

## 2

# Técnicas Inteligentes aplicadas à Detecção e Diagnóstico de Falhas

Sistemas Inteligentes utilizam técnicas de modelagem ou aplicam diretamente métodos baseados em Inteligência Computacional. Eles surgiram para contornar as dificuldades encontradas pelos métodos tradicionais na modelagem e no tratamento de sistemas complexos.

O objetivo do diagnóstico de falhas é identificar falhas em um sistema defeituoso através da coleta e análise de dados sobre o estado do sistema, utilizando medições, testes e outras fontes de informação, como, por exemplo, sintomas de mau funcionamento. Geralmente, esta função é realizada por um ser humano bastante especializado, e é bastante importante em todos os estágios do ciclo de vida de um produto, principalmente durante a fabricação e a manutenção no campo. Nas últimas décadas, o diagnóstico automático de falhas tem sido um campo de pesquisa bastante ativo, mas a aceitação destas técnicas na indústria não tem sido muito grande (Fenton et al., 2001).

Neste capítulo, é apresentada a terminologia básica sobre diagnóstico de falhas, a descrição de algumas técnicas de diagnósticos tradicionais e uma revisão bibliográfica sucinta sobre a utilização de técnicas inteligentes neste campo.

### 2.1

#### O Processo de Diagnóstico

Em primeiro lugar, serão apresentadas algumas definições utilizadas na área de detecção e diagnóstico de falhas.

O termo *falha* se refere a uma diminuição total ou parcial da capacidade de desempenho de um componente, equipamento, processo ou sistema para atender uma certa função durante um determinado período de tempo.

Os sistemas que contém falhas comportam-se diferentemente do esperado. Chama-se *erro* (Venkatasubramanian et al., 2003) a discrepância observada entre uma variável medida e uma faixa aceitável para o valor esperado desta variável.

As falhas podem ser classificadas de diversas maneiras. Uma *falha paramétrica* (Venkatasubramanian et al., 2003) é o desvio de um parâmetro do sistema no tempo ou devido às condições ambientais que o levam a assumir um valor fora do estabelecido como *nominal*. Quando se observa um desvio grande e repentino do valor esperado do parâmetro tem-se uma *falha catastrófica* ou *estrutural*. Estas falhas se referem a mudanças na própria estrutura do sistema. São exemplos de falhas estruturais curto-circuito e circuito aberto em circuitos eletrônicos (Duhamel & Rault, 1979) e válvulas travadas e canos com vazamento em processos químicos (Venkatasubramanian et al., 2003).

A maneira pela qual as falhas ocorrem também pode ser classificada. Chama-se *falha simples* aquela que atinge somente um parâmetro ou componente por vez, enquanto as *falhas múltiplas* atingem vários parâmetros ou componentes simultaneamente (Duhamel & Rault, 1979).

Diz-se que duas *falhas* são *independentes* se entre elas não houver relação alguma de causa e efeito entre suas ocorrências, enquanto que são chamadas de *dependentes* se essa relação existir (Duhamel & Rault, 1979).

No que se refere a sua estabilidade no tempo, uma *falha* é dita *permanente* quando se dá de forma definitiva, sem a possibilidade de reparo, e é chamada de *intermitente*, esta quando ocorre de forma temporária (Duhamel & Rault, 1979). Alguns autores utilizam o termo *transiente* para classificar uma falha causada pela mudança temporária de algum fator ambiental e outros ainda também utilizam o termo *incipiente*, para falhas que vão gradativamente evoluindo para falhas mais graves (Manders et al, 2000).

Quanto à detectabilidade, as falhas podem ser classificadas em *mascaráveis*, *dominantes*, *equivalentes* ou *indistintas*, *não-observáveis* ou *indetectáveis*, *isoladas* ou *detectáveis*. As *falhas mascaráveis* são aquelas cujos efeitos compensam-se mutuamente tornando o comportamento do sistema livre de erros em determinadas situações. As falhas chamadas de *dominantes* são aquelas cuja evidência de seu efeito é muito maior do que os efeitos de todas as outras falhas que ocorram de forma simultânea. Falhas classificadas como *equivalentes* ou *indistintas* são aquelas cujos efeitos são iguais sob certas condições, e que, portanto, não podem ser atribuídas exclusivamente a esta ou aquela causa. As falhas *não observáveis* ou *indetectáveis* (Slamani & Kaminska, 1996) são aquelas para as quais não existem condições ou um conjunto de condições possível que

seja capaz de revelar sua existência. Finalmente, as falhas *detectáveis* são aquelas que podem ser reveladas inequivocamente sob circunstâncias apropriadas.

O objetivo do processo de detecção e diagnóstico de falhas é identificar a causa do mau funcionamento do sistema. Normalmente o processo de diagnóstico pode ser dividido em três etapas. A primeira é a *detecção de falha*, isto é, determinar se uma falha, de fato, ocorreu no sistema. A segunda etapa consiste em *isolar a falha*, isto é, determinar onde esta falha ocorreu, e, finalmente, a terceira consiste em determinar o *tipo e a extensão da falha* no sistema. Para que cada uma destas etapas possa ser cumprida é necessário que haja, em primeiro lugar, o processo de geração de informação, que algumas vezes também é chamado de geração de resíduos, onde informações acerca da natureza da falha devem ser adquiridas. Estas informações podem ser adquiridas por meio da observação de sintomas, da realização de medições e da utilização de testes de diagnósticos.

Uma vez que as informações referentes à falha foram coletadas, estas podem ser usadas para localizar um subconjunto de componentes ou módulos defeituosos. Se mais de um subconjunto ou módulo puder ser responsável pelo mau funcionamento, pode ser necessário obter informações adicionais através de novos testes ou de informação histórica. Se a discriminação não puder ser feita de forma inequívoca, então pode ser utilizada a experiência de um ser humano treinado empregando um processo de tentativa e erro.

## **2.2 Técnicas Tradicionais de Diagnóstico de Falhas**

As chamadas técnicas tradicionais de diagnóstico de falhas são aquelas que têm recebido uma maior aceitação da indústria, sobretudo as baseadas em sistemas de regras e em árvores de decisão (Fenton et al., 2001).

### **2.2.1 Sistemas baseados em Regras**

Sistemas baseados em regras representam a experiência de técnicos bem treinados na forma de regras do tipo “SE sintoma(s) ENTÃO falha(s)”. A representação do conhecimento para um problema em particular pode conter um número demasiadamente grande de regras. A inferência nestes sistemas consiste

em obter informações sobre o problema e utilizar as regras que concordam com esta informação. Este tipo de sistema tem aplicações em diversas áreas como telefonia, aviação, computadores, etc (Rowland, 1993).

As principais desvantagens desse tipo de sistema são: a dificuldade de adquirir conhecimento, uma vez que um especialista em reparar um determinado sistema deve determinar o conjunto de regras suficiente para que o sistema seja diagnosticado; a grande dependência das regras com o sistema em particular, pois uma nova base de regras deve ser gerada para cada sistema, e, por fim, sua habilidade para lidar com falhas não previstas é questionável.

### 2.2.2 Árvores de Decisão de Falhas

É o método mais comumente utilizado para documentar procedimentos de diagnósticos de falhas. Uma árvore de decisão de falhas utiliza sintomas ou resultados de testes para decidir que ramo da árvore deve ser seguido. Cada ramo da árvore é composto de ações, novos testes e recomendações de reparo. A Figura 2.1 mostra um exemplo.

A geração automática de árvores de decisão para sistemas complexos tem sido um campo bastante ativo, como pode ser visto em (Juricic, 1997).

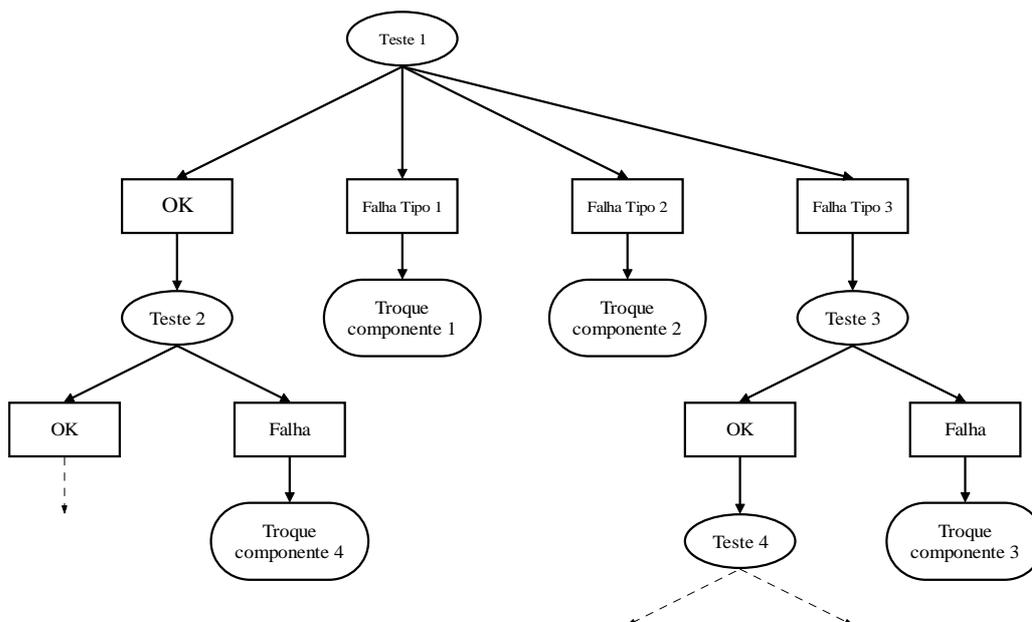


Figura 2.1 – Exemplo de uma árvore de decisão.

A principal vantagem da árvore de decisão é a sua simplicidade. Entretanto, para sistemas complexos, esta árvore pode ser muito grande. Além disso, árvores de decisão são bastante dependentes do sistema.

## 2.3

### Abordagens baseadas em modelos (Model Based Reasoning)

Os modelos baseados na estrutura, no comportamento e na funcionalidade têm sido mais pesquisados porque é possível incorporar alguma hierarquia na representação do sistema, isto é, modelar um sistema a partir dos modelos dos subsistemas que o constituem.

O GDE (*General Diagnostic Engine*) (Kleer, 1987) infere o comportamento de um dispositivo a partir de sua estrutura e funcionalidade através do ATMS (*Assumption Based Truth Maintenance System*). Utilizando propagação de restrições, ele é capaz de identificar diagnósticos mínimos, mas considera todos os “supersets” de um diagnóstico mínimo como um possível diagnóstico. Entretanto, se um diagnóstico mínimo for descartado na fase de discriminação, todos os diagnósticos derivados dele também o são. O GDE utiliza medições adicionais para diferenciar entre possíveis candidatos. A seqüência na qual estas medições devem ser feitas é determinada por um sistema de busca guiado pela probabilidade de falha de cada componente.

O GDE apresenta as seguintes desvantagens: a incapacidade de lidar com um grande número de componentes, a não utilização de lógica temporal e a incapacidade de inferir sob incertezas. Apesar destas deficiências o GDE serviu de base para vários outros sistemas como, por exemplo, o XDE (Fenton et al., 2001).

Embora modelos baseados em comportamento e estrutura sejam uma boa solução, em diversos problemas de diagnóstico existem algumas limitações importantes: são sistemas computacionalmente intensos, sobretudo se os modelos utilizados forem complexos, é necessário estabelecer uma relação de compromisso entre a complexidade do modelo e a capacidade de produzir diagnósticos precisos; a geração de modelos é demorada e cara, e, portanto, métodos para geração (identificação) automática de modelos são necessários, sobretudo em sistemas mais complexos.

## 2.4 Case Based Reasoning (CBR)

CBR é uma metodologia para modelar o raciocínio humano e construir sistemas especialistas (Bergmann, 1998). Ela consiste em armazenar experiências de soluções (diagnósticos) anteriores, que são chamadas de casos, e utilizá-las na solução de novos problemas. Quando um novo problema é proposto, o CBR recupera um ou mais casos que sejam semelhantes ao problema proposto, e a solução é obtida através da adaptação, revisão e combinação dos casos recuperados. Dependendo do grau de sucesso (ou falha) da solução obtida, este novo caso pode ser armazenado para uso futuro.

A solução de um problema usando CBR geralmente pode ser dividida em cinco passos:

- Representação dos casos
- Recuperação de um caso da base de casos
- Utilização do caso recuperado
- Verificação da solução
- Armazenamento do novo caso (aprendizado)

A Figura 2.2 mostra o ciclo de funcionamento de um sistema CBR.

A representação dos casos consiste em determinar:

- O que deve ser armazenado, isto é, que características são relevantes para o diagnóstico em questão. Por exemplo, no caso do diagnóstico de falhas, um caso deve conter a descrição dos sintomas, a descrição da falha e a causa e a descrição da estratégia de reparo.
- Uma estrutura apropriada para representar o conteúdo de um caso. Geralmente, os casos estão armazenados em listas, entretanto também são utilizadas representações como objetos, grafos ou através da lógica de predicados.
- Um esquema de indexação para permitir a fácil recuperação.

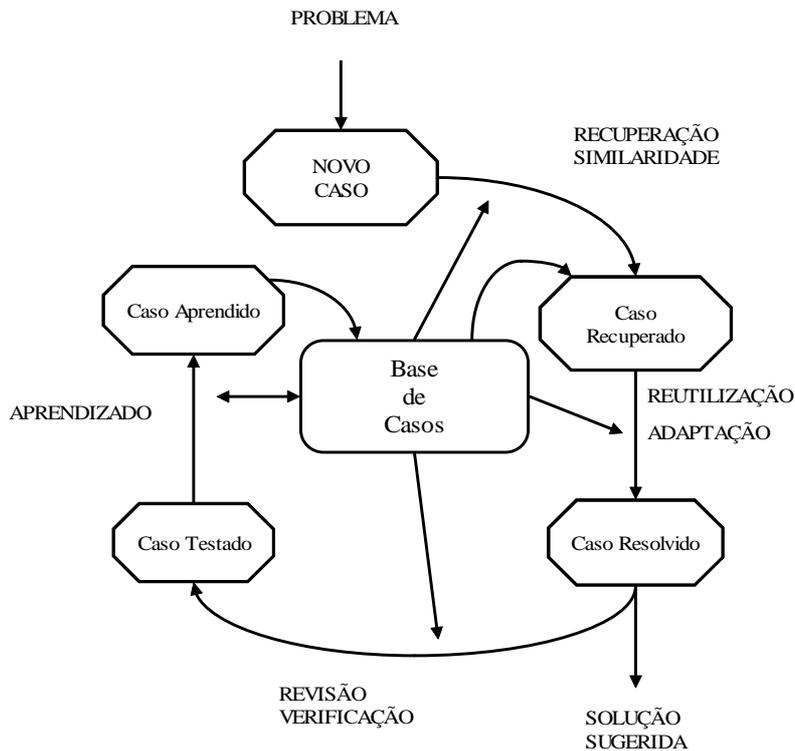


Figura 2.2 – Ciclo de Funcionamento de um sistema CBR.

A recuperação dos casos consiste em determinar que características são importantes para o problema em questão, e, a partir destas, determinar quais são os casos similares. A similaridade entre os casos é um conceito fundamental no CBR e a quantificação da similaridade representa uma questão importante a ser resolvida em um sistema CBR. Os casos contêm medidas de grandezas do sistema (variáveis) que está sendo monitorado (sintomas) e a descrição da(s) falha(s) responsáveis pelo mau funcionamento. O cálculo da similaridade é feito comparando-se os valores das medidas envolvidas e atribuindo-se, a esta comparação, um grau entre 0 e 1. É designado um grau maior para os valores mais próximos. Com os valores de similaridade calculados para cada variável, estes são combinados em um valor único de similaridade para o caso. Esta combinação, tipicamente, é feita através de uma soma ponderada das similaridades de cada variável, sendo dado um peso maior às variáveis consideradas mais importantes.

Um aspecto prático importante no desempenho do sistema é que a maneira pela qual os casos estão armazenados deve permitir a recuperação dos casos similares de modo eficiente.

A partir do momento em que casos similares foram recuperados, é iniciado o processo de utilização do caso recuperado. Este processo pode envolver: a utilização da solução do caso recuperado sem alterações; a alteração da solução fornecida por intervenção humana ou alterações feitas de modo automático.

A verificação da solução obtida pode ser feita utilizando-se simulações ou empregando esta solução no mundo real.

## **2.5**

### **Abordagens utilizando Lógica Fuzzy**

A Lógica Fuzzy (Zadeh, 1965) fornece um meio alternativo de representar a imprecisão e a falta de informação associadas à descrição das características de um determinado elemento de um problema em particular. Ela utiliza termos lingüísticos, que são inerentemente imprecisos, à semelhança daqueles da linguagem natural, para representar as características de um elemento do problema. A potencialidade da Lógica Fuzzy consiste na utilização de variáveis lingüísticas, no lugar de variáveis quantitativas, na representação de conceitos imprecisos.

A incorporação da Lógica Fuzzy em modelos computacionais é especialmente útil em dois tipos de situações: (i) no caso de sistemas complexos onde a compreensão do processo em questão está praticamente limitada ao julgamento pessoal e (ii) em processos onde o raciocínio, a percepção e o processo de decisão humano estão intrinsecamente envolvidos.

Estas características fazem com que a Lógica Fuzzy seja bastante adequada para o diagnóstico de falhas. Tipicamente ela é utilizada:

- Na geração de um modelo do sistema
- Na análise de resíduos

#### **2.5.1**

##### **Geração de modelos**

Um sistema fuzzy pode ser usado para modelar um componente ou um módulo de um sistema maior. Em (Attarha, 2000) os sistemas fuzzy são utilizados para modelar as portas lógicas. Simulações dos circuitos das portas lógicas no SPICE são utilizadas para obter os dados numéricos, que por sua vez são

utilizados para a obtenção dos modelos. Então, estes modelos são utilizados em um simulador voltado para a detecção de falhas. Neste simulador pode-se observar com grande precisão como os níveis de tensão se propagam pelo circuito, sendo possível determinar, por exemplo, se um circuito contém um curto entre dois nós, o que causaria níveis lógicos anormais. A Figura 2.3 mostra o algoritmo empregado.

Primeiro, um vetor de testes  $V$  é gerado e apresentado tanto ao circuito lógico sem falhas, que será simulado por um simulador lógico, quanto ao modelo fuzzy do circuito no qual foi introduzida uma ponte resistiva entre dois nós. Se as saídas são diferentes, então a falha pode ser detectada pelo vetor de teste  $V$ .

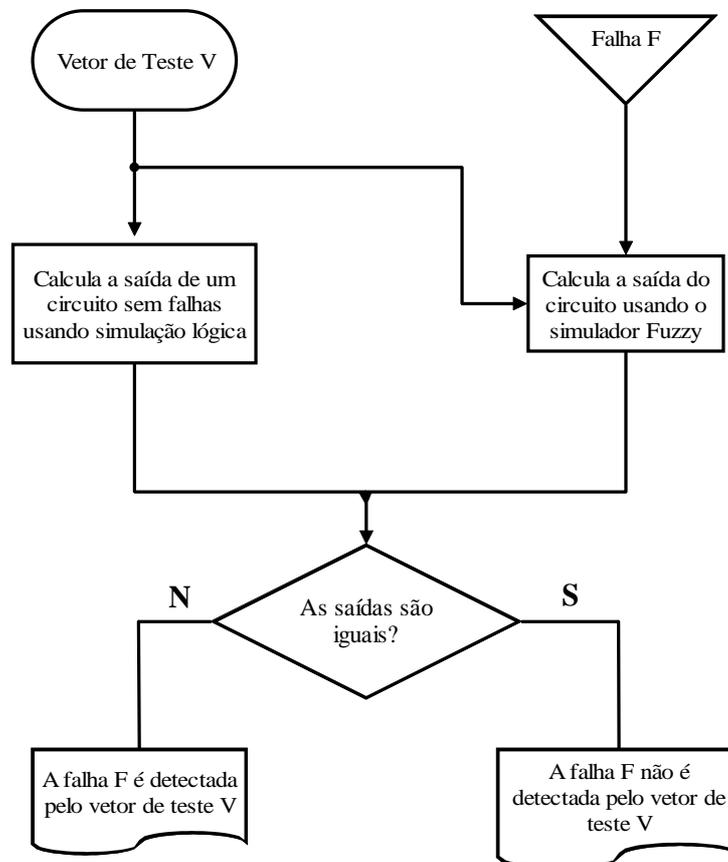


Figura 2.3 – Algoritmo do simulador Fuzzy.

### 2.5.2 Análise de resíduos

A utilização mais comum da Lógica Fuzzy na área do diagnóstico de falhas tem sido na avaliação de resíduos (Dalton, 1999). A avaliação de resíduos normalmente necessita de algum tipo de inferência, onde a conclusão de que uma falha ocorreu no sistema pode se basear não só na informação contida nos

resíduos, mas também em informações que são difíceis de codificar em modelos matemáticos tradicionais, tais como registros de manutenção ou a experiência do operador.

Entre algumas das abordagens mais utilizadas citam-se: a utilização de limiares adaptativos fuzzy, a clusterização fuzzy e o emprego de regras fuzzy.

Os limiares adaptativos fuzzy são capazes de superar as desvantagens de utilizar limiares fixos em variáveis medidas ou em resíduos. Um sistema fuzzy pode gerar limiares adaptativos, que variem de acordo com as condições de operação da planta observada. A desvantagem deste método é que ele é aplicável somente para a indicação da existência de falhas. Uma outra etapa de processamento é necessária para isolar estas falhas.

A idéia central presente no fuzzy *clustering* é o reconhecimento de padrões. Dados são utilizados *off line* para determinar os centros dos clusters que representam todas as falhas de interesse. Durante a operação do sistema, determina-se o grau de pertinência dos dados coletados a cada um dos clusters pré-definidos, sendo o dado classificado naquele cluster ao qual ele tem a maior pertinência. A Figura 2.4 mostra este processo.

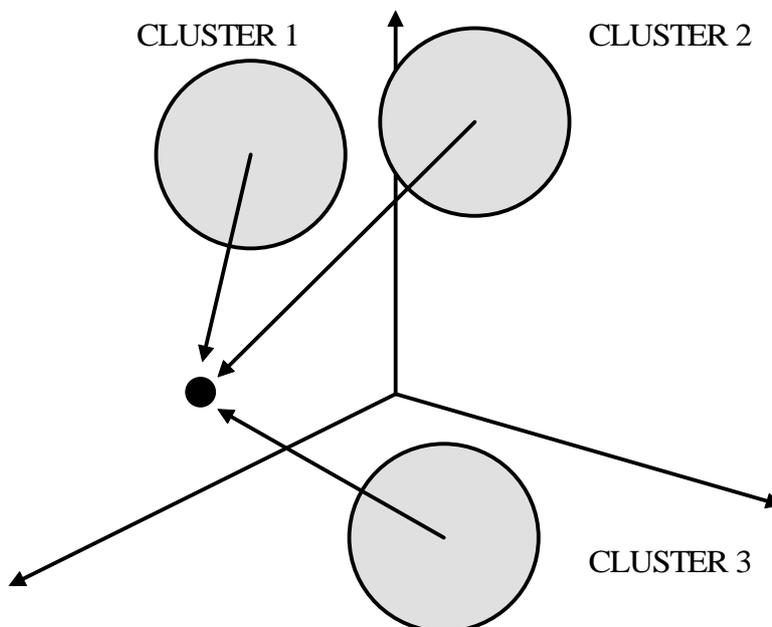


Figura 2.4 – Localização do ponto em relação aos clusters.

O método de *fuzzy clustering* é útil quando existem muitos resíduos, ou quando não há conhecimento sobre o sistema a ser diagnosticado. Dentre os métodos de *fuzzy clustering* mais usados podem ser citados o Fuzzy C-means e o Subtractive.

A maior vantagem da utilização de regras fuzzy é possibilitar a inclusão de informação heurística no esquema de análise. Regras fuzzy tendem a facilitar o entendimento e funcionam de modo semelhante ao utilizado por seres humanos para resolver problemas.

A análise de resíduos empregando regras fuzzy utiliza a idéia de que cada resíduo pode ser zero, negativo ou positivo com um certo grau de pertinência, e que um sistema de inferência pode ser usado para determinar o grau de presença de uma determinada falha no sistema ou para determinar o grau de gravidade de uma falha presente no sistema. As regras fuzzy indicam as condições nas quais falhas existem e também indicam as condições nas quais não há falhas. Por exemplo:

```
IF resíduo1 é POSITIVO AND resíduo2 é NEGATIVO
                                     THEN falha1 é PRESENTE
IF resíduo1 é ZERO AND resíduo2 é ZERO
                                     THEN falha1 é AUSENTE
```

Observa-se que neste tipo de sistema o efeito da falha nos resíduos deve ser conhecido.

Também é possível determinar a base de regras de forma automática a partir de dados do sistema em consideração, mas esta abordagem tem as seguintes desvantagens: dados referentes a todas as falhas de interesse, e em todos os pontos de operação, devem estar disponíveis; algoritmos de busca de regras podem ficar presos em mínimos locais e a base encontrada pode não representar corretamente o sistema, e, se estas regras não refletirem a experiência do operador, elas podem não ser validadas.

Uma alternativa que pode ser utilizada é iniciar o processo de derivação de regras a partir de uma base inicial elaborada pelo operador.

Um algoritmo que usa esta abordagem é descrito a seguir:

1. Determine o comportamento dos resíduos em relação a cada falha
2. Derive regras que expressem este comportamento e adicione-as à base existente.

3. Verifique se todas as falhas podem ser isoladas. Caso afirmativo, vá para 4. Se não:
  - Adicione mais funções de pertinência ou
  - Adicione outro resíduo ao sistema e volte para 1.
4. Uma vez que a base de regras está completa, os parâmetros da função de pertinência podem ser encontrados.
5. A base de regras resultante pode ser testada. Se o resultado for satisfatório, o processo está completo. Se não retorne a 3.

Existem diversos métodos que podem ser usados para sintonizar os parâmetros do sistema fuzzy, incluindo Fuzzy Clustering, Redes Neurais e Algoritmos Genéticos (Amaral, 2002)(Nauck, 1994).

Um exemplo da abordagem apresentada anteriormente pode ser vista em (Abdulghafour, 1996). Neste artigo, um sistema fuzzy para diagnóstico de circuitos é gerado, tendo como entradas medições feitas em nós dos circuitos e como saídas os valores dos elementos. Sendo assim, o valor do componente que é obtido pelo sistema fuzzy indica se o circuito apresenta ou não uma falha.

## 2.6

### Abordagens utilizando Redes Neurais

As Redes Neurais tornaram-se um importante paradigma e são inspiradas no funcionamento do cérebro humano. Elas vêm sendo desenvolvidas para resolver problemas de processamento de padrões que seriam intratáveis ou extremamente custosos computacionalmente quando implementados via computação tradicional. A descrição apresentada a seguir é baseada em (Barbosa et al., 2000).

Em analogia com o cérebro humano, as redes neurais são massivamente paralelas e se baseiam em unidades processadoras simples (neurônios) densamente interconectadas. Estes padrões de interconexão podem variar desde redes *feed-forward* de uma única camada, como as primeiras redes perceptron, até topologias mais complexas, formadas por várias camadas com retropropagação de erros como no caso do modelo *backpropagation*, ou mesmo redes recorrentes que apresentam um comportamento dinâmico, como as redes de Hopfield.

Uma rede neural é representada por interconexões ponderadas (pesos) entre os neurônios. Estes pesos são parâmetros que definem a função não-linear que é

implementada pela rede. O processo de determinação de tais parâmetros é chamado de treinamento ou aprendizado, e se baseia na apresentação de muitos padrões de treinamento. As redes neurais são inerentemente adaptativas, ajustando-se à natureza imprecisa, ambígua e incompleta de dados reais. Os procedimentos de aprendizado podem ser supervisionados ou não-supervisionados. No treinamento supervisionado, um padrão de treinamento, composto por um padrão de entrada e a saída desejada, é apresentado à rede, que geralmente ajusta os valores dos pesos com base na diferença entre a saída desejada e a saída da rede. Nos procedimentos não-supervisionados, a rede classifica padrões de entrada sem a necessidade de conhecer a saída desejada.

As aplicações de redes neurais ao diagnóstico de falhas podem ser separadas em duas grandes áreas: classificação de padrões de falhas e identificação de parâmetros de um sistema.

### **2.6.1 Classificação de padrões**

Nesta abordagem, o problema de diagnóstico de falhas é visto como um problema de classificação de padrões. A partir de um dicionário de falhas pré-definido, é possível treinar uma rede para classificar um vetor de resíduos em classes de falhas.

Considerando-se especificamente aplicações em circuitos eletrônicos, em geral, estas classes de falhas são obtidas através de simulações dos circuitos supondo a presença de uma única falha. Os tipos de falhas mencionados são falhas catastróficas (curto-circuito ou circuito-aberto) e variações anormais nos valores dos componentes.

Em (Garcia, 2000), o diagnóstico de falhas de circuitos lineares é obtido através do treinamento de uma rede para classificar um vetor de medidas obtidas no circuito em classes de falhas pré-determinadas. A rede é treinada usando simulações de circuitos defeituosos. O pré-processamento das entradas é bastante elementar (apenas normalização), indicando que este tipo de rede conseguirá bons resultados apenas para circuitos pequenos. Se o circuito aumentar, haverá uma explosão de dimensionalidade.

Em (Hayashi, 2002), o diagnóstico de máquinas industriais é implementado classificando-se o espectro de frequência do som das máquinas em condição normal e anormal de operação.

Em (Arminian & Arminian, 2002), variações no valor de componentes em circuitos eletrônicos são tomadas como falhas do circuito (classes do problema). Os padrões de entrada são medidas do circuito pré-processadas com *wavelets*, com os coeficientes mais importantes escolhidos através de PCA (*Principal Components Analysis*). Neste caso, a rede faz a classificação indicando a que classe de falha um vetor de entrada pertence.

Em (Wang et al., 2004), o diagnóstico de falhas é feito em um Filtro Sallen Key utilizando redes RBF e Back Propagation para determinar a classe de falha do circuito. O vetor de entrada é composto das amplitudes medidas no nó de saída em diferentes frequências. A porcentagem de acertos fica em uma faixa de 88 a 100%.

Em (Grzechca & Rutkowski, 2002) dois Filtros Sallen Key em cascata são diagnosticados a partir de medições do atraso de propagação, do tempo de subida e do overshoot em diversos nós do circuito. A detecção é feita em duas fases. Na primeira usa-se uma rede neural para classificar o circuito em Normal/Anormal. Neste caso as taxas de acerto ficam em uma faixa de 91,1 a 96,41%. Em uma segunda etapa, é feita uma classificação para determinar a classe da falha, isto é, determinar qual dos componentes apresenta problemas. Neste caso a taxa de acerto é maior do que 80% para a maioria das classes de falha, mas existem casos onde a taxa de acerto é menor do que 50%.

Em (Yi-Gang et al., 2002), é proposto um método para diagnosticar circuitos analógicos grandes. Neste método, o circuito é dividido em pequenos blocos que por sua vez são diagnosticados. As falhas consideradas são do tipo catastrófico e as medidas são os valores CC em pontos dos circuitos. Os exemplos utilizados são uma rede resistiva e um amplificador operacional. O método é avaliado apenas para falhas em alguns componentes. As redes utilizadas são do tipo *Multi-Layer Perceptron* (MLP) treinadas por Back Propagation.

Em (Mohammadi et al., 2002) utilizam-se redes RBF e MLP para diagnosticar uma rede resistiva e um amplificador com FET de um estágio. As falhas consideradas são do tipo catastrófico em alguns componentes e as medidas

são os valores CC em pontos dos circuitos. Os resultados são apresentados para algumas falhas.

Em (Amaral, 2003), uma série de experimentos em chapas de aço contendo diversos tipos de defeito, realizados em um simulador de PIG (*Pipeline Inspection Gizmo*) magnético construído na PUC-Rio, proporcionou uma excelente base de dados de sinais magnéticos, a qual foi utilizada para treinamento de um sistema integrado de redes neurais artificiais para a análise não-destrutiva de estruturas de aço. Inicialmente, uma rede PNN determina em qual lado da chapa de aço se localiza o defeito. Em seguida, uma rede neural de classificação divide os defeitos de acordo com sua profundidade, e, finalmente, redes neurais MLP de caracterização fornecem uma estimativa numérica da profundidade dos defeitos. Os resultados obtidos são satisfatórios, com erros de classificação no caso da determinação do lado do defeito em torno de 15%, e abaixo de 5% no caso da classificação de profundidade. Já a rede de caracterização forneceu estimativas da profundidade dos defeitos com erros médios menores do que 1%.

### 2.6.2 Identificação de parâmetros

Neste tipo de abordagem uma rede neural ou neuro-fuzzy pode ser usada para identificar os parâmetros de um sistema dinâmico e utilizá-los em um modelo do sistema que está sendo diagnosticado ou como resíduos, que, por sua vez, podem ser classificados de acordo com um conjunto de falhas pré-definido.

Em (Materka, 1996), utiliza-se um sistema de redes neurais para obter uma modelagem paramétrica de um circuito elétrico. A vantagem da utilização de uma rede neural é a sua capacidade de, uma vez treinada, reconhecer os parâmetros do sistema rapidamente, permitindo a identificação *on-line*. A rede faz um mapeamento entre o espaço das medições e o espaço dos parâmetros. O sistema utilizado é composto de um classificador seguido de aproximadores de função. O classificador se encarrega de classificar o vetor de medições em uma das regiões do espaço de parâmetros; a seguir uma das redes aproximadoras de função otimizada para aquela região encarrega-se de obter os parâmetros corretos.

Em (Caminhas, 2001), os parâmetros de diversos sistemas dinâmicos são identificados por uma rede neuro-fuzzy. Um conjunto de pesos  $W_0$  é obtido no

treinamento *off line* da rede com um sistema sem falhas. Um outro conjunto de pesos  $W$  é obtido através do treinamento *on line*. Os resíduos são gerados a partir da diferença entre  $W$  e  $W_0$ . Estes resíduos são então classificados por uma outra rede neuro-fuzzy de acordo com um conjunto de falhas pré-definido.