo de mapa de Kohonen

O modelo de Kohonen produz um mapeamento topológico que localiza otimamente um número fixo de vetores em um espaço de entrada de dimensionalidade mais elevada e, desse modo, facilita a compressão de dados. Segundo (HAYKIN, 2001), é possível derivar o modelo de Kohonen de duas formas. A primeira utiliza as idéias básicas de auto-organização, motivadas por considerações neuro-biológicas, para derivar o modelo tradicional. A segunda forma de se derivar o modelo de Kohonen é utilizando uma abordagem de quantização vetorial (LQV¹²) que usa um modelo envolvendo um codificador e um decodificador. Na figura 3.23 é mostrado o

¹¹ Do inglês Self-Organizing Map

¹² Do inglês Learning Quantization Vector

modelo LQV de Kohonen, também chamado camada de Kohonen. A seguir, será tratada mais especificamente esta segunda abordagem.




FIGURA 3.23: Diagrama ilustrativo da camada de Kohonen

Na camada de Kohonen, para um dado vetor de entrada “ $X = [X_1, X_2, \dots, X_n]$ ”, um e somente um neurônio de Kohonen é ativado em “1”, os demais apresentam saída zero, isto é, para um dado vetor de entrada existe um único neurônio ativo. Todo neurônio de Kohonen está associado a um conjunto de pesos que o conectam a cada componente do vetor de entrada, conforme exposto na FIG. 3.22. Por exemplo, o neurônio N_1 tem associado a ele seus respectivos pesos ($W_{11}, W_{21}, \dots, W_{n1}$), compreendendo um vetor de peso W_1 . A saída de cada neurônio da camada de Kohonen é a soma das entradas, ponderadas pelos pesos de conexão, de acordo com a equação (13.16).

$$Y_j = \sum_{i=1}^n X_i W_{ij} \quad (3.16)$$

A rede de Kohonen classifica os vetores de entrada em grupos que são similares, isto é, acompanhado pelo ajuste dos pesos da rede de Kohonen, de modo que os vetores de entrada similares ativam o mesmo neurônio de Kohonen. O treinamento da rede de Kohonen é feito por um algoritmo não supervisionado e a isto se deve à dificuldade de se determinar qual neurônio

específico da camada de Kohonen será ativado, porém, somente é necessário garantir que o treinamento separe os vetores em grupos similares. O neurônio a ser ativado é determinado por $\max(Y_j)$, e o ajuste dos pesos é feito através da equação (3.17).

$$W_{ij}(k+1) = W_{ij}(k) + \alpha(X_i - W_{ij}(k)) \quad (3.17)$$

onde α é a taxa de ajuste de pesos, tomada positiva e menor ou igual a “1”. Inicialmente toma-se α com valor próximo do limite superior no intervalo $[0, 1]$ e, à medida que os pesos vão se ajustando, o valor de α é reduzido para um valor próximo de “0”.

3.2.6 Rede Perceptron de Múltiplas Camadas

Conforme exposto em (BRAGA et al., 2000), as redes neurais de uma só camada resolvem apenas problemas linearmente separáveis. A solução de problemas não linearmente separáveis passa pelo uso de redes com uma ou mais camadas intermediárias, ou escondidas. Uma rede com uma camada intermediária permite implementar qualquer função contínua. A utilização de duas camadas intermediárias permite a aproximação de qualquer função. Com isto, conclui-se que a rede neural de múltiplas camadas (MLP) com algoritmo de retro-propagação (*backpropagation*), apresentam um poder computacional muito maior do que aquele apresentado pelas redes sem camadas intermediárias. A rede MLP é uma das mais conhecidas e aplicadas arquiteturas de redes neurais. Sua arquitetura (ou topologia) consiste de uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída, conforme apresentado na figura 3.24. Os neurônios são conectados por arcos e a cada arco está associado um peso. A comunicação entre os neurônios é realizada através dessas interconexões ponderadas. Cada neurônio da rede tem uma função não-decrescente e diferenciável, conhecida como função de ativação.




FIGURA 3. 24: Estrutura de uma rede neural perceptron de múltiplas camadas.
Fonte: (HAYKIN, 2001)

Nesse tipo de rede, um sinal de entrada se propaga para frente através da rede, camada por camada, até que a camada de saída seja atingida, gerando assim a resposta da rede a esse sinal de entrada. Este processo é conhecido como *feed-forward*.

Conforme mencionado anteriormente, o treinamento de tal rede é realizado pelo algoritmo backpropagation de forma supervisionada. Esse treinamento supervisionado consiste em dois passos. No primeiro, um padrão é apresentado às unidades da camada de entrada e, a partir dessa camada as unidades calculam sua resposta produzida na camada de saída, o erro é calculado (diferença entre a saída obtida e a saída desejada) e no segundo passo, este 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, utilizando-se a regra Delta generalizada, que minimiza o erro quadrático médio utilizando o método do gradiente descendente. Desta maneira, os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retro-propagado.

Esse processo gira em torno de um conjunto de amostra de treinamento $\{x(p), d(p)\}$ (para $n = 1, \dots, P$) onde P é o número de amostras de treinamento contidas no conjunto de amostras, $x(p)$ é o vetor de entrada da rede, $d(p)$ é a resposta que se deseja obter para o estímulo $x(p)$, e o erro $e(p)$ é dado pela equação (3.18):

$$e_j(p) = d_j(p) - y_j(p) \quad (3.18)$$

onde $y(p)$ é a saída real da rede naquele momento.

O processo da propagação para frente (*feed-forward*) e o algoritmo do *backpropagation* (retro-propagação) são apresentados em maiores detalhes no (ANEXO II) e em (HAYKIN, 2001).

Depois que a rede estiver treinada e o erro estiver em um nível satisfatório, ela poderá ser utilizada como uma ferramenta para classificação de novos dados. Para isto, a rede deverá ser utilizada apenas no modo progressivo (*feed-forward*). Ou seja, novas entradas apresentadas à camada de entrada 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 é o modelo dos dados, na interpretação da rede.

Uma limitação da aplicação de tal rede refere-se ao tempo de treinamento de redes neurais utilizando *backpropagation*, que tende a ser muito lento. Algumas vezes são necessários milhares de ciclos para se chegar a níveis de erros aceitáveis, principalmente se estiver sendo simulado em computadores seriais, pois a CPU deve calcular as funções para cada unidade e suas conexões separadamente, o que pode ser problemático em redes muito grandes, ou com grande quantidade de dados. Muitos estudos estão sendo realizados para implementação de redes neurais em computadores paralelos (BRAGA et al., 2000).

Outro problema é definir a arquitetura ideal da rede de forma que ela seja tão grande quanto o necessário para conseguir obter as representações necessárias, ao 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. Uma das maneiras de se resolver esse problema é a utilização da métrica de Hecht-Nielsen (HECHT-NIELSEN, 1990) que afirma que, com apenas uma camada oculta, já é possível calcular uma função arbitrária qualquer a partir de dados fornecidos. De acordo com essa métrica, a camada oculta deve ter por volta de $2n + 1$ neurônios, onde n é o número de variáveis de entrada.

3.2.7 Sistemas Neuro-fuzzy e Redes Neurais Fuzzy (FNN¹³)

Conforme mencionado anteriormente, as redes neurais são ótimas para a detecção de padrões, porém não são boas para explicar como esses padrões são alcançados. Já os sistemas fuzzy que trabalham com a imprecisão e explicam bem a sua tomada de decisão não podem gerar automaticamente as regras que tomaram aquela decisão. A limitação das características computacionais particulares vem impulsionando os pesquisadores a investir na criação de sistemas inteligentes híbridos, onde duas ou mais técnicas de inteligência computacional são combinadas para suprir as limitações individuais de cada técnica.

Pesquisas recentes (GARZON et al., 2002) têm mostrado que sistemas inteligentes híbridos fornecem métodos eficientes para aplicações práticas. Ao se compensar as deficiências de uma técnica com os benefícios de outra, cria-se estruturas de enorme potencial. A natureza complementar dos dois sistemas descritos anteriormente (Sistemas Fuzzy e Redes Neurais) propiciam a integração dessas tecnologias dando origem ao que hoje é chamado de sistemas *neuro-fuzzy*.

O objetivo principal de combinar sistemas fuzzy e redes neurais é desenvolver arquiteturas que utilizem sistemas fuzzy para representar e processar o conhecimento de forma clara e de fácil interpretação e aproveitem a capacidade de aprendizado das redes neurais. As redes neurais são uma boa forma de ajustar os conhecimentos especialistas e gerar automaticamente novas regras fuzzy e novas funções de pertinência. Por outro lado, a lógica fuzzy aperfeiçoa a capacidade de generalização dos sistemas de redes neurais, promovendo uma saída mais realista quando é necessária uma extrapolação além dos limites dos dados de treinamento.

¹³ Do inglês Fuzzy Neural Network

Segundo (PALADE et al., 2000), a combinação das redes neurais e sistemas fuzzy pode ser realizada de duas maneiras diferentes:

- a) ***A rede neural é a metodologia básica e a lógica fuzzy é a segunda:*** Estes sistemas híbridos são principalmente redes neurais, porém, estas são equipadas com habilidades de processamento de informações fuzzy. Estes sistemas são usualmente chamados de **redes neurais fuzzy** e são redes neurais cujas entradas, saídas e os pesos são conjuntos fuzzy e, usualmente, são providas de neurônios chamados neurônios fuzzy.
- b) ***A lógica fuzzy é a metodologia básica e a rede neural é a subsequente.*** Estes sistemas são basicamente sistemas fuzzy incorporados de habilidades das redes neurais, tais como: aprendizado, adaptação e paralelismo. Estes sistemas são usualmente chamados de **sistemas neuro-fuzzy**. Tais sistemas são representados como um modo especial de sistemas fuzzy aprenderem informações de uma base de dados, utilizando algoritmos de aprendizado das redes neurais, ou seja, os sistemas neuro-fuzzy podem ser sempre interpretados como um conjunto de regras fuzzy que podem ser representadas com a arquitetura de uma rede neural. Um exemplo de um sistema neuro-fuzzy é o sistema ANFIS apresentado na seção (3.2.3).

As redes neurais fuzzy utilizam uma “máquina fuzzy” para combinar lógica fuzzy e redes neurais. A máquina fuzzy é um processador que recebe dados padrões como entrada e converte-os em categorias difusas para serem utilizadas pelas redes neurais. Uma RNA pode converter o conhecimento em regras polivalentes e funções de pertinência e a lógica fuzzy pode otimizar o número de regras que a rede aprende. A estrutura de uma rede neural fuzzy pode ser composta de uma camada de fuzzyficação, uma camada oculta e uma camada de saída conforme apresentado na figura 3.25.




FIGURA 3.25: Estrutura básica de uma rede neural fuzzy
Fonte: (PATTON et al., 1999)

A entrada é fuzzyficada com funções de pertinência previamente construídas para cada variável de entrada e, posteriormente, esses valores fuzzyficados servem como entrada de uma rede neural que pode ser, por exemplo, uma rede do tipo MLP descrita anteriormente (ver seção 3.2.6). A rede é treinada com os dados fuzzyficados e as saídas da rede também são valores fuzzy que, se necessário podem ser defuzzyficadas por algoritmos de defuzzyficação mencionados na seção (3.2.1). Essa combinação resulta no aumento da velocidade, tolerância a erros e adaptabilidade. Em (CALADO et al., 2001), é relatado como tais técnicas podem ser aplicadas na forma de sistemas de diagnóstico de faltas; (PALADE et al., 2000) mostra a aplicação de sistemas neuro-fuzzy na detecção e isolamento de faltas de uma turbina industrial a gás e, em (HELL et al, 2002a), é apresentada um rede neural fuzzy no diagnóstico de faltas de transformadores de potência baseado na análise dos gases dissolvidos.

Tanto a Rede Neural Fuzzy, quanto as demais técnicas apresentadas neste capítulo, foram aplicadas ao problema de diagnóstico de faltas de disjuntores de alta tensão e seus resultados são apresentados no capítulo seguinte.

4. IMPLEMENTAÇÃO DAS TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL NO SISTEMA DE DIAGNÓSTICO

Este capítulo é dedicado à simulação e à apresentação de como as técnicas de inteligência computacional foram aplicadas para realizar o diagnóstico dos disjuntores FA1 da Lorenzetti (138 kV) e LTB da ABB (138 kV) a partir das variáveis propostas a serem monitoradas e, ainda, mostrar como a base de dados utilizada para o treinamento, análise e comparação das técnicas foi gerada. Utilizou-se o MATLAB como plataforma para simulação.

4.1 Formação da Base de Dados

A base de dados é formada de vetores constituídos de valores das variáveis de entrada do sistema especialista, ou seja, cada vetor possui um valor para o tempo de abertura (T_A), para o tempo de fechamento (T_F), para a pressão do gás SF_6 (P_{SF6}), para a pressão do sistema hidráulico ($P_{O/N2}$) (caso de disjuntores com acionamento hidráulico) e para a corrente do motor (I_{MT}) (caso de disjuntores com acionamento a mola). Esses vetores foram gerados de forma a representar todos os casos de falta apresentados nos fluxogramas das figuras 3.1 e 3.2. Desta maneira, a combinação das variáveis em cada vetor que não estivesse associada a algum tipo de falta, era descartada. Outra consideração feita durante a formação da base de dados, foi a de representar os dados o mais próximo do real possível através de observações realizadas em campo.

Contudo, para a utilização dos dados dessa base no desenvolvimento das técnicas de diagnóstico, necessitou-se não apenas das amostras de tais sinais mas, também, dos diagnósticos relativos a cada uma das amostras, para que assim fosse possível realizar o treinamento e o ajuste das técnicas propostas a serem utilizadas. Desenvolveu-se então um algoritmo que, a partir das informações referentes aos valores dos sinais propostos a serem monitorados, gerasse um diagnóstico que seria tomado como uma referência para a validação da utilização das técnicas de inteligência computacional propostas. O sistema de simulação de diagnóstico foi construído a partir dos fluxogramas de diagnóstico apresentados nas figuras 3.1 e 3.2, apresentadas no capítulo 3. O número total de amostras geradas e o número de amostras correspondente a cada tipo de falta, para os disjuntores dos tipos FA1 e LTB são apresentados nas tabelas 4.1 e 4.2, respectivamente.

TABELA 4.1: Número de amostras geradas para cada tipo de falta do disjuntor FA1

Tipo de falta	F.1	F.2	F.3	F.4	F.5	F.6	F.7	F.8	F.9	Total
Nº de amostras	69	87	79	62	86	78	121	99	102	783

TABELA 4.2: Número de amostras geradas para cada tipo de falta do disjuntor LTB

Tipo de falta	F.1	F.2	F.3	F.4	F.5	F.6	F.7	F.8	F.9	F.10	Total
Nº de amostras	61	89	89	68	99	81	82	95	69	58	791

Cada tipo de falta (F.1, F.2, ..., F.10) é relacionada a cada código de defeito de acordo com a tabela 3.2, sendo que, o “código 1”, representado nas tabelas acima como “F.1”, designa a condição normal de operação do disjuntor, e os demais, condições de falta.

4.2 Técnicas de Inteligência Computacional Aplicadas no Diagnóstico de Falhas de Disjuntores de Alta Tensão

Na tentativa de resolver o problema de identificação de falhas em disjuntores de alta tensão, a partir dos sinais propostos a serem monitorados, foram utilizadas 7 técnicas de inteligência computacional, conforme apresentadas no capítulo 3. As considerações de implementação de cada uma destas técnicas, bem como a comparação entre elas, são discutidas a seguir.

4.3 Sistema de Inferência Fuzzy (FIS) Aplicado ao Diagnóstico de Falhas de Disjuntores de Alta Tensão

A principal vantagem do Sistema de Inferência Fuzzy é que ele permite que as falhas sejam identificadas através de relações SE / ENTÃO, construídas a partir do conhecimento que o especialista tem do equipamento, devido às observações na operação do mesmo, sendo, portanto uma técnica de fácil implementação e entendimento.

O método aplicado foi o sistema de inferência fuzzy de Mamdani em que cada conseqüente das regras é especificado por um *singleton* fuzzy que equivale ao modelo de Sugeno de ordem zero, resumido da seguinte forma:

Entrada de dados: Valores “crisp” associados a cada uma das variáveis de entrada (T_A , T_F , P_{SF6} e $P_{O/N2}$ ou I_{MT}) são fornecidos ao sistema.

Fuzzificação: Os dados fornecidos são aplicados às funções de pertinências construídas a partir dos valores dos limites superior e inferior de cada variável conforme mostrado nas TAB's. 3.3 e 3.4 assumindo valores “*alto, médio e baixo*” e gerando números fuzzy. As funções de pertinências criadas para cada variável a ser monitorada nos disjuntores dos tipos FA1 e LTB são mostradas nas figuras 4.1 e 4.2, respectivamente.




FIGURA 4.1 Funções de pertinência das variáveis do disjuntor do tipo FA1




FIGURA 4.2 Funções de pertinência das variáveis do disjuntor do tipo LTB

Inferência: A partir das entradas fuzzificadas, todas as regras são verificadas e para cada regra é associado um fator de certeza. As regras criadas para a determinação do diagnóstico dos disjuntores com acionamento hidráulico (neste caso, o disjuntor do tipo FA1), bem como a estrutura completa do sistema de inferência fuzzy são mostradas na (FIG. 4.3).




FIGURA 4.3: Estrutura do Sistema de Inferência Fuzzy para o disjuntor do tipo FA1

Diagnóstico: O fator de certeza (ou índice de pertinência) de cada regra é obtido tomando-se o mínimo índice de pertinência das variáveis de entrada nos seus respectivos conjuntos (ver FIG. 3.15 – seção 3.2.2). Como neste caso, a saída não é uma função e, sim, conjuntos fuzzy *singleton*, esses valores são comparados, e a saída do sistema (o diagnóstico

final) é a saída da regra que possuir o maior fator de certeza. A FIG. 4.4 ilustra como o processo de inferência foi realizado para uma amostra.




FIGURA 4.4: Processo de inferência fuzzy

Os valores de $T_A = 40,75$ ms, $T_F = 85,9$ ms, $P_{SF_6} = 0,55$ MPa e $P_{O/N_2} = 32,5$ MPa são fuzzificados. Como pode ser visto, as regras 1, 2 e 5 são ativadas para esta entrada, porém o maior fator de certeza é dado pela regra cinco, cuja saída corresponde ao código 5, que representa uma falta de acordo com a tabela 3.2. Assim, a saída do sistema é representada por esse código.

Estrutura semelhante foi criada para diagnosticar faltas no disjuntor do tipo LTB (acionamento a mola carregada por motor elétrico). As entradas são submetidas às funções de pertinências mostradas na figura 4.2 e o processo de inferência para a determinação do diagnóstico é realizado da mesma maneira que o processo descrito anteriormente, porém com regras diferentes. As regras construídas para este tipo de disjuntor foram as seguintes:

- 1) **SE** T_A é Médio **E** T_F é Médio **E** P_{SF_6} é Médio **E** I_{MT} é Médio **ENTÃO** Saída é 1
- 2) **SE** T_A é Alto **E** T_F é Médio **E** P_{SF_6} é Médio **E** I_{MT} é Médio **ENTÃO** Saída é 2
- 3) **SE** T_A é Alto **E** T_F é Baixo **E** P_{SF_6} é Médio **E** I_{MT} é Médio **ENTÃO** Saída é 3

- 4) *SE T_A é Baixo E T_F é Médio E P_{SF6} é Médio E I_{MT} é Médio ENTÃO Saída é 4*
- 5) *SE T_A é Alto E T_F é Alto E P_{SF6} é Médio E I_{MT} é Médio ENTÃO Saída é 5*
- 6) *SE T_A é Baixo E T_F é Baixo E P_{SF6} é Baixo E I_{MT} é Médio ENTÃO Saída é 6*
- 7) *SE T_A é Alto E T_F é Alto E P_{SF6} é Alto E I_{MT} é Médio ENTÃO Saída é 7*
- 8) *SE T_A é Médio E T_F é Médio E P_{SF6} é Médio E I_{MT} é Zero ENTÃO Saída é 8*
- 9) *SE T_A é Médio E T_F é Alto E P_{SF6} é Médio E I_{MT} é Baixo ENTÃO Saída é 9*
- 10) *SE T_A é Alto E T_F é Médio E P_{SF6} é Médio E I_{MT} é Alto ENTÃO Saída é 10*

As saídas também correspondem aos códigos de faltas apresentados na tabela 3.2.

Os resultados obtidos pelo sistema de inferência fuzzy, através da base de dados gerada para cada um dos dois tipos de disjuntores, comparados aos resultados obtidos pelo sistema de simulação de diagnóstico construído a partir dos fluxogramas de diagnóstico apresentados nas figuras 3.1 e 3.2, são mostrados na tabela 4.3.

TABELA 4.3: Resultados obtidos pelo Sistema de Inferência Fuzzy (FIS)

Dados de Entrada	Nº de amostras testadas			
	Diagnósticos obtidos pela simulação		Diagnósticos obtidos pelo FIS	
	FA1	LTB	FA1	LTB
Amostras relacionadas à falta 1	69	61	56	61
Amostras relacionadas à falta 2	87	89	75	89
Amostras relacionadas à falta 3	79	89	92	89
Amostras relacionadas à falta 4	62	68	73	68
Amostras relacionadas à falta 5	86	99	87	138
Amostras relacionadas à falta 6	78	81	78	81
Amostras relacionadas à falta 7	121	82	121	82
Amostras relacionadas à falta 8	99	95	99	41
Amostras relacionadas à falta 9	102	69	102	84
Amostras relacionadas à falta 10	—	68	—	58
Total de acertos			756	737
Precisão			96,80%	93,20%

A discrepância elevada, entre os resultados da simulação e dos diagnósticos relativos às faltas 8 e 5 do disjuntor LTB e da falta 3 do disjuntor FA1, é explicada pelo fato de que os vetores relacionados a essas faltas contidos na base de dados gerada estão bem próximos das fronteiras com outros tipos de falta, desta maneira. O sistema de inferência fuzzy com as

funções de pertinência criadas, não conseguiu classificar corretamente todos os padrões para esses tipos de faltas. Como observa-se a seguir, pelos resultados do sistema ANFIS (tabela 4.4) onde as funções de pertinência são ajustadas através do treinamento, essa discrepância diminui consideravelmente.

4.4 Sistema de Inferência Fuzzy Neuro-Adaptativo (ANFIS) Aplicado ao Diagnóstico de Faltas de Disjuntores de Alta Tensão

Esta técnica foi utilizada com a finalidade de se criar uma estrutura adaptativa para o Sistema de Inferência Fuzzy descrito na seção anterior, realizando ajustes nas funções de pertinências criadas com o objetivo de minimizar o erro de saída e aumentar o índice de desempenho através de dados de treinamento.

Da mesma forma que o Sistema de Inferência Fuzzy desenvolvido, para o ANFIS foram utilizadas as mesmas entradas com as mesmas funções de pertinência apresentadas nas figuras 4.1 e 4.2. À medida em que os dados de treinamento (entradas e suas respectivas saídas) foram sendo apresentados ao sistema, os parâmetros das funções de pertinência foram sendo modificados ajustando as funções de pertinência para essa massa de dados. Como neste caso a saída não é uma função e, sim, conjuntos *singleton* fuzzy, os parâmetros consequentes não são ajustados e a saída é obtida aplicando-se uma função competitiva aos neurônios da camada 4, conforme apresentado na figura 4.5.




FIGURA 4.5: Estrutura construída para o ANFIS

Essa figura ilustra a estrutura do sistema ANFIS, construído com a finalidade de identificar faltas em disjuntores com acionamento hidráulico (neste caso, o disjuntor do tipo FA1). A estrutura construída para identificar faltas em disjuntores com acionamento à mola carregada por motor elétrico é semelhante à apresentada na figura 4.5, porém um dos parâmetros de entrada é a corrente do motor (I_{MT}), ao invés da pressão do sistema hidráulico (P_{O/N_2}) e, na camada 4, onde se encontram os consequentes, existe um nó a mais representando uma falta, pois para este tipo de disjuntor, com essas variáveis de entrada, é possível identificar 10 tipos diferentes de faltas, conforme apresentado na tabela 3.2.

No processo de treinamento do sistema, foram utilizadas 128 amostras de treinamento (aproximadamente 16 % da base de dados) para o disjuntor do tipo FA1 e 119 amostras de treinamento (aproximadamente 15% da base de dados) para o disjuntor do tipo LTB, e os testes de validação foram feitos utilizando o restante das amostras da base, ou seja, 655 amostras para o disjuntor do tipo FA1 e 672 amostras para o disjuntor do tipo LTB. Os resultados obtidos para o sistema ANFIS são apresentados na tabela 4.4. Vale lembrar que nos resultados apresentados nesta tabela, não são consideradas as amostras utilizadas para o treinamento tanto nas colunas

relacionadas aos diagnósticos obtidos pela simulação, quanto nas colunas relacionadas aos diagnósticos obtidos pelo ANFIS.

TABELA 4.4: Resultados obtidos pelo Sistema de Inferência Fuzzy Neuro-Adaptativo

Dados de Entrada	Número de amostras testadas			
	Diagnósticos obtidos pela simulação		Diagnósticos obtidos pelo ANFIS	
	FA1	LTB	FA1	LTB
Amostras relacionadas à falta 1	51	50	51	40
Amostras relacionadas à falta 2	68	72	62	70
Amostras relacionadas à falta 3	68	71	74	71
Amostras relacionadas à falta 4	52	59	52	59
Amostras relacionadas à falta 5	77	88	77	86
Amostras relacionadas à falta 6	69	68	69	68
Amostras relacionadas à falta 7	101	69	101	73
Amostras relacionadas à falta 8	82	87	82	83
Amostras relacionadas à falta 9	87	59	87	63
Amostras relacionadas à falta 10	—	49	—	59
Total de acertos			648	656
Precisão			99,00%	97,60%

4.5 Fuzzy C-means Aplicado ao Diagnóstico de Falhas em Disjuntores de Alta Tensão

A Clusterização é um assunto fundamental quando se trata de reconhecimento de padrões. A clusterização fuzzy é muito utilizada nesta área devido ao fato que, na maioria das aplicações práticas, uma partição crisp ou determinação de conjuntos pela lógica clássica pode ser muito restritiva e inviável devido, muitas vezes, às condições vagas e imprecisas de uma massa de dados. No entanto, quando se tem conhecimento a priori da massa de dados, ou seja, quando se sabe em quantos grupos de dados a massa de dados pode ser classificada, a técnica Fuzzy C-means torna-se uma ferramenta poderosa para a classificação de padrões. Assim, essa técnica pode ser utilizada com sucesso no diagnóstico de disjuntores, uma vez que o processo de diagnóstico de falhas de disjuntores, com base em um vetor de dados das variáveis propostas a

serem monitoradas, pode ser visto como um problema de classificação de padrões, onde cada classe refere-se a um tipo de falta.

As entradas do algoritmo Fuzzy C-means para o diagnóstico de disjuntores foram as mesmas utilizadas nas técnicas descritas anteriormente, ou seja, os tempos de abertura, tempos de fechamento, pressão do gás SF₆, pressão do sistema hidráulico (para caso do disjuntor FA1 que possui o sistema de acionamento hidráulico) e a corrente do motor de carregamento da mola (para caso do disjuntor LTB que possui o sistema de acionamento à mola). Inicialmente, foram definidos que o espaço de entrada fosse dividido em 9 grupos para a massa de dados do disjuntor do tipo FA1 e 10 grupos para a massa de dados do disjuntor do tipo LTB, onde cada um desses grupos é relacionado a um dos tipos de faltas descritos na tabela 3.2. Para o cálculo dos centros de cada grupo foi utilizado o mesmo número de amostras utilizado para o treinamento do sistema ANFIS, descrito na seção anterior, ou seja, 128 amostras para o disjuntor FA1 e 119 para o disjuntor LTB.

Antes de iniciar o processo de cálculo dos centros e dos níveis de pertinência de cada amostra à um determinado grupo, são definidos também uma medida de distância que define a distância permitida entre os pontos e os centros dos clusters (neste caso $m = 1,1$), um limite utilizado como critério de parada ($\epsilon = 1 \times 10^{-5}$) e o número de iterações máximo (1000). À medida que as variáveis de entrada são apresentadas ao algoritmo, vão sendo calculados os centros de cada grupo bem como o nível de pertinência de cada amostra à cada um dos grupos, de acordo com o algoritmo apresentado na seção (3.2.4.1). Ao final da última iteração, a pseudopartição obtida deve ser analisada segundo algum critério que expresse a idéia geral de que as associações são fortes dentro do *cluster* e fracas entre *clusters*. Este critério é definido como um índice de desempenho (ver equação 13.17) que mede, para todos os elementos, a soma das distâncias ponderadas de cada elemento a cada um dos centros dos *clusters* da pseudopartição. Quanto menor o valor deste índice, melhor a pseudopartição *fuzzy* gerada.

Desta maneira, foram calculados os centros e determinados os grupos relacionados a cada falta das amostras de treinamento. Assim, para o restante das amostras, foram calculadas as distâncias euclidianas de cada amostra a cada centro de cada grupo, classificando-as dentro do grupo no qual a distância euclidiana fosse a menor.

Para título de ilustração, escolheu-se as amostras relacionadas ao disjuntor FA1 e, como o espaço de entradas tem quatro dimensões (quatro variáveis), considerou-se que a pressão do óleo de sistema hidráulico ($P_{O/N2}$) estivesse invariante no seu valor nominal, não a representando a fim de se obter um espaço tridimensional e construir o gráfico apresentado na FIG. 4.6, que mostra os grupos formados (com os dados normalizados) relacionados a cada um dos sete tipos de falta possíveis de se identificar com $P_{O/N2}$ invariante, além de mostrar os centros calculados.




FIGURA 4.6: Resultados obtidos pelo algoritmo Fuzzy C-means

Nesse gráfico, cada um dos pontos plotados corresponde a uma amostra das variáveis propostas a serem monitoradas, e cada um dos formatos assumidos por estes pontos corresponde a um tipo de falta, conforme mostrado na legenda, e os pontos marcados por um “X” correspondem ao centro calculado para cada grupo.

Os resultados obtidos pela técnica de classificação de padrões Fuzzy C-means para o diagnóstico de disjuntores são apresentados na tabela 4.5, sendo que, dentro dos resultados apresentados nesta tabela, não estão sendo consideradas as amostras utilizadas para o cálculo dos centros.

TABELA 4.5: Resultados obtidos pelo Fuzzy C-means

Dados de Entrada	Número de amostras testadas			
	Diagnósticos obtidos pela simulação		Diagnósticos obtidos pelo Fuzzy C-means	
	FA1	LTB	FA1	LTB
Amostras relacionadas à falta 1	51	50	44	67
Amostras relacionadas à falta 2	68	72	63	72
Amostras relacionadas à falta 3	68	71	88	71
Amostras relacionadas à falta 4	52	59	49	59
Amostras relacionadas à falta 5	77	88	64	88
Amostras relacionadas à falta 6	69	68	69	68
Amostras relacionadas à falta 7	101	69	104	69
Amostras relacionadas à falta 8	82	87	88	87
Amostras relacionadas à falta 9	87	59	86	59
Amostras relacionadas à falta 10	—	49	—	32
Total de acertos			608	627
Precisão			92,90%	93,30%

4.6 Relações de Equivalência Fuzzy Aplicada ao Diagnóstico de Falhas em Disjuntores de Alta Tensão

A técnica de clusterização, baseada em relações de equivalência fuzzy, também pode ser aplicada ao diagnóstico de disjuntores pelo fato deste problema poder ser visto como um problema de classificação de padrões. Cada classe obtida com o uso de tal técnica representa um tipo de falta e cada vetor de entrada, composto das variáveis propostas para serem monitoradas, pode ser classificado dentro de um grupo de faltas específico, devido à sua relação com os elementos do mesmo. A vantagem do uso dessa técnica comparada ao uso do algoritmo Fuzzy C-means é que ela não requer que a quantidade de grupos a serem obtidos a partir de uma massa de dados seja especificada previamente. É ideal quando não se tem conhecimento algum sobre a massa de dados a ser tratada e pode ser útil para detectar um novo tipo de falta, ou seja, um tipo que não tenha sido previsto.

A massa de dados utilizada para a classificação dos conjuntos e obtenção do diagnóstico foi a mesma utilizada nas técnicas anteriores, tanto para o disjuntor do tipo FA1, quanto para o disjuntor do tipo LTB, onde cada amostra é um vetor contendo valores das variáveis propostas a serem monitoradas. A partir dessa massa de dados, foram calculadas as relações de compatibilidade fuzzy através da aplicação da equação (13.18) que indica o grau de similaridade entre cada amostra. Para o processamento desse cálculo, inicialmente foi obtido o valor de δ ($\delta = 0,62$ para a massa de dados relacionada ao disjuntor FA1 e $\delta = 0,60$ para o LTB) que é o inverso da maior distância dos elementos pertencentes à massa de dados normalizada e o parâmetro q da função de distância de Minkowski foi dado como $q = 2$, que equivale a distância euclidiana. Dessa forma, as relações de compatibilidade foram obtidas e formaram-se as matrizes (uma para o disjuntor FA1 e outra para o LTB) com os valores dessas relações. As duas matrizes obtidas eram simétricas e reflexivas. Para que elas se tornassem *max-min* transitivas foi aplicado o algoritmo descrito no (ANEXO I) obtendo-se, assim, as relações de equivalência fuzzy. O próximo passo foi a obtenção do valor do α -cut (que representa grupos similares no conjunto de dados) mais adequado ao problema proposto. Alguns valores de α -cuts foram testados e o valor que melhor representou a estrutura de dados para a classificação dos diferentes tipos de faltas foi α -cut = 0,83, para a massa de dados relacionada ao disjuntor FA1 e α -cut = 0,93 para a massa de dados relacionada ao disjuntor LTB.

Para a determinação das faltas, foram considerados vetores padrões que representam cada uma das nove faltas relacionadas ao disjuntor FA1 e cada uma das dez faltas relacionadas ao disjuntor LTB. A partir da matriz de relação de equivalência calculada anteriormente, é determinado, para cada amostra, o grau de similaridade com cada vetor padrão de falta. Desta maneira, a amostra é classificada no grupo de faltas o qual o grau de similaridade com o vetor padrão de falta é maior. Se o grau de similaridade de uma amostra com cada vetor padrão de faltas for pequeno (menor que o α -cut determinado anteriormente), esta amostra pode ser considerada um ruído, e se acontecer o mesmo com várias amostras, pode ser que esteja ocorrendo um tipo de falta não previsto.

Para ilustrar a aplicação deste método no diagnóstico de faltas de disjuntores, considerou-se um pequeno grupo de dados retirados das amostras relacionadas ao disjuntor

FA1, onde cada amostra é um vetor constituído dos valores de tempo de abertura, tempo de fechamento, pressão do gás SF₆ e pressão do sistema hidráulico, representados na tabela 4.6.

TABELA 4.6: Amostras de dados relacionadas ao disjuntor FA1.

Amostras:	X_{1p}	X_{2p}	X_{3p}	X₄	X₅	X₆
T_A (ms)	37,5	42,5	32,5	36,2	43,6	30,8
T_F (ms)	82,5	77,5	87,5	83,3	78,0	89,3
P_{SF6} (MPa)	0,56	0,56	0,56	0,55	0,54	0,57
P_{O/N2} (Mpa)	32,5	32,5	35,5	33,1	31,9	34,9

onde x_{1p} , x_{2p} e x_{3p} são vetores padrões relacionados às faltas 1, 3 e 9, respectivamente.

Calculam-se as relações de compatibilidade através da fórmula (3.18) com os valores de $q = 2$ e $\delta = 0,05$ (inverso da maior distância euclidiana entre os dados deste conjunto). A matriz das relações de compatibilidade fuzzy é apresentada a seguir:

$$R = \begin{bmatrix} 1 & 0,59 & 0,55 & 0,9 & 0,56 & 0,43 \\ 0,59 & 1 & 0,16 & 0,5 & 0,92 & 0,03 \\ 0,55 & 0,16 & 1 & 0,64 & 0,13 & 0,85 \\ 0,9 & 0,5 & 0,64 & 1 & 0,47 & 0,52 \\ 0,56 & 0,92 & 0,13 & 0,47 & 1 & 0,0 \\ 0,43 & 0,03 & 0,85 & 0,52 & 0,0 & 1 \end{bmatrix}$$

Nota-se que a matriz R é reflexiva e simétrica pois satisfaz as relações $R(x_i, x_k) = 1$ quando $i = k$ e $R(x_i, x_k) = R(x_k, x_i) \quad \forall x \in X$ respectivamente. Porém, essa relação não é *max-min* transitiva e aplica-se, então, ao algoritmo apresentado no (ANEXO I) e obtém-se a seguinte relação *max-min* transitiva (relação de equivalência fuzzy):

$$R_T = \begin{bmatrix} 1 & 0,59 & 0,64 & 0,9 & 0,59 & 0,64 \\ 0,59 & 1 & 0,59 & 0,59 & 0,92 & 0,59 \\ 0,64 & 0,59 & 1 & 0,64 & 0,59 & 0,85 \\ 0,9 & 0,59 & 0,64 & 1 & 0,59 & 0,64 \\ 0,59 & 0,92 & 0,59 & 0,59 & 1 & 0,59 \\ 0,64 & 0,59 & 0,85 & 0,64 & 0,59 & 1 \end{bmatrix}$$

Essa relação induz a quatro distintas porções de seus α -cut que representam grupos similares no conjunto de dados.

$$\begin{aligned} \alpha \in [0 - 0,59] &: \{ \{ x_{1p}, x_{2p}, x_{3p}, x_4, x_5 \} \} \\ \alpha \in (0,59 - 0,64] &: \{ \{ x_{1p}, x_{3p}, x_4, x_6 \}, \{ x_{2p}, x_5 \} \} \\ \alpha \in (0,64 - 0,92] &: \{ \{ x_{1p}, x_4 \}, \{ x_{2p}, x_5 \}, \{ x_{3p}, x_6 \} \} \\ \alpha \in (0,92 - 1] &: \{ \{ x_{1p} \}, \{ x_{2p} \}, \{ x_{3p} \}, \{ x_4 \}, \{ x_5 \}, \{ x_6 \} \} \end{aligned}$$

O Dendograma do grupamento dos dados utilizando a distância *Euclidiana* para este exemplo é ilustrado na figura 4.7:




FIGURA 4.7: Ilustração do dendograma do exemplo dado.

As amostras x_{1p} e x_4 são relacionadas à falta 1, as amostras x_{3p} e x_5 à falta 3 e as amostras x_{3p} e x_6 são relacionadas à falta 9 (ver tabela 3.2) para $\alpha = 0,92$. Assim, as amostras foram associadas aos vetores padrões das faltas que tinham o grau de similaridade maior. Esse mesmo processo foi realizado para toda a base de dados e os resultados obtidos para o diagnóstico de disjuntores são apresentados na tabela 4.7. Nos resultados apresentados nesta tabela estão sendo consideradas todas as amostras da base de dados.

TABELA 4.7: Resultados obtidos pela Relação de Equivalência Fuzzy.

Daddos de Entrada	Nº de amostras testadas			
	Diagnósticos obtidos pela simulação		Relação de Equivalência Fuzzy	
	FA1	LTB	FA1	LTB
Amostras relacionadas à falta 1	69	61	55	60
Amostras relacionadas à falta 2	87	89	78	85
Amostras relacionadas à falta 3	79	89	77	87
Amostras relacionadas à falta 4	62	68	64	68
Amostras relacionadas à falta 5	86	99	69	96
Amostras relacionadas à falta 6	78	81	79	81
Amostras relacionadas à falta 7	121	82	156	82
Amostras relacionadas à falta 8	99	95	111	96
Amostras relacionadas à falta 9	102	69	103	69
Amostras relacionadas à falta 10		68		69
Total de acertos				734
Precisão				93,80%
				752
				95,08%

4.7 Modelo de Kohonen Aplicado ao Diagnóstico de Faltas em Disjuntores de Alta Tensão

As Redes Neurais Kohonen (ou Mapa Auto Organizável de Kohonen), que são redes que possuem o aprendizado competitivo e não supervisionado, vêm demonstrando resultados significativos e com baixo custo computacional na descoberta de características ou padrões em um conjunto de dados. Dadas essas características, conclui-se que esse tipo de rede pode ser utilizado para diagnosticar faltas em disjuntores de alta tensão, através dos sinais propostos a

serem monitorados, classificando as amostras de dados dentro de grupos relacionados a cada tipo de falta.

Inicialmente, como entrada para a Rede Neural de Kohonen, foram utilizadas as mesmas variáveis de entrada utilizadas nos sistemas de diagnóstico apresentados anteriormente. Esta estrutura foi composta por quatro nós de entrada, referentes às variáveis propostas a serem monitoradas, tanto para os disjuntores com acionamento hidráulico, quanto para os disjuntores com acionamento a mola; nove neurônios de saída para o sistema elaborado para os disjuntores com acionamento hidráulico e dez neurônios para o sistema elaborado para os disjuntores com acionamento a mola, sendo que cada um deles está relacionado com um tipo de falta, listados na tabela 3.2.

Entretanto, verificou-se que, devido à Rede Kohonen identificar padrões pertencentes aos mesmos grupos através da distância euclidiana, ela fazia com que padrões de entrada, mesmo muito distantes no espaço, poderiam pertencer ao mesmo grupo de falta, enquanto padrões relativamente próximos poderiam pertencer a grupos distintos, o que também pode acontecer nas técnicas Fuzzy C-means e Relações de Equivalência Fuzzy, apresentadas anteriormente.

A forma encontrada de melhorar a performance desta rede foi fuzzificar os dados de entrada tomando-se os conjuntos fuzzy apresentados nas figuras 4.1 e 4.2, formando assim, a estrutura de uma rede neural Kohonen fuzzy. Dessa forma, os vetores muito distantes teriam pertinência igual a 1 no conjunto alto, independente do quanto esse vetor estivesse distante dos outros relacionados ao mesmo grupo (mesmo tipo de falta).

Assim, a nova estrutura testada foi composta por doze nós na camada de entrada do sistema elaborado para os disjuntores com acionamento hidráulico e treze nós de entrada para os disjuntores com acionamento a mola, sendo que cada um deles representava a pertinência, para cada uma das quatro variáveis de entrada, nos conjuntos Baixo ($\mu_B(\cdot)$), Médio ($\mu_M(\cdot)$) e Alto ($\mu_A(\cdot)$). A saída, da mesma forma que na estrutura anterior, era composta por nove neurônios para o sistema elaborado para os disjuntores com acionamento hidráulico e dez neurônios para

os disjuntores com acionamento a mola, cada um representando um tipo de falta. Desta maneira, quando é apresentada uma nova amostra à rede, depois de ter sido devidamente treinada, é ativado um único neurônio na camada de saída representando um tipo de falta. Esta estrutura apresentou uma melhora significativa na precisão da rede, porém não alcançou os resultados desejados. A partir disso, decidiu-se dobrar o número de neurônios na camada de saída obtendo-se, assim, dezoito neurônios na camada de saída da estrutura montada para o disjuntor com acionamento hidráulico e vinte neurônios na saída da estrutura montada para o disjuntor com acionamento a mola. Com isso, uma falta é representada por dois neurônios na camada de saída da rede. Do mesmo modo que a estrutura anterior, quando apresentada uma nova entrada para a rede, só um neurônio na camada de saída é ativado e este indica um tipo de falta das faltas descritas na tabela 3.2. Com a estrutura montada com dois neurônios indicando uma só falta, verificou-se que o espaço de saída da rede foi melhor representado obtendo-se uma melhor precisão. Houve, entretanto, um aumento no custo computacional mas, devido ao aumento significativo na precisão da rede, concluiu-se que esta última estrutura de rede elaborada é a mais viável para a situação.

A estrutura da rede neural Kohonen fuzzy utilizada para detectar faltas nos disjuntores com acionamento hidráulico é ilustrada na figura 4.8. O treinamento desta rede foi realizado com o mesmo número de amostras utilizado para o treinamento dos sistemas ANFIS e Fuzzy C-means com o intuito de, posteriormente, comparar o desempenho da aplicação de tais técnicas.




FIGURA 4.8: Estrutura da Rede Neural Kohonen Fuzzy

Desta forma, o processo de obtenção do diagnóstico através das variáveis propostas a serem monitoradas é iniciado com o cálculo da menor distância entre os vetores de entrada fuzificados e os vetores de peso associados a cada um dos neurônios que compõem a saída da rede neural. Assim, o neurônio relativo ao vetor de pesos mais próximo do vetor de entrada é

considerado como vencedor, e o tipo de falta referente à amostra será aquele associado ao neurônio vencedor.

Os resultados obtidos aplicando-se a Rede Neural Kohonen Fuzzy para o diagnóstico de faltas em disjuntores de alta tensão são apresentados na (TAB 4.8).

TABELA 4.8: Resultados obtidos pela Rede Neural Kohonen Fuzzy

Dados de Entrada	Número de amostras testadas			
	Diagnósticos obtidos pela simulação		Diagnósticos obtidos pelo Kohonen fuzzy	
	FA1	LTB	FA1	LTB
Amostras relacionadas à falta 1	51	50	53	51
Amostras relacionadas à falta 2	68	72	70	72
Amostras relacionadas à falta 3	68	71	68	71
Amostras relacionadas à falta 4	52	59	50	58
Amostras relacionadas à falta 5	77	88	77	88
Amostras relacionadas à falta 6	69	68	69	68
Amostras relacionadas à falta 7	101	69	101	69
Amostras relacionadas à falta 8	82	87	81	87
Amostras relacionadas à falta 9	87	59	86	60
Amostras relacionadas à falta 10	—	49	—	48
Total de acertos			648	667
Precisão			99,00%	99,50%

4.8 Rede Neural Perceptron Multicamada Aplicada ao Diagnóstico de Faltas em Disjuntores de Alta Tensão

As redes neurais perceptron de multicamadas apresentam um poder computacional muito maior do que aquele apresentado pelas redes sem camadas intermediárias, possuem um campo de aplicação bastante amplo e têm grande capacidade de generalização e, por esses motivos, escolheu-se tal rede para elaboração de um sistema de diagnóstico.

As entradas utilizadas para a construção do sistema de diagnóstico de disjuntores foram as mesmas utilizadas nas técnicas anteriores e as saídas para se efetuar o treinamento

supervisionado foram aquelas obtidas através dos sistemas de simulação de diagnósticos apresentados nas figuras 3.1 e 3.2. O processo de treinamento utilizado foi o algoritmo backpropagation descrito no (ANEXO II), que é um dos algoritmos mais utilizados em aplicações práticas, podendo resolver problemas de previsão, classificação e reconhecimento de padrões. Entretanto, existem alguns desafios para se construir um sistema utilizando uma rede MLP com algoritmo backpropagation, são eles:

Para que uma rede neural possa aprender todos os padrões dos conjuntos de treinamento e tenha a capacidade de responder corretamente a padrões nunca vistos (generalizar) é preciso definir corretamente o tamanho da rede neural, ou seja, o número de camadas e o número de neurônios em cada camada. A maneira de se resolver esse problema é a utilização da métrica de Hecht-Nielsen (HECHT-NIELSEN, 1990), que afirma que com apenas uma camada oculta já é possível calcular uma função arbitrária qualquer a partir de dados fornecidos. De acordo com essa métrica, a camada oculta deve ter por volta de $2n + 1$ neurônios, onde n é o número de variáveis de entrada. Dessa forma, as redes construídas possuem quatro entradas e nove neurônios na camada intermediária. A quantidade de neurônios da camada de saída foi obtida de forma empírica, ou seja, foram testadas algumas estruturas, e a que apresentou o melhor resultado, tanto na precisão, quanto no custo computacional, foi a rede com nove neurônios na camada de saída, para o caso dos disjuntores com acionamento hidráulico e dez neurônios para a rede construída para os disjuntores com acionamento a mola carregada por motor elétrico. Nesse caso, a saída da rede passa apenas por uma função competitiva e o neurônio que apresentar maior valor de saída é associado a um código de falta conforme apresentado na tabela 3.2. Desse modo, quando a saída do neurônio N_1 vencia sobre as demais para uma determinada amostra, o código de diagnóstico relativo a esta amostra era igual a 1. Se o neurônio vencedor fosse o N_2 , o diagnóstico para a dada amostra seria 2 e, assim por diante.

A estrutura da rede MLP proposta para realizar o diagnóstico de disjuntores, em específico os disjuntores com acionamento hidráulico, é apresentada na figura 4.9.




FIGURA 4.9: Estrutura da Rede MLP para o diagnóstico de disjuntores.

Outro problema é a paralisia da rede neural. Com o treinamento, os pesos da rede podem alcançar valores muito altos. Com isso, a soma ponderada de cada processador torna-se muito alta também. Aplicando-se a função de ativação não linear à saída do neurônio, obtém-se valores que se aproximam da região de ativação. Desta forma, a derivada da função de ativação, que faz parte do processo de aprendizado do algoritmo backpropagation (ver ANEXO II), tende para zero fazendo com que a rede pare de aprender. Para resolver esse problema, é necessário que os valores iniciais dos pesos e limiares sejam distribuídos num intervalo pequeno. O intervalo escolhido foi entre -0.1 e +0.1. Outro procedimento adotado para evitar a paralisia da

rede foi o de normalizar os dados de entrada de maneira que eles estivessem contidos em um intervalo entre os valores 0 e 1.

Nessa rede, todos os neurônios foram implementados usando a função de ativação do tipo sigmoidal conforme a equação (4.1).

$$y_j^{(l)} = \frac{1}{1 - e^{-\delta x v_j^{(l)}}} \quad (4.1)$$

onde $y_j^{(l)}$ é a saída do neurônio j da camada l , $v_j^{(l)}$ é a soma ponderada de todas as entradas acrescida do bias e δ representa inclinação da função.

Dessa maneira, as redes foram treinadas com 128 amostras para o disjuntor FA1 com acionamento hidráulico e 119 amostras para o disjuntor LTB com acionamento à mola, extraídas aleatoriamente da base de dados. Os parâmetros da rede utilizados no treinamento são apresentados na tabela 4.9.

TABELA 4.9: Parâmetros usados na rede neural MLP.

Parâmetro	Valor
Número de camadas	3
Número de neurônios na camada 1	4
Número de neurônios na camada 2	9
Número de neurônios na camada 3	9
Tolerância de erro	10^{-2}
Taxa de aprendizado	Adaptativa
Coeficiente δ da função de ativação	1

Nesse processo, o valor da taxa de aprendizado é inicialmente fixado como um valor alto e depois reduzido gradativamente de acordo com a convergência do erro, evitando assim que a rede neural não fique estagnada num mínimo local e atinja o desempenho desejado (erro mínimo a ser atingido).

Os resultados obtidos para o diagnóstico de disjuntores utilizando a rede neural MLP são apresentados na tabela 4.10.

TABELA 4.10: Resultados obtidos pela Rede Neural MLP

Dados de Entrada	Número de amostras testadas			
	Diagnósticos obtidos pela simulação		Diagnósticos obtidos pela MLP	
	FA1	LTB	FA1	LTB
Amostras relacionadas à falta 1	51	50	43	38
Amostras relacionadas à falta 2	68	72	74	70
Amostras relacionadas à falta 3	68	71	71	71
Amostras relacionadas à falta 4	52	59	42	67
Amostras relacionadas à falta 5	77	88	62	79
Amostras relacionadas à falta 6	69	68	69	68
Amostras relacionadas à falta 7	101	69	115	78
Amostras relacionadas à falta 8	82	87	84	88
Amostras relacionadas à falta 9	87	59	95	62
Amostras relacionadas à falta 10	—	49	—	51
Total de acertos			619	638
Precisão			94,50%	94,90%

4.9 Rede Neural Fuzzy Aplicada ao Diagnóstico de Falhas em Disjuntores de Alta Tensão

A justificativa para a implementação de um sistema híbrido, como a Rede Neural Fuzzy para o diagnóstico de falhas em disjuntores é dada pelo fato de que a união de tais técnicas pode eliminar algumas limitações relacionadas a cada uma das mesmas como, por exemplo, a incapacidade da rede neural de explicar de forma clara os padrões alcançados e a incapacidade do sistema de inferência fuzzy de gerar automaticamente as regras para a tomada de decisão.

A estrutura construída para a rede neural fuzzy é semelhante à rede MLP mostrada na seção anterior, porém com uma camada de fuzzificação a mais, o que caracteriza a estrutura híbrida. A rede construída é dividida em três camadas: a camada de fuzzificação, onde os valores das variáveis propostas a serem monitoradas para os dois tipos de disjuntores são fuzzyficados, de acordo com as funções de pertinência apresentadas nas figuras 4.1 e 4.2 e a saída dessa camada que é composta de doze nós para a estrutura montada para o disjuntor com acionamento hidráulico e treze nós para a estrutura montada para o disjuntor com acionamento a

mola; uma camada oculta com o mesmo número de neurônios das redes MLPs apresentadas na seção anterior e a camada de saída, representada por um vetor de nove neurônios para a estrutura criada para o disjuntor com acionamento hidráulico e um vetor de dez neurônios para o disjuntor com acionamento a mola, onde o primeiro neurônio representa a condição normal do disjuntor e cada um dos outros representam uma condição de falta, conforme apresentado na tabela 3.2. Dessa maneira, a rede é treinada (também pelo algoritmo backpropagation) para obter o valor “1” para o neurônio que representa o diagnóstico correto para uma dada amostra, e o valor “0” para os outros neurônios. Mesmo assim, quando apresentadas amostras diferentes das que foram treinadas, os neurônios das camadas de saída apresentavam valores diferentes de “0” e “1”, assim o valor final do diagnóstico é dado pelo neurônio com o maior valor de saída. A estrutura criada para diagnosticar falta em disjuntores (neste caso o disjuntor com acionamento hidráulico) é apresentada na figura 4.10.




FIGURA 4.10: Estrutura da Rede Neural Fuzzy para o diagnóstico de disjuntores

As entradas dessa rede foram as mesmas utilizadas nas técnicas descritas anteriormente para os dois tipos de disjuntores e, para o treinamento, utilizou-se o mesmo número de amostras utilizadas no treinamento das técnicas já descritas, ou seja, 15% da base de dados do disjuntor LTB e 16% de todas as amostras geradas para o disjuntor FA1, e o restante da base foi utilizada para testes de validação. Essa técnica apresentou uma grande melhoria na velocidade de treinamento e na precisão do diagnóstico comparado ao uso da rede MLP tradicional. Os resultados obtidos para o diagnóstico de disjuntores utilizando a Rede Neural Fuzzy são apresentados na tabela 4.11.

TABELA 4.11: Resultados obtidos pela Rede Neural Fuzzy

Dados de Entrada	Número de amostras testadas			
	Diagnósticos obtidos pela simulação		Diagnósticos obtidos pela FNN	
	FA1	LTB	FA1	LTB
Amostras relacionadas à falta 1	51	50	48	51
Amostras relacionadas à falta 2	68	72	70	71
Amostras relacionadas à falta 3	68	71	68	71
Amostras relacionadas à falta 4	52	59	52	59
Amostras relacionadas à falta 5	77	88	78	89
Amostras relacionadas à falta 6	69	68	69	66
Amostras relacionadas à falta 7	101	69	101	69
Amostras relacionadas à falta 8	82	87	82	86
Amostras relacionadas à falta 9	87	59	87	60
Amostras relacionadas à falta 10		49		50
Total de acertos			652	667
Precisão			99,40%	99,30%

4.10 Análise Comparativa dos Resultados Obtidos pelas Técnicas Propostas a Serem Utilizadas para o Diagnóstico de Disjuntores

As técnicas que apresentaram uma melhor precisão no diagnóstico de faltas de disjuntores foram as Redes Neurais Fuzzy, a Rede Neural Kohonen Fuzzy e o sistema ANFIS, com as Redes Neurais Fuzzy e Rede Neural Kohonen Fuzzy obtendo os melhores índices. Em termos de custos computacionais, a Rede Neural Kohonen Fuzzy obteve um melhor

desempenho (maior velocidade de processamento), comparado ao ANFIS e à Rede Neural Fuzzy. Porém, uma vez que os diagnósticos utilizados no treinamento foram obtidos a partir de simulação baseada nos algoritmos construídos e representados nas figuras 3.1 e 3.2, muitas vezes os dados gerados podem não apresentar com precisão a realidade da condição do equipamento devido às condições climáticas às quais esses equipamentos são submetidos, podendo assim aumentar ou diminuir valores como, por exemplo, a pressão do gás SF₆ ou a pressão do sistema hidráulico, sem que esteja ocorrendo uma falta no equipamento. Sob essas condições, é possível que as técnicas ANFIS e Redes Neurais Fuzzy tenham uma melhor aproximação para diagnósticos reais obtidos em campo, devido à grande capacidade de mapeamento não linear.

O algoritmo Fuzzy C-means obteve o menor tempo de treinamento e processamento (cálculo dos centros e obtenção do diagnóstico) dentre todas as técnicas apresentadas, porém, os índices de acertos foram os menores. O uso da Relação de Equivalência Fuzzy, para o diagnóstico de disjuntores, produziu resultados melhores que o algoritmo Fuzzy C-means apresentado, porém com um tempo de processamento um pouco maior, mas, mesmo assim, menor do que o tempo gasto na maioria das técnicas. O uso da Relação de Equivalência fuzzy tem a vantagem de não requerer um conhecimento *a priori* da massa de dados a ser tratada com é o caso do algoritmo Fuzzy C-means e da Rede Kohonen Fuzzy, onde se deve determinar o número de grupos e o número de neurônios relacionados a cada falta respectivamente, e não é necessária a utilização dos dados de saída (os diagnósticos) relacionados a cada amostra para o processamento, como é o caso da Rede MLP, Rede Neural Fuzzy e do Sistema ANFIS. No entanto, a utilização da Relação Equivalência Fuzzy é a mais indicada quando não se tem conhecimento *a priori* da massa de dados e não está disponível a relação de entrada x saída (sintoma x falta) na base de dados.

A partir dessa análise, conclui-se que das técnicas utilizadas com treinamento não supervisionado, a Rede Neural de Kohonen fuzzy é mais apropriada, pois apresentou o melhor resultado com um tempo de processamento pequeno e, das técnicas que utilizaram o aprendizado supervisionado, conclui-se através da análise dos índices de acertos e do custo computacional que, a Rede Neural Fuzzy é a mais indicada. Vale lembrar que a técnica ANFIS,

construída a partir do Sistema de Inferência Fuzzy (FIS), apresentou uma boa precisão e, assim como o FIS, explica muito bem o processo de obtenção do diagnóstico.

As tabelas 4.12 e 4.13 apresentam um resumo dos resultados obtidos durante a utilização das técnicas propostas neste trabalho para a obtenção do diagnóstico dos disjuntores a SF₆ com acionamento hidráulico e a mola respectivamente, bem como os tempos de treinamento e de processamento gastos por cada técnica.

TABELA 4.12: Resumo dos resultados obtidos para o diagnóstico do disjuntor FA1

Código de Falta	Resultado Simulação	Número de amostras validadas						
		Diagnóstico FIS	Diagnóstico ANFIS	Diagnóstico F. C-means	Diagnóstico R.E.F.	Diagnóstico Kohonen F.	Diagnóstico MLP	Diagnóstico FNN
1	69	69	51	44	55	53	43	48
2	87	87	62	63	78	70	74	70
3	79	79	74	88	77	68	71	68
4	62	62	52	49	64	50	42	52
5	86	86	77	64	69	77	62	78
6	78	78	69	69	79	69	69	69
7	121	121	101	104	156	101	115	101
8	99	99	82	88	111	81	84	82
9	102	102	87	86	103	86	95	87
Total de acertos		756	648	608	734	648	619	652
Precisão		96,80%	99,00%	92,90%	93,80%	99,00%	94,50%	99,40%
Tempo de treinamento (s)		—	112,87	7,3	—	22,9	140,84	77,5
Tempo de processamento (s)		3,18	1,59	1,14	29,6	1,18	0,15	0,17

TABELA 4.13: Resumo dos resultados obtidos para o diagnóstico do disjuntor LTB

Código de Falta	Resultado Simulação	Número de amostras validadas						
		Diagnóstico FIS	Diagnóstico ANFIS	Diagnóstico F. C-means	Diagnóstico R.E.F.	Diagnóstico Kohonen F.	Diagnóstico MLP	Diagnóstico FNN
1	61	61	40	67	60	51	38	51
2	89	89	70	72	85	72	70	71
3	89	89	71	71	87	71	71	71
4	68	68	59	59	68	58	67	59
5	99	99	86	88	96	88	79	89
6	81	81	68	68	81	68	68	66
7	82	82	73	69	82	69	78	69
8	95	95	83	87	96	87	88	86
9	69	69	63	59	96	60	62	60
10	68	68	59	32	69	48	51	50
Total de acertos		737	656	627	752	668	638	667
Precisão		93,20%	97,60%	93,30%	95,08%	99,40%	94,90%	99,30%
Tempo de treinamento (s)		—	119,82	8,7	—	25,3	135,63	59,56
Tempo de processamento (s)		3,2	1,68	1,2	32,6	1,19	0,18	0,23

Vale lembrar que durante a aplicação do Sistema de Inferência Fuzzy e da Relação de Equivalência Fuzzy foram utilizadas todas as amostras da base de dados para a obtenção dos diagnósticos e apresentação dos resultados de acordo com as tabelas 4.12 e 4.13, enquanto que nas demais técnicas, as amostras utilizadas para o treinamento não foram consideradas durante a obtenção dos diagnósticos e apresentação dos resultados.

Com base nos resultados apresentados nas tabelas 4.12 e 4.13, pode ser visto que as técnicas que apresentam as maiores porcentagens de acerto foram o ANFIS, a Rede Neural Fuzzy e a Rede Neural de Kohonen fuzzy, e as técnicas que gastaram os menores tempos para a realização do diagnóstico foram o Sistema de Inferência Fuzzy, a Rede Neural de Kohonen fuzzy e o algoritmo Fuzzy C-means. Com isto, é possível concluir que a Rede Neural de Kohonen Fuzzy é a técnica que apresentou os melhores resultados, levando-se em consideração o percentual de acertos e o tempo gasto para a realização do diagnóstico, sendo que a Rede Neural Fuzzy e o ANFIS também atendem os requisitos mínimos considerando estes aspectos apresentados.

É importante ressaltar que a base de dados utilizada durante a obtenção dos resultados foi gerada aleatoriamente, dentro de limites aceitáveis para cada variável e a partir de combinações entre as variáveis possíveis de ocorrer (ver figuras 3.1 e 3.2). Entretanto, pretende-se obter amostras reais de tais variáveis através da implantação futura do sistema de monitoramento proposto neste trabalho, para validar a aplicação das técnicas desenvolvidas e obter diagnósticos reais. A obtenção dos tempos de abertura e fechamento será feita através da análise das oscilografias das correntes de interrupção, as quais já são monitoradas em algumas subestações através dos relés digitais. O levantamento dessas oscilografias já está sendo realizado e a proposta contendo o processo de obtenção dos tempos de abertura e fechamento, através da análise computacional das oscilografias das correntes de interrupção, é descrita no próximo capítulo, na seção 5.2, como uma proposta para continuidade deste trabalho.

5. CONCLUSÕES E PROPOSTAS PARA A CONTINUIDADE DO TRABALHO

Neste capítulo, são apresentadas as conclusões sobre a análise dos resultados mais importantes, bem como a proposta para a continuidade de trabalho.

5.1 Conclusões

Este trabalho concentrou-se na proposta de um sistema de monitoramento de disjuntores de alta tensão que consistiu em três fundamentos para torná-la viável, que são:

- a) Verificação dos sinais que podem ser obtidos utilizando recursos já existentes em algumas subestações;
- b) Escolha de sinais que possam identificar defeitos em componentes dos disjuntores que representam uma grande porcentagem nas causas de falhas;
- c) Escolha de sinais que possam ser monitorados sem alteração nas características construtivas do equipamento.

Além disso, propõe-se o uso de técnicas de inteligência computacional para a determinação do diagnóstico de faltas nos disjuntores de alta tensão, com base no vetor de dados das variáveis propostas a serem monitoradas.

Inicialmente, realizou-se um estudo do funcionamento de vários tipos de disjuntores, das principais causas de falhas, das técnicas de monitoramento que vêm sendo implantadas no mundo e dos recursos já existentes na concessionária local que podem ser utilizados para obter informações importantes da condição dos disjuntores, com o objetivo de se fazer uma proposta concisa e viável e adquirir o conhecimento necessário para determinar quais faltas (defeitos) as variáveis propostas a serem monitoradas podem indicar, fazendo-se uma correta análise das mesmas. Dessa forma, foi possível construir as relações entre a mudança na faixa de valores das variáveis propostas a serem monitoradas e as faltas que elas podem indicar, conforme apresentado na tabela 3.1. Foi possível, também, correlacionar os valores dessas variáveis e inferir o diagnóstico mais provável, conforme mostrado nos fluxogramas elaborados e apresentados nas figuras 3.1 e 3.2, lembrando que as faltas e seus códigos são listados na tabela 3.2, tanto para as faltas relacionadas aos disjuntores com acionamento hidráulico, quanto para os disjuntores com acionamento a mola.

Foram apresentadas, também, sete técnicas de inteligência computacional com a finalidade de diagnosticarem faltas em disjuntores de alta tensão e verificar a capacidade das mesmas na determinação do diagnóstico, chegando-se à conclusão que a Rede Neural Fuzzy, o Sistema de Inferência Fuzzy Neuro Adaptativo e a Rede Neural de Kohonen Fuzzy apresentaram uma grande precisão na solução do problema proposto, sendo que a Rede Neural de Kohonen Fuzzy requer menores custos computacionais, comparada a estas duas outras técnicas. Vale lembrar que a utilização da Relação Equivalência Fuzzy é indicada quando não se tem conhecimento *a priori* da massa de dados.

É importante, mais uma vez, salientar que os diagnósticos utilizados nos processos de treinamento e validação das técnicas utilizadas foram obtidos aplicando-se a base de dados gerada a partir dos algoritmos construídos com base nos fluxogramas mencionados anteriormente, elaborados a partir do conhecimento adquirido durante o estudo do estado da arte. Um objetivo futuro deste trabalho é aplicar as técnicas de inteligência computacional propostas a serem utilizados no diagnóstico de disjuntores a situações reais, com o sistema de monitoramento proposto devidamente implantado com o intuito de obter diagnósticos reais de faltas. Nesse caso, é possível que outras técnicas, tais como a Rede Neural Fuzzy, a Rede MLP e o ANFIS se mostrem mais adequadas do que a Rede Neural de Kohonen Fuzzy, devido à sua capacidade de mapeamento não linear.

5.2 Proposta para Continuidade de Trabalho

Conforme já descrito, a obtenção dos tempos de abertura e fechamento do disjuntor pode ser realizada fazendo-se uma análise dos registros das oscilografias das correntes no momento da interrupção e do restabelecimento das mesmas, sendo que o tempo de abertura pode ser obtido analisando-se a corrente no momento da interrupção e, o tempo de fechamento pode ser obtido analisando-se a corrente no momento de seu restabelecimento.

Como mencionado na seção 2.3, o tempo de abertura é compreendido entre o instante da energização da bobina de abertura e o instante de separação dos contatos, o tempo de fechamento é compreendido entre o instante da energização da bobina de fechamento e o instante de união dos contatos e o tempo de interrupção é compreendido entre o instante da energização da bobina de abertura e o instante em que a corrente foi interrompida, ou seja, o tempo de abertura somado ao tempo de duração do arco. O autor (SHENG et al., 2005) desenvolveu um sistema capaz de obter o tempo de duração do arco (tempo compreendido entre o momento de separação dos contatos e o momento de interrupção da corrente), através da análise de oscilografias lidas e registradas por um dispositivo capaz de fazer a leitura numa frequência de 1000 Hz ou 20 amostras por ciclo. No momento de separação dos contatos, a corrente que flui através dos mesmos sofre uma grande variação até o momento de sua extinção (valor zero de corrente). Com isso, torna-se possível obter esses momentos e calcular o tempo de duração do arco aplicando técnicas de processamento de sinais como a Transformada Discreta de Fourier e técnicas de estatística como a variância e o desvio padrão, conforme exposto no trabalho citado anteriormente. A figura 5.1 ilustra o registro de uma oscilografia retirada de (SHENG et al., 2005) bem como mostra a relação dos tempos envolvidos durante a interrupção de uma corrente.




FIGURA 5.1: Oscilografia da corrente de interrupção e tempos relacionados à abertura

Na figura 5.1, “**A**” é o momento de separação dos contatos, onde a corrente começa a variar, e “**B**” é o momento da extinção da corrente.

Alguns relés digitais já instalados em algumas subestações da concessionária de energia elétrica local, além de registrar essas oscilografias, de utilizar uma frequência de amostragem semelhante à do trabalho citado anteriormente, também são capazes de registrar o momento em que o disjuntor recebeu o comando de abertura ou fechamento. Dessa forma, é possível fazer uma análise desses dados e calcular os tempos de abertura, arco e interrupção durante uma abertura do disjuntor e o tempo de seu fechamento durante o fechamento do mesmo. Assim, os tempos de abertura e fechamento, obtidos através desta análise, servirão como entrada junto com as outras variáveis a serem monitoradas no sistema especialista, composto das técnicas desenvolvidas neste trabalho e das propostas a serem utilizadas para a obtenção do diagnóstico dos disjuntores. A figura 5.2 ilustra a estrutura básica do sistema proposto a ser desenvolvido.




FIGURA 5.2: Estrutura básica do sistema proposto.

É importante salientar que a análise das oscilografias para a obtenção dos tempos envolvidos na operação do disjuntor, tais como os tempos de abertura, fechamento e arco, pode ser realizada para qualquer tipo de disjuntor que é comandado por um relé digital com as características que já foram descritas anteriormente. Conclui-se, então, que este tipo de análise é extensivo aos mais variados tipos de disjuntores e economicamente viável a disjuntores com classe de tensão inferior a 63 kV, onde o monitoramento de outros tipos de sinais como pressão do gás SF₆, pressão do óleo, corrente do motor, etc. São inviáveis devido ao custo deste monitoramento comparado ao custo de tais disjuntores. Neste caso, pode-se fazer uma análise

somente dos tempos relacionados à operação do disjuntor e da corrente de interrupção, lembrando que os tempos de abertura e fechamento podem indicar mudanças nas partes mecânicas do disjuntor (fricção, lubrificação inadequada, corrosão, etc.) e mudanças no tempo de arco podem indicar deficiência no sistema de isolamento e extinção do arco, (vazamentos, diminuição da pressão do gás na câmara, etc.).

A análise das oscilografias também pode ser realizada para determinar os valores instantâneos da corrente de interrupção e, mediante a equação (2.1), estimar o desgaste dos contatos e determinar a vida útil dos mesmos.

O resgate dessas oscilografias já está sendo realizado, registrando-se um número por volta de duzentas, relacionadas a cinco disjuntores do tipo LTB do fabricante ABB, instalados em quatro diferentes subestações.

REFERÊNCIAS

AMINIAN, M.; AMINIAM, F. Neural Network Based Analog-Circuit Fault Diagnosis Using Wavelet Transformer as a Processor. **IEEE Transactions on Circuits and Systems II**, v.47, p.151-156, feb. 2000.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 7118: Disjuntores de Alta Tensão – especificação**. Rio de Janeiro: ABNT, 1994, 161p.

BEZDEK, J. C. **Pattern Recognition with Fuzzy Objective Function Algorithms**. Plenum Press, New York, 1981.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T.B. **Redes Neurais Artificiais Teoria e Aplicações**. LTC Editora, Rio de Janeiro, 2000, 262p.

BRANCO, F. G. Dicionário de Termos de Manutenção, Confiabilidade e Qualidade. Rio de Janeiro: Abramam: Associação Brasileira de Manutenção, 1996, 122p.

CALADO, J.; KORBICZ, J.; PATAN, K.; PATTON, R.; COSTA, J. M. G. S. Soft Computing Approaches to Fault Diagnosis for Dynamic Systems. **European Journal of Control**, v.7, p.248-286, 2001.

COLOMBO, R. **Disjuntores de Alta Tensão**. Siemens S.A. e Livraria Nobel S.A., 1ª edição, São Paulo: Nobel Ed., 1986, 202p.

DEMJANENKO, V.; et al. A Noninvasive Diagnostic Instrument for Power Circuit Breakers. **IEEE Transactions on Power Delivery**, v.7, p.656-663, abr. 1992.

DEXTER, A. L. Fuzzy Model Based Fault Diagnosis. **IEE Proceedings-Control Theory and Applications**, v.142, p.545-550, nov. 1995.

DEWULF, J. A.; JUNG, T.; DUPRAZ, J. P.; MONTILLET, G. F. A Development and Application of Circuit Breakers Diagnostic and Monitoring. **Transmission and Distribution Conference and Exposition**, v.2, p. 774-779, set. 2003.

DUFOURNET, D. Recent Evolution of High-Voltage SF₆ Circuit Breakers. **IEE Colloquium on Physics of Power Interruption**, p.3/1-3/3, out 1995.

DUKARM, J. J. Transformer Oil Diagnosis Using Fuzzy Logic and Neural Networks. **Canadian Conference on Electrical and Computer Engineering**, v.1, p.329-332, set. 1993.

DUPRAZ, J. A.; SCHIEMANN A.; MONTILLET, G. F. Design Objectives of New Digital Control and Monitoring of High Voltage circuit Breakers. **IEEE/PES Transmission and Distribution Conference and Exposition**, v.2, p.1088-1093, out. 2001.

ENGEL, J. C.; MURPHY W. J.; ORAVETZ, D. M. Remote Monitoring of Circuit Breakers. **Conference Record of the 1999 IEEE Industry Applications Conference**, v.4, p.2344-2347, out. 1999.

GARZON, M. H.; ANKARAJU, P.; DRUMWRIGHT, E.; KOZMA, R. Neurofuzzy Recognition and Generation of Facial Features in Talking Heads. **Proceedings of the 2002 IEEE International Conference on Fuzzy Systems**, v.2, p.926-931, mai 2002.

GERTLER, J. J. **Fault Detection and Diagnosis in Engineering Systems**. Marcel Dekker, 1^a edição, New York, 1998.

GOTO, K.; SAKAKIBARA, T.; KAMATA, I.; IJEDA S. On-line Monitoring and Diagnosis of Gas Circuit Breakers. **IEEE Transactions on Power Delivery**, Tokyo, v.4, n.1, p.375-381, jan. 1989.

GRIJP, M. H. B.; HOPKINS, R. A.; BEDET, J. S.; GREYLING, J. E. Condition Monitoring of High Voltage Circuit Breaker. **IEEE AFRICON 4th**, v.2, p.880-885, set. 1996.

HAYKIN S. **Redes Neurais: Princípios e Práticas**. 2^a ed., Porto Alegre-RS – Brasil: Bookman, 2001, 900p.

HELL, M. B.; D'Angelo, M. F. S. V.; COSTA Jr., P. P. Power Transformer Fault Diagnosis Based in Dissolved Gas Analysis Using a Fuzzy Neural Network Approach in Real Data Base. VINDUSCON – IEEE International Conference on Industry Application, 2002 **Advances Information Science and Soft Computing**, NY-USA: WEAS Press, Cap 34, p.181-186, 2002a.

HELL, M. B.; D'Angelo, M. F. S. V.; SILVA, N. A.; FONSECA, G. I. B.; COSTA Jr., P. P. Power Transformer Fault Diagnosis Based in Dissolved Gas Analysis Using Kohonen Neural Network Approach in Real Data Base. **VINDUSCON – IEEE International Conference on Industry Application**, 2002b.

HELL, M. B.; D'Angelo, M. F. S. V.; SILVA, N. A.; FONSECA, G. I. B.; COSTA Jr., P. P. An Adaptative Neuro-Fuzzy Inference System Based on Dissolved Gas Analysis for Fault Diagnosis for Power Transformers. **2002 WEAS International Conference on Power Engineering Systems**, 2002c.

HEISING, C. R.; JANSSEN, A. L. J.; LANZ, W.; COLOMBO, E.; DIALYNAS, E. N. Summary of CIGRÉ 13.06 Working Group World Wide Reliability Data and Maintenance Cost Data on High Voltage Circuit Breakers Above 63 kV. **IEEE Transactions on Power Delivery**, v.9, p.21-39, jan. 1994.

HENSMAN, G. O.; GALE, P. F. The Application of Disturbance for Cost Effective Protection and Switchgear Monitoring and Maintenance. **Electricity Distribution CIRED. 12th International Conference**. v.4, p.4.17/1 – 4.17/5, mai. 1993.

HETCH-NIELSEN, R. **Neurocomputing**. NY-NewYork USA Addison Wesley Publisher, 1990, 433p.

HUO, Y.; IOANNOU, P. A.; MIRMIRANI, M. Fault-Tolerant Control and Reconfiguration for High Performance Aircraft: Review. **CATT Technical Report 01-11-01**, http://www.usc.edu/dept/ee/catt/2002/ying/web_AIR/CATT-01-11-01.pdf, 2002.

IEEE Std C37.10-1995. IEEE Guide for Diagnostics and Failure Investigation of Power Circuit Breakers. **IEEE Power Engineering Society**, 1995, 55p.

IEEE Std C37.10.1-2000. IEEE Guide for the selection of Monitoring for Circuit Breakers. **IEEE Power Engineering Society**, 2000, 49p.

INTERNATIONAL STANDARDS IEC 56. High-Voltage Alternating Current Circuit Breakers. **International Electrotechnical Commission**, 1987.

ISERMANN, R.; ULIERU, M. Integrated Fault Detection and Diagnosis. **International Conference on Systems, Man and Cybernetics**, v.1, p.743-748, out. 1993.

JANG, J. –S. R. ANFIS: Adaptive-Neuro-Based Fuzzy Inference System. **IEEE Transactions on System, Man and Cybernetics**, v.23, n.3, p.665-685, mai./jun. 1993.

JANG, J. –S. R.; SUM, C. –T.; MIZUTANI, E. **Neuro-Fuzzy and Soft Computing**. NY-USA: Prentice Hall, 1997, 614p.

JONES C. J.; et al. Guidelines for Monitoring Control and Supervision of GIS Incorporating Advanced Technologies. **CIGRÈ 23-203**, 1996.

KATSCHINSKI, U.; OLSZEWSKI, W.; SCHAEFFLER, T. A New Generation of Control and Diagnostic Techniques for Gas Insulated Switchgear. **International Conference on Energy Management and Power Delivery**, v.2, p.607-6012, mar. 1998.

KIM, J. B.; KIM, M. S.; PARK, K. S.; SONG, W. P.; KIM, D. S.; KIL G. S. Development of Monitoring and Diagnostic System for SF₆ Gas Insulated Switchgear. **Conference Record of the 2002 IEEE International Symposium on Electrical Insulation**, p.453-456, abr. 2002.

KLIR, G. J.; YUAN, B. **Fuzzy Sets and Fuzzy Logic Theory and Applications**. Pertinence Hall, New Jersey, 1995, 574p.

KOHONEN, T. The Self Organizing Map. **Proceedings of IEEE**, v.78, p.1464-1480, set. 1990.

LAI, M. L.; et al. Mechanical Failure Detection of Circuit Breakers. **IEEE Transactions on Power Delivery**, New York, v.3, n.4, p.1724-1731, out. 1988.

LEE, D. S. S.; LITHGOW, B. J.; MORRISON, R. E. New Fault Diagnosis of Circuit Breakers. **IEEE Transactions on Power Delivery**, v.7, n.2, p.454-459, abr. 2003.

MANDAMI, E. H.; ASSILIAN, S. An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller. **International Journal of Man-Machine Studies**, v.7, n.1, p.1-15, jan. 1975.

MCLLOROY, C.; RICHEY, K. R.; WATSON, R. Circuit Breaker Condition Based Monitoring Developments. **Fourth International Conference on Trends in Distribution Switchgear**, p.168-172, nov. 1994.

MILACH, M. **Manutenção de Disjuntores de Alta Tensão**. Rio de Janeiro: Cervantes Ed., 1993, 235p.

NELSON, J. H. Electric Utility Considerations Circuit Breaker Monitoring. **IEEE/PES Transmission and Distribution Conference and Exposition**, v.2, p.1094-1097, out. 2001.

OHSHITA, Y.; HASHIMOTO, A.; KUROSAWA, Y. A Diagnostic Technique to Detect Abnormal Conditions of Contacts Measuring Vibrations in Metal Enclosures of Gas Insulated Switchgear. **IEEE Transactions on Power Delivery**, Tokyo, v.4, n.4, p.2090-2094, out. 1989.

OZAWA, J.; SHINDO, K.; SARUTA, H.; YAMASHITA, M. Ultra High Frequency Electromagnetic Wave Detector for Diagnostic of Metal Clad Switchgear Insulation. **IEEE Transactions on Power Delivery**, v.9, n.2, p.675-679, abr. 1994.

PALADE, V.; PATTON, R. J.; UPPAL, F. J.; QUEVEDO, J.; DALEY S. Fault Diagnosis of an Industrial Gas Turbine Using Neuro-Fuzzy Methods. http://web.comlab.ox.ac.uk/oucl/work/vasile.palade/papers/Palade_CongresIFAC2002.pdf, 2002.

PATTON, R. J.; LOPEZ-TORIBIO, C. J.; UPPAL, F. J. Artificial Intelligence Approaches to Fault Diagnosis. **IEE Colloquium on Condition Monitoring: Machinery**, p.5/1-518, abr. 1999.

PATTON, R. J.; KANGETHE, S. M. Robust Fault Diagnosis Using The Model-Based Approaches to Fault Diagnosis. **IEE Colloquium on Condition Monitoring and Failure Diagnosis**, p.2/1-213, nov. 1988.

POELT, A.; HAINES, M. Experiences with Condition Monitoring of HV Circuit Breaker. **IEEE/PES Transmission and Distribution Conference and Exposition**, v.2, p.1077-1082, out. 2001.

REASON, J. Circuit Breakers with on-line condition monitoring. **Electrical World**, v.209, n.2, p.21-26, feb. 1995.

RUNDE, M.; OTTESEN, G. E.; FAUGSTAD, K. Acoustic Diagnosis of High Voltage Circuit Breakers. **IEEE Transactions on Power Delivery**, Norwegian, v.7, n.3, p.1306-1315, jul. 1992.

SERNA, M. S. **Sistema de Monitoramento e Metodologia de Estimativa dos Tempos de Operação do Disjuntor**. Tese de Doutorado submetida à Escola Politécnica da Universidade de São Paulo – USP, abr. 2005.

SHENG, S.; LI, K. K.; CHAN, W.L.; ZENG, X. J.; XIANZHONG, D. A Practical Circuit Breaker Monitoring System. **Conference Record of the 2005 Industry Applications Conference**, v.2, p.867-872, out. 2005.

SOLIS, L. A.; et al. Experiência no Projeto de Sistemas de Monitoramento em Tempo Real de Disjuntores. **Anais do II CITENEL**, 2003.

STANEK, M. **Model-Aided Diagnosis for High Voltage Circuit Breakers**. Tese de Doutorado submetida ao Instituto Federal de Tecnologia - Suíça, Zuirich, 2000.

TAKAGI, T.; SUGENO, M. Fuzzy Identification Systems and its Application to Modeling Control. **IEEE Transactions on System, Man and Cybernetics**, v.15, p.116-132, 1985.

UTSUMI, T.; ENDO F.; ISHIKAWA, T.; IWAASA, S.; YAMAGIWA, T. Preventive Maintenance System with a Different Gas Injecting Facility for GIS. **IEEE Transactions on Power Delivery**, v.8, n.3, p.1107-1113, jul. 1993.

YAMAGIA, T.; YAMADA, H.; ENDO, F.; OHSHITA, Y.; IZUMI, S.; YAMADA, I. Development of Preventive Maintenance System for Highly Reliable Gas Insulated Switchgear. **IEEE Transactions on Power Delivery**, v.6, n.2, p.840-848, abr. 1991.

ZADEH, L. A. Fuzzy Sets. **Information and Control**, v.8, p.338-353, 1965.

ZIMMERMANN, H. –J. **Fuzzy Set Theory and Its Applications**. 4 ed., Boston/Dordrecht/London, Kluwer Academic Publishers, 2001, 514p.

ANEXO I – RELAÇÃO MAX-MIN TRANSITIVA

Conforme exposto em (KLIR e YUAN, 1995) uma relação de equivalência fuzzy é uma relação que é reflexiva, simétrica e *max-min* transitiva.

Uma relação fuzzy é *reflexiva* se e somente se:

$$R(x,x)=1 \quad \forall x \in X \quad (\text{AI.1})$$

Uma relação fuzzy é *simétrica* se e somente se:

$$R(x,y) = R(y,x) \quad \forall x e y \in X \quad (\text{AI.2})$$

Uma relação fuzzy é *transitiva* (ou mais especificamente *max-min transitiva*) se e somente se:

$$R(x,z) \geq \max_{y \in Y} \min [R(x,y), R(y,z)] \quad (\text{AI.3})$$

é satisfeito para cada par $(x,z) \in Z$.

Na expressão anterior, *max* é o operador de máximo (que obtém o valor máximo da relação) e *min* é o operador de mínimo (que obtém o valor mínimo da relação). A expressão que define a transitividade é resultado da composição de duas relações nebulosas e, nesse caso, essa composição é a *max-min*. Caso uma relação $R(x,x)$ não seja *max-min transitiva*, para torná-la *max-min transitiva* basta aplicar o simples algoritmo descrito a seguir:

1º Passo: $R' = R \cup (R \circ R)$.

2º Passo: Se $R' \neq R$, faça $R = R'$ e vá para o passo 1.

3º Passo: Pare quando $R' = R_T$.

Para um melhor entendimento, considera-se o seguinte exemplo retirado de (KLIR e YUAN, 1995):

Exemplo: Utilizando o algoritmo descrito anteriormente, pode-se determinar a relação *max-min transitiva* $R_T(x,x)$ de uma relação fuzzy $R(x,x)$ definida pela matriz de pertinências dada a seguir:

$$R = \begin{bmatrix} 0,7 & 0,5 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0,4 & 0 & 0 \\ 0 & 0 & 0,8 & 0 \end{bmatrix}$$

Aplicando o primeiro passo do algoritmo, obtém-se:

$$R \circ R = \begin{bmatrix} 0,7 & 0,5 & 0 & 0,5 \\ 0 & 0 & 0,8 & 0 \\ 0 & 0 & 0 & 0,4 \\ 0 & 0,4 & 0 & 0 \end{bmatrix} \quad R \cup (R \circ R) = \begin{bmatrix} 0,7 & 0,5 & 0,5 & 0,5 \\ 0 & 0 & 0,8 & 1 \\ 0 & 0,4 & 0 & 0,4 \\ 0 & 0,4 & 0,8 & 0 \end{bmatrix} = R'$$

Como $R' \neq R$, a matriz R' é tomada como a nova matriz R e o passo anterior é repetido:

$$R \circ R = \begin{bmatrix} 0,7 & 0,5 & 0,5 & 0,5 \\ 0 & 0,4 & 0,8 & 0,4 \\ 0 & 0,4 & 0,4 & 0,4 \\ 0 & 0,4 & 0,4 & 0,4 \end{bmatrix} \quad R \cup (R \circ R) = \begin{bmatrix} 0,7 & 0,5 & 0,5 & 0,5 \\ 0 & 0,4 & 0,8 & 1 \\ 0 & 0,4 & 0,4 & 0,4 \\ 0 & 0,4 & 0,8 & 0 \end{bmatrix} = R'$$

Como $R' \neq R$, a matriz R' é tomada como a nova matriz R e o passo anterior é repetido até que seja satisfeita a igualdade $R' = R$. Para este exemplo, a matriz *max-min transitiva* calculada a partir da matriz de pertinência dada, é a seguinte:

$$R_T = \begin{bmatrix} 0,7 & 0,5 & 0,5 & 0,5 \\ 0 & 0,4 & 0,8 & 1 \\ 0 & 0,4 & 0,4 & 0,4 \\ 0 & 0,4 & 0,8 & 0,4 \end{bmatrix}$$

ANEXO II – ALGORITMO DE RETROPROPAGAÇÃO (BACKPROPAGATION)

O Algoritmo *Backpropagation* é o algoritmo de treinamento de redes neurais multicamadas mais difundido, e se baseia no aprendizado supervisionado por correção de erros. Durante este treinamento, a rede opera numa sequência de dois passos onde, no primeiro, um padrão é apresentado à camada de entrada da rede e a resposta é propagada para as unidades da camada seguinte, até a camada de saída onde é obtida a resposta da rede e o erro é calculado. No segundo passo, o erro é propagado a partir da camada de saída até a camada de entrada. Desta forma, os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado.

Este processo gira em torno de um conjunto de amostras de treinamento $\{x(p), d(p)\}$ (para $n=1, \dots, P$), onde P é o número de amostras de treinamento contidas no conjunto de amostras, e pode ser resumido conforme apresentado em (HAYKIN, 2001), como segue:

1 – Inicialização: Caso não exista nenhuma informação prévia armazenada na rede, é necessário que os pesos sinápticos e bias (limiares) sejam iniciados aleatoriamente dentro de um intervalo pré-estabelecido. Um exemplo de um intervalo bastante utilizado é $[-1;1]$;

2 – Apresentação dos exemplos de treinamento: Após a inicialização, um padrão de treinamento $\{x(p), d(p)\}$, onde $x(p)$ é o vetor de entrada da rede e $d(p)$ é a resposta que se deseja obter para o estímulo $x(p)$, deve ser apresentado à rede;

3 – Propagação para Frente (*Feedforward*): Neste passo a saída da rede é calculada, propagando-se o sinal camada por camada. Assim, a saída do neurônio j na camada l , denotado por $y_j^{(l)}(p)$, pode ser expressa por:

$$y_j^{(l)}(p) = \varphi_j(v_j^{(l)}(p)) \quad (\text{AII.1})$$

onde

$$v_j^{(l)}(p) = \sum_{i=0}^m w_{ji}^{(l)}(p) y_i^{(l-1)}(p)$$

e m é o número total de entradas incluindo os limiares, $w_{ji}^{(l)}(p)$ é o peso que parte da unidade i da camada $l - 1$ para a unidade j da camada l , $y_i^{(l-1)}(p)$ é a saída do neurônio i na camada anterior $l - 1$, para o p -ésimo padrão de treinamento e $\phi_j(\cdot)$ é a função de ativação associada ao neurônio j . Para $i = 0$, temos $y_0^{(l-1)}(p) = +1$ e $w_{j0}^l = b_j^{(l)}(p)$ que o bias (limiar) aplicado ao neurônio j da camada l .

Se o neurônio j está na primeira camada intermediária, ou seja $l = 1$, então:

$$y_j^{(0)}(p) = x_j(p) \quad (\text{AII.2})$$

onde $x_j(p)$ é o j -ésimo elemento do vetor de entrada $x(p)$. Se o neurônio j está na camada de saída, isto é $l = L$ (onde L é o número de camadas da rede), então:

$$y_j^{(L)} = o_j(p) \quad (\text{AII.3})$$

onde $o_j(p)$ é o j -ésimo elemento do vetor de saída, obtido pela propagação do vetor de entrada $x(p)$ através da rede. Desta forma é possível calcular o sinal de erro da saída $e_j(p)$:

$$e_j(p) = d_j(p) - o_j(p) \quad (\text{AII.4})$$

onde $d_j(p)$ é o j -ésimo elemento do vetor de saídas desejadas $d(p)$.

4 – Propagação para trás (Backpropagation): Neste passo os gradientes locais δ da rede são calculados por:

$$\delta_j^l(p) = e_j(p) \phi_j' (v_j^{(l)}(p)) \quad (\text{AII.5})$$

para o neurônio j da camada de saída L , ou:

$$\delta_j^l(p) = \phi'(v_j^l(p)) \sum \delta_k^{(l+1)}(p) w_{kj}^{(l+1)}(p) \quad (\text{AII.6})$$

onde o apóstrofe em $\phi'(\cdot)$ representa a diferenciação em relação ao argumento. O ajuste dos pesos sinápticos da rede na camada l é feito de acordo com a regra delta generalizada, como seguinte:

$$w_{ji}^{(l)}(p)(k+1) = w_{ji}^{(l)}(p)(k) + \Delta w_{ji}^{(l)}(p)(k) \quad (\text{AII.7})$$

onde:

$$\Delta w_{ji}^{(l)}(p)(k) = \eta \delta_j^{(l)}(p)(k) y_i^{(l-1)}(p)(k) \quad (\text{AII.8})$$

η é o parâmetro *taxa de aprendizagem*, que apresenta a quantidade de modificação dos pesos na iteração k. Quanto menor for o parâmetro da taxa de aprendizagem, menores serão as variações dos pesos sinápticos da rede, de uma iteração para outra, e mais suave será a trajetória no espaço de pesos. Esta melhoria, entretanto, é obtida à custa de uma aprendizagem lenta.

5 – Iterações: As propagações para frente e para trás (passos 3 e 4 respectivamente) devem ser calculadas, apresentando-se novos padrões de treinamento para a rede, até que um critério de parada (tais como erro máximo admissível, número máximo de iterações, etc.) seja satisfeito.

Desta forma é realizado o treinamento da rede neural de multicamadas através do algoritmo *backpropagation*. Uma abordagem mais detalhada pode ser encontrada em (HAYKIN, 2001).