



Pontifícia Universidade Católica de Minas Gerais

Programa de Pós Graduação em Engenharia Elétrica

**Detecção e Isolamento de Falhas em Motores de Indução
Utilizando Técnicas de Inteligência Computacional**

João Leonardo Ribeiro Neto

DISSERTAÇÃO DE MESTRADO PPGEE-XX / 2006

ORIENTADOR : PROF. DR. PYRAMO PIRES DA COSTA JÚNIOR

OUTUBRO / 2006



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

JOÃO LEONARDO RIBEIRO NETO

Detecção e Isolamento de Falhas em Motores de Indução Utilizando Técnicas de Inteligência Computacional

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica de Minas Gerais como requisito parcial para obtenção do grau de Mestre em Engenharia Elétrica, elaborada sob a orientação do Prof. Dr. Pyramo Pires da Costa Júnior.

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE MINAS GERAIS

BELO HORIZONTE

2006

FICHA CATALOGRÁFICA

Elaborada pela Biblioteca da Pontifícia Universidade Católica de Minas Gerais

R484d	<p>Ribeiro Neto, João Leonardo Detecção e isolamento de faltas em motores de indução utilizando técnicas de inteligência computacional / João Leonardo Ribeiro Neto - Belo Horizonte, 2006. 121f. Il.</p> <p>Orientador: Prof. Dr. Pyramo Pires da Costa Júnior Dissertação (Mestrado) – Pontifícia Universidade Católica de Minas Gerais, Programa de Pós-Graduação em Engenharia Elétrica Bibliografia.</p> <p>1. Motores elétricos de indução. 2. Inteligência artificial. 3. Redes neurais (Computação). 4. Lógica difusa. I. Costa Junior, Pyramo Pires da. II. Pontifícia Universidade Católica de Minas Gerais. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.</p> <p>CDU: 621.313.33</p>
-------	--

Bibliotecária : Mônica dos Santos Fernandes Rodrigues – CRB 6/1809

Aos meus pais

*J*arbas (in memorian) e *F*rancisca

À companheira de todas as horas

*M*atilde

Aos meus filhos

*G*uilherme e *D*anilo

Agradecimentos

Ao professor Pyramo Pires Costa Junior, pela dedicação, paciência e competência na orientação dos trabalhos.

Aos professores do Programa, pela contribuição fundamental para a condução da pesquisa.

Ao amigo Michel Bortolini Hell, pelo apoio e contribuição à conclusão deste trabalho.

Aos funcionários do Programa, pela presteza e dedicação.

Em especial a Matilde, Guilherme e Danilo, pela paciência e apoio em todos os momentos.

Conteúdo

Resumo	ix
Notações e Definições	x
1 Considerações Iniciais	12
1.1 Introdução	12
1.2 Relevância	16
1.3 Escopo	16
1.4 Objetivo	17
1.5 Metodologia	17
1.6 Estrutura do trabalho	17
2 Revisão bibliográfica	19
2.1 Detecção e Isolamento de Falhas Baseado em Modelo	19
2.1.1 Métodos para geração de resíduos	22
2.1.2 Técnicas para avaliação de resíduos	28
2.1.3 Robustez na detecção e isolamento de falhas em sistemas baseados em modelo	30
2.2 Aplicação das técnicas baseada em modelos qualitativos no diagnóstico de falhas	34
2.2.1 A Lógica Fuzzy em sistemas de diagnóstico de falhas	36
2.2.2 As RNAs em sistemas de diagnóstico de falhas	38
2.2.3 Abordagens híbridas em diagnóstico de falhas	41
3 Monitoramento de falhas em máquinas elétricas	44
3.1 Considerações gerais	44
3.1.1 A natureza das falhas em máquinas elétricas	45

3.2	Tipos de faltas e técnicas de monitoramento e identificação	48
3.2.1	Faltas no rolamento	48
3.2.2	Faltas na barra do rotor	50
3.2.3	Faltas relacionadas à excentricidade	51
3.2.4	Faltas no estator	52
3.3	Aplicações de técnicas de Inteligência Computacional em sistema de monitoramento de máquinas	55
3.3.1	Redes Neurais	55
3.3.2	Sistemas baseados em Lógica Fuzzy e Sistemas Neurofuzzy	58
3.4	Considerações finais	59
4	Resultados experimentais	62
4.1	Considerações iniciais	62
4.1.1	Variáveis observadas	62
4.2	Sistema de Diagnóstico para Condições Ideais	66
4.2.1	Analisador de faltas baseado em uma rede neural MLP	67
4.2.2	Analisador de faltas baseado em um sistema de inferência fuzzy	68
4.2.3	Analisador de faltas baseado em agrupamento fuzzy	69
4.3	Sistema de diagnóstico considerando distúrbios externos	71
4.4	Sistema de diagnóstico para condições reais	73
4.4.1	Observador Neural - Rede de Elman	74
4.4.2	Observador Neurofuzzy - Rede Neurofuzzy Recorrente	76
4.5	Quadro geral comparativo	78
5	Análise dos resultados de simulação	79
5.1	Considerações finais	79
5.2	Contribuições futuras	81
A	Modelo analítico do motor de indução	82
A.1	Motor de indução sem falta	82
A.2	Motor de indução com falta	84

B Modelos de analisadores de faltas utilizados	87
B.1 Rede neural MLP	87
B.1.1 O Algoritmo <i>Backpropagation</i>	88
B.2 Sistema de inferência fuzzy (FIS)	93
B.2.1 Passo 1 - Divisão dos espaços de entrada e saída em regiões fuzzy	93
B.2.2 Passo 2 - Geração das regras fuzzy a partir dos pares de dados	94
B.2.3 Passo 3 - Associação de um grau para cada regra	95
B.3 Agrupamento fuzzy (FCM)	96
C Modelos de observadores utilizados	98
C.1 Modelo qualitativo utilizando RNA	98
C.2 Redes Neurofuzzy Recorrentes - abordagem híbrida	100
C.2.1 Estrutura da Rede Neurofuzzy Recorrente	101
Bibliografia	108
Abstract	118

Lista de Figuras

1.1	Uma possível classificação dos métodos de detecção e isolamento de faltas	14
2.1	Sistema em malha aberta com falta	20
2.2	Estrutura conceitual de diagnóstico de faltas baseada em modelos	22
2.3	Estrutura completa de um gerador de resíduos	23
2.4	Gerador de resíduo baseado em observador	25
2.5	Geração de resíduos via identificação de parâmetros	26
2.6	Esquema dedicado (Conjunto estruturado de resíduos)	29
2.7	Esquema de observador generalizado	29
2.8	Isolamento de falta com conjunto residual direcional	30
2.9	Esquema geral de diagnóstico de faltas utilizando RNAs	41
2.10	Arquiteturas de RNAs para Diagnóstico de Faltas em Sistemas Dinâmicos	42
2.11	Estrutura de treinamento NARX	43
2.12	Conceito básico de uma rede neurofuzzy	43
3.1	Origem de faltas em máquinas de indução	48
3.2	Faltas mais comuns em máquinas de indução e suas causas	49
4.1	Variáveis de Entrada	63
4.2	Distúrbios externos	64
4.3	Sinal de corrente para condições reais	65
4.4	Esquema do sistema de diagnóstico em condições ideais	66
4.5	Analisador de faltas baseado em rede MLP	67
4.6	Analisador de faltas baseado em sistema de inferência FIS	68
4.7	Analisador de Faltas Baseado em Agrupamento Fuzzy	69
4.8	Esquema do sistema de diagnóstico considerando distúrbios externos	71

4.9	Esquema do sistema de diagnóstico para condições reais - observador neural . . .	74
4.10	Observador neural de máquina de indução	75
4.11	Esquema do sistema de diagnóstico para condições reais - observador neurofuzzy	76
4.12	Observador neurofuzzy da máquina de indução	77
A.1	Representação de curto circuito na fase A em um motor de indução	84
A.2	Protótipo de laboratório utilizado no experimento	86
B.1	Diagrama ilustrativo de uma Rede Neural com duas camadas intermediárias . . .	88
B.2	Fluxo de sinal ilustrando o efeito da constante de momento	91
B.3	Exemplo de Função de Ativação	92
B.4	Problema de Mínimos Locais	93
B.5	Divisão dos espaços de entrada e saída em regiões fuzzy e as correspondentes funções de pertinência. $(a)m(x_1), (b)m(x_2)$ e $(c)m(y)$	94
C.1	Estrutura da rede Elman	99
C.2	Rede Neural Recorrente	101
C.3	Relação da camada intermediária com os nós de entradas	102
C.4	Rede neurofuzzy recorrente	102
C.5	Neurônio lógico recorrente	103

Lista de Tabelas

4.1	Resultados obtidos sem observador para condições ideais	70
4.2	Resultados obtidos sem observador - com distúrbios externos e sem ruídos	70
4.3	Resultados obtidos com observador - com distúrbios externos e sem ruídos . . .	72
4.4	Resultados obtidos com observador analítico e para condições reais	73
4.5	Resultados obtidos com observador neural de Elman para condições reais	75
4.6	Resultados obtidos com observador neurofuzzy para condição reais	77
4.7	Resultado geral comparativo	78

Resumo

Os objetivos deste trabalho são, propor e discutir um sistema de detecção e isolamento de faltas de curto circuito entre espiras do enrolamento do estator de máquinas de indução, utilizando técnicas de Inteligência Computacional.

As características monitoradas para detectar e isolar faltas no estator foram o fator de potência e o valor eficaz da corrente em cada uma das fases que, por sua vez, foram obtidas a partir da saída de um simulador de uma máquina de indução, considerando o comportamento da máquina em diversas situações, com e sem faltas. Posteriormente, um protótipo de laboratório validou os resultados obtidos pela simulação.

Em relação à estrutura do sistema de diagnóstico, foram abordadas várias combinações de técnicas utilizando Redes Neurais Artificiais, Lógica Fuzzy e estruturas Neurofuzzy para implementar geradores de resíduos e analisadores de faltas que melhor respondessem às questões relativas à robustez e à capacidade de diagnosticar faltas incipientes. Considerou-se, também, um gerador de resíduos baseado em modelo analítico, como uma das possíveis ferramentas para compor o sistema de diagnóstico proposto.

Os resultados apresentados com a utilização de observadores baseados em Redes Neurais e Neurofuzzy, em conjunto com analisadores de resíduos neurais e estruturas fuzzy, apresentaram-se bastante promissores, permitindo comprovar a eficácia deste tipo de abordagem em sistema de diagnóstico de faltas em motores de indução ou, até mesmo, na utilização dessas técnicas em monitoramento de máquinas elétricas em geral.

Notações e Definições

- I_A - Corrente na fase A
- I_B - Corrente na fase B
- I_C - Corrente na fase C
- V_{AB} - Tensão entre as fases A e B
- V_{BC} - Tensão entre as fases B e C
- V_{CA} - Tensão entre as fases C e A
- θ_A - Defasagem entre a corrente I_A e a tensão V_{AB}
- θ_B - Defasagem entre a corrente I_B e a tensão V_{BC}
- θ_C - Defasagem entre a corrente I_C e a tensão V_{CA}
- Z^{-1} - Operador de atraso unitário
- ANFIS - *Adaptative-Network-Based Fuzzy Inference System*
- DOS - *Dedicated Observer Scheme*
- DTC - *Direct Torque Control*
- EBP - *Error Back Propagation*
- EPRI - *Electric Power Research Institute*
- EPVA - *Extented Park's Vector Approach*
- FALCON - *Fuzzy Learning Control/Decision Network*

- FCM - *Fuzzy C-Means*
- FDI - *Fault Detection and Isolation*
- FIS - *Fuzzy Inference System*
- GOS - *Generalized Observer Scheme*
- IEEE - *Institute of Electrical and Electronics Engineers*
- LMIs - *Linear Matrix Inequalities*
- LVQ - *Learning Vector Quantization*
- MCSA - *Machine Current Signature Analysis*
- MLP - *Multilayer Preceptron*
- NARX - *Nonlinear Auto Regressive eXogeneous*
- PDC - *Parallel Distributed Compensation*
- RMS - *Root Mean Square*
- RNA(s) - *Rede(s) Neural(is) Artificial(is)*
- TS - *Takagi-Sugeno*
- VLSI - *Very Large Scale Integration*

Capítulo 1

Considerações Iniciais

1.1 Introdução

Nas últimas duas décadas tem havido um crescimento significativo das investigações no campo de monitoramento e diagnóstico de faltas, em decorrência da crescente complexidade dos sistemas de controle automático de processos e da necessidade de segurança em áreas críticas de plantas industriais tais como reatores atômicos, processos químicos e geração de energia. Ao mesmo tempo, os avanços tecnológicos no campo computacional facilitam a simulação de sistemas complexos ou a análise de grandes quantidades de dados em tempo real.

Sistemas complexos consistem de centenas de elementos trabalhando de maneira interdependente e que estão individualmente sujeitos a faltas. Em relação a estes sistemas, para que se mantenham um alto nível de segurança, desempenho, confiabilidade e eficiência, especialmente no caso de processos que trabalham continuamente por um longo período de tempo, é importante que faltas nos componentes e/ou operações anormais sejam detectadas prontamente, e que a origem, a intensidade sejam diagnosticadas, para que se realizem ações corretivas.

Uma falta, pode ser definida como uma alteração no funcionamento do sistema que causa o comprometimento do seu desempenho. Esta anomalia pode ou não causar uma parada total da planta. Em muitos casos, podem causar uma deterioração do desempenho da planta em relação ao seu potencial nominal sem, contudo, impedir o seu funcionamento. Além de diagnosticar a falta, o sistema de monitoramento deve fazê-lo de maneira rápida, de forma a evitar o seu agravamento, principalmente em casos de faltas incipientes.

Em processos reais, as incertezas com relação ao verdadeiro comportamento do sistema a ser

monitorado, distúrbios desconhecidos, imprecisão nas medições de sinais ou uma combinação total ou parcial desses fatos, dificultam a tarefa de detecção e isolamento de faltas - FDI. Em razão disto, torna-se necessário o desenvolvimento de sistemas robustos, que se caracterizam por dissociar das possíveis faltas, os ruídos, os erros de modelagem ou as pequenas mudanças no comportamento do sistema. Esta característica deve ser considerada tanto na detecção quanto no isolamento da falta.

O procedimento que utiliza a detecção e isolamento de faltas, avaliando o seu significado e gravidade no processo, é chamado *Sistema de Diagnóstico de Faltas* (PATTON, R.J. et al. 2000). Portanto, um sistema desta natureza consiste na detecção da falta, identificando anomalias no funcionamento do sistema a partir da geração de resíduos, seguido do seu isolamento ou identificação do local de ocorrência, isto é, em quais sensores, atuadores ou funções da planta ocorre o problema. A FIG. 1.1 apresenta um diagrama para uma possível classificação dos métodos de detecção e isolamento de faltas.

A função de detecção e isolamento de faltas pode ser obtida utilizando métodos clássicos tais como a *redundância de hardware*, que é a replicação de computadores, sensores, atuadores e outros componentes; a *checagem de limites*, feita através da medição direta de sinais, avaliando a discrepância em relação aos limites de tolerância dos sinais monitorados e a *análise de sinais*, que trabalha diretamente os sinais mensuráveis através de seus modelos, como funções de correlações e frequência espectral.

Alternativamente, pode-se utilizar as informações *analíticas ou funcionais* sobre o sistema a ser monitorado, admitindo que este relacionamento funcional possa ser considerado como um conhecimento prévio do processo. Frequentemente, estes métodos são apresentados na forma de um modelo matemático do sistema em consideração, conhecido como redundância analítica. Sistemas de monitoramento que utilizam esta abordagem são conhecidos também como *Sistemas de Diagnóstico de Faltas Baseado em Modelos*. Neste caso, a idéia é obter sinais que reflitam as inconsistências entre a operação nominal do sistema e a operação real. O princípio básico é comparar as respostas do sistema real em relação ao sistema reconstruído através do modelo matemático.¹ Utilizando este conhecimento a priori, um sistema desta natureza pode identificar mudanças em um ponto de operação da planta.

Muitos métodos de *detecção e isolamento de faltas baseado em modelos* são concebidos a

¹Esta abordagem é frequentemente denominada de modelagem quantitativa.

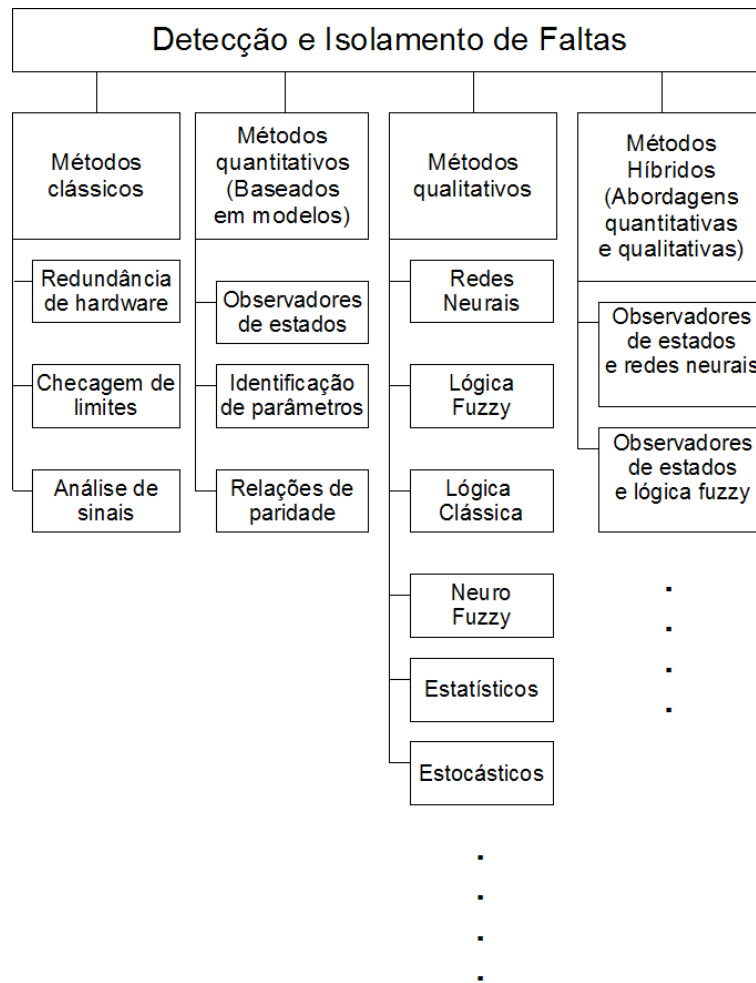


Figura 1.1: Uma possível classificação dos métodos de detecção e isolamento de falhas

partir de sistemas dinâmicos lineares. No caso de sistemas não lineares, isto normalmente implica em uma linearização do modelo em torno de um ponto de operação.

A redundância analítica pode ser exemplificada a partir de um conjunto de medições x_1 , x_2 e x_3 dependentes entre si, isto é,

$$x_1 = f(x_2, x_3) \tag{1.1}$$

onde, x_1 pode ser estimado a partir de medições de sinais de x_2 e x_3 . Esta estimativa pode, então, ser comparada ao valor real de x_1 e alguma diferença entre o valor real e o estimado pode indicar uma falta. Esta diferença gerada pela comparação é denominada de *resíduo*: se for zero, a planta não apresenta falta; diferente de zero apresenta falta (DALTON, T. 1999).

Os trabalhos desenvolvidos nesta linha utilizam, em grande medida, as contribuições da moderna teoria de controle, bem como, os avanços da tecnologia computacional, o que tem permitido

melhoria na capacidade de processamento e confiabilidade no uso de sofisticadas funções de supervisão de sistemas (PATTON, R.J. & KANGETHE, S.M. 1988).

Esses resíduos podem ser obtidos utilizando método de estimação de estados, tradicionalmente através de *observadores de estado ou filtros de Kalman*, da estimação de parâmetros ou a relações de paridade. Enquanto a estimação de parâmetros emprega identificação em tempo real dos parâmetros do modelo matemático associados aos coeficientes físicos do processo, a estimação de estados consiste na reconstrução do conjunto ou subconjunto de estados ou variáveis mensuráveis consideradas do modelo matemático em tempo real.

Já no caso das relações de paridade, a geração de resíduos se dá através do rearranjo do modelo de entrada e saída, de tal maneira que as equações sob condições normais, sem faltas, ruídos e/ou erros de modelagem, produzam resíduo zero. As equações do modelo, rearranjadas, são chamadas de *equações de paridade*.

Nestas abordagens, a exatidão e a precisão necessárias na descrição do modelo implicam que qualquer erro na modelagem pode afetar os resultados da detecção e isolamento de faltas. Esta consideração é particularmente verdadeira para sistemas complexos com dinâmica não linear, que apresentam incertezas nas condições de operação.

No caso de não haver o modelo quantitativo, ou este for incompleto ou impreciso, a opção seria utilizar modelos mais abstratos, baseados nos aspectos qualitativos do processo como, por exemplo, desenvolver regras a partir da Lógica Clássica ou da Lógica Fuzzy, que permitam descrever o comportamento do sistema. Outra alternativa, que também se caracteriza pela mesma independência em relação ao modelo do sistema, são as abordagens que utilizam os métodos conexionistas, onde se destacam as RNAs. Estas estruturas, podem ser treinadas para reproduzir um comportamento específico do sistema a partir de um conjunto de dados históricos.

Na atualidade, os mecanismos de detecção e isolamento de faltas requerem também que os mesmos sejam robustos, ou seja, maximizem a capacidade de detectar e isolar faltas, ao mesmo tempo que minimizam a influência dos efeitos das incertezas e distúrbios inerentes aos sistemas dinâmicos. Estas características são obtidas tanto utilizando métodos quantitativos, quanto métodos qualitativos, ou mesmo a partir de abordagens que manipulam informações qualitativas e quantitativas, neste caso, conhecidos como métodos híbridos. Por exemplo, gerando resíduos através da estimação de parâmetros ou observadores de estado e deixando a tomada de decisão para um sistema de inferência fuzzy ou para uma RNA. Há também os métodos chamados de *soft computing* que empregam a combinação de técnicas da área de Inteligência Computacional,

como a Lógica Fuzzy, as RNAs, esquemas neurofuzzy, programação evolucionária.

1.2 Relevância

Reconhecidamente, as máquinas de indução são de suma importância nos ambientes de produção, principalmente em função do seu baixo custo, porte razoável, menor custo de manutenção e operação, dentre outras vantagens. Conseqüentemente, as técnicas para diagnosticar este tipo de máquina têm sido bastante discutidas, tanto na indústria como nos meios acadêmicos.

Máquinas de indução apresentam vários tipos de distúrbios durante a operação, que podem levar a algum tipo de falta. Estudos nesta área mostram que neste tipo de máquina, aproximadamente de 30 a 40% das faltas ocorrem no estator. Estes percentuais são confirmados por pesquisas patrocinadas pelos institutos IEEE e EPRI, onde aproximadamente 7500 motores foram examinados extensivamente, e os resultados mostraram que problemas no estator são responsáveis por quase 38% das faltas. Isto nos leva a considerar que executar a manutenção preditiva em máquinas de indução requer testes ou monitoramento sensíveis para diagnóstico das condições do estator (IVONNE, Y. B. et al. 2005).

Nas últimas décadas, o monitoramento e detecção de faltas em máquinas elétricas têm evoluído das técnicas convencionais para técnicas baseadas em Inteligência Computacional, tais como Lógica Fuzzy, RNAs ou estruturas que combinam técnicas como os Sistemas Neurofuzzy. Estas técnicas apresentam vantagens em relação às técnicas convencionais em abordagens de diagnóstico de faltas. Além de um bom desempenho, estas técnicas podem facilmente ser estendidas e modificadas, incorporando novas informações ou dados.

1.3 Escopo

Este trabalho apresenta primeiramente uma revisão bibliográfica das principais técnicas de diagnóstico de faltas, considerando dois grandes grupos: as técnicas baseadas em modelos e as técnicas livres de modelos. Em seguida discorre sobre a implementação de sistemas de diagnóstico de faltas em máquinas de indução, utilizando técnicas livres de modelos baseada em Inteligência Computacional e modelos híbridos. Na seqüência, apresenta estudo comparativo e conclusões, implementando um sistema de monitoramento de faltas no enrolamento estator de máquinas de indução, utilizando abordagens quantitativas e qualitativas.

1.4 Objetivo

Apresentar um estudo comparativo de implementação de um sistema de detecção e isolamento de faltas no estator de máquinas de indução, utilizando técnicas de Inteligência Computacional.

1.5 Metodologia

O sistema de monitoramento proposto foi construído, utilizando técnicas de Inteligência Computacional tais como RNAs, estruturas Fuzzy e Neurofuzzy, empregando um simulador de máquina de indução, a partir do qual foram geradas as informações necessárias para o treinamento das estruturas neurais utilizadas e simulações necessárias. A condução dos trabalhos seguiu a seguinte cronologia:

- **Primeira Fase:** Levantamento de referências bibliográficas sobre as questões relacionadas à detecção e isolamento de faltas em máquinas elétricas;
- **Segunda Fase:** A partir do levantamento bibliográfico, os estudos foram direcionados para os sistemas de monitoramento que utilizam técnicas de Inteligência Computacional, com aplicações em máquinas de indução e especificamente faltas no enrolamento do estator;
- **Terceira Fase:** Desenvolveram-se os sistemas de detecção e isolamento de faltas, utilizando-se estruturas de RNAs, Lógica Fuzzy e Neurofuzzy, com o objetivo de gerar informações comparativas acerca da utilização destas ferramentas;
- **Quarta Fase:** Testes e validações dos sistemas desenvolvidos;
- **Quinta Fase:** Redação da dissertação.

1.6 Estrutura do trabalho

- **Capítulo 1:** Introdução do problema proposto, sua relevância, escopo, objetivos a serem atingidos e metodologia utilizada;
- **Capítulo 2:** Revisão bibliográfica das técnicas utilizadas na implementação de sistemas de detecção e isolamento de faltas;

- **Capítulo 3:** Apresentação das propostas de sistemas de detecção e isolamento de faltas utilizando técnicas de Inteligência Computacional em máquinas de indução;
- **Capítulo 4:** Apresentação dos sistemas desenvolvidos, utilizando RNAs, Lógica Fuzzy e neurofuzzy, para diagnosticar faltas no estator de máquinas de indução;
- **Capítulo 5:** Análise dos resultados de simulação.

Capítulo 2

Revisão bibliográfica

2.1 Detecção e Isolamento de Faltas Baseado em Modelo

Quando se utilizam informações baseadas na descrição matemática do processo, o princípio básico é comparar as respostas do sistema real com aquelas obtidas pelo modelo. Tais estruturas são empregadas para produzir informações quantificáveis e, para isto, obtêm-se os valores característicos das variáveis do processo. As diferenças entre o comportamento real e o esperado são expressas como resíduos.

Os erros que resultam da modelagem podem influenciar negativamente os processos de monitoramento, tornando-se uma fonte de alarmes falsos, o que faz destes o principal desafio a ser superado por sistemas que utilizam este tipo de abordagem (FRANK, P.M. 1994).

Examinando a literatura, observa-se uma extensa variedade de métodos que utilizam esta abordagem, normalmente divididos em três subgrupos: aqueles que se baseiam na *identificação de parâmetros*, os que utilizam a *estimação de estados* (a partir de observadores e filtros) e os que se baseiam nas *relações de paridade*. Em qualquer uma destas situações é necessário que o processo possa ser descrito através de um modelo matemático, o que torna importante a discrepância entre o modelo e o processo real. Neste caso, o modelo propriamente dito é a questão central.

Para uma análise mais detalhada da tarefa de detecção e isolamento de faltas, empregar-se-á, a princípio, um sistema em malha aberta. Este será dividido em três partes: *atuadores*, *dinâmica do sistema* e *sensores*, como ilustrado na FIG. 2.1.

Aqui, $u(t)$ é o vetor de sinais medidos na entrada, $y(t)$ o vetor de sinais medidos na saída,

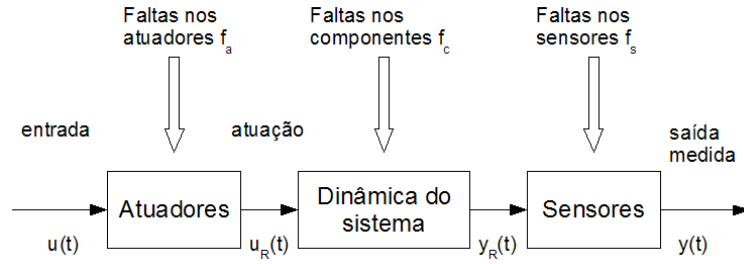


Figura 2.1: Sistema em malha aberta com falha

$u_R(t)$ e $y_R(t)$ são sinais corrompidos por faltas no atuador e no sensor. No caso do sistema livre de faltas, a dinâmica do sistema da FIG. 2.1 pode ser descrita pelo modelo em espaço de estados como

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu_r(t) \\ y_r(t) = Cx(t) + Du_r(t) \end{cases} \quad (2.1)$$

onde $x(t)$ é vetor de estados e A, B, C, D são as matrizes de dimensões apropriadas.

As faltas no sistema podem ocorrer devido ao atuador, componente do sistema e sensores. Quando as faltas são consideradas, a dinâmica do sistema muda como segue:

- Falta no atuador

$$u_r(t) = u(t) + f_a(t) \quad (2.2)$$

desprezando a dinâmica do atuador, $f_a(t) \in \mathbf{R}^r$ é o vetor de falta do atuador, onde $f_a(t) = [f_{a1}, f_{a2}, \dots, f_{an}]^T$. $u_r(t)$ e $u(t) \in \mathbf{R}^r$, onde $u_r(t)$ é o vetor de entrada do sistema e $u(t)$ é o vetor de entrada do atuador.

- Falta nos componentes do Sistema Dinâmico

$$\dot{x}(t) = Ax(t) + Bu_r(t) + f_c(t) \quad (2.3)$$

onde $f_c(t)$ é o vetor de falta nos componentes do sistema, $f_c(t) \in \mathbf{R}^n$, $f_c = [f_{c1}, f_{c2}, \dots, f_{cn}]^T$; $x(t)$ é vetor de estado $\in \mathbf{R}^n$; $A \in \mathbf{R}^{n \times n}$, $B \in \mathbf{R}^{n \times r}$ e $u_r \in \mathbf{R}^r$, já definido anteriormente.

- Falta no sensor

$$y(t) = y_R(t) + f_s(t) \quad (2.4)$$

desprezando a dinâmica do sensor, $f_s(t) \in \mathbf{R}^m$ é o vetor de falta do sensor, $f_s = [f_{1s}, f_{2s}, \dots, f_{ms}]^T$; $y(t) \in \mathbf{R}^m$ é o vetor de saída do sensor, sendo $y(t) = [y_1, y_2, \dots, y_m]^T$ e $y_R(t) \in \mathbf{R}^m$ é o vetor de saída da planta, onde $y_R(t) = [y_{R1}, y_{R2}, \dots, y_{Rm}]^T$.

Se as três condições prévias de falta são consideradas simultaneamente, o modelo dinâmico do sistema passa a ser:

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) + Bf_a(t) + f_c(t) \\ y(t) = Cx(t) + Du(t) + Df_a(t) + f_s(t) \end{cases} \quad (2.5)$$

onde $C \in \mathbf{R}^{m \times n}$ e $D \in \mathbf{R}^{m \times r}$.

Generalizando o modelo em espaço de estados do sistema com todas as possíveis faltas, pode ser expresso como:

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) + R_1 f(t) \\ y(t) = Cx(t) + Du(t) + R_2 f(t) \end{cases} \quad (2.6)$$

onde $f(t) \in \mathbf{R}^g$ é um vetor de falta, cujos componentes $f_i(t)$ com $(i = 1, 2, \dots, g)$ correspondem à faltas específicas, $R_1 \in \mathbf{R}^{n \times g}$, $R_2 \in \mathbf{R}^{m \times g}$, são matrizes de entrada que representam os efeitos das faltas sobre o sistema.

Determinando limites, fixos ou variáveis, para as bandas dos sinais medidos no processo a ser monitorado, as faltas são detectadas quando se geram resíduos a partir da diferença entre os valores das medidas reais e os estimados, a partir do modelo matemático do sistema em consideração. A FIG. 2.2 ilustra a estrutura conceitual e geral de um sistema desta natureza, compreendendo os dois estágios mencionados anteriormente, ou seja, a geração destes resíduos e a tomada de decisão (ISERMANN, R. 1984), (CHOW, S.Y. & WILLSKY, A.S. 1984).

O resíduo é um sinal $r(t)$, que traz informações do tempo e da localização das faltas. São quantidades que representam a inconsistência entre as medições na planta real e as saídas obtidas a partir do seu modelo matemático. Se está próximo de zero, o sistema está livre de faltas, caso

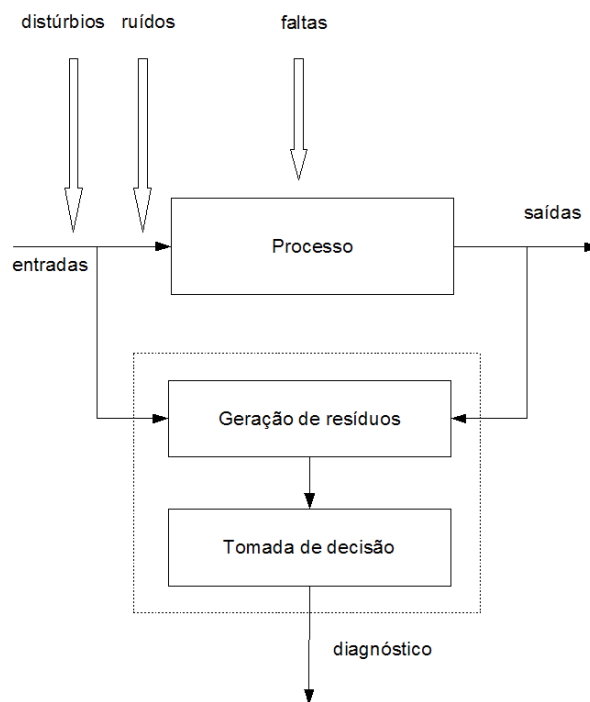


Figura 2.2: Estrutura conceitual de diagnóstico de falhas baseada em modelos

contrário, está ocorrendo uma falta. Se múltiplas faltas ocorrem e têm que ser isoladas, é necessário gerar conjunto de resíduos estruturados, de tal forma que as diferentes faltas sejam refletidas pelos resíduos nas diferentes situações e que possam ser discriminadas (PATTON, R.J. & CHEN, J. 1992).

O processo de decisão avalia e monitora onde a provável falta está ocorrendo. Esta decisão pode consistir de um simples teste de limiar, a partir de valores obtidos em tempo real, ou através da obtenção de médias móveis de resíduos, ou diretamente a partir de métodos estatísticos (PATTON, R.J. & CHEN, J. 1992).

2.1.1 Métodos para geração de resíduos

Enquanto o método de *checagem de limites* depende do estado em um determinado ponto de operação, os métodos que geram sinais de resíduos são independentes dos estados de operação e respondem somente pelas faltas. Na ausência delas, os resíduos devem-se somente a ruídos e distúrbios, nominalmente próximo de zero (PATTON, R.J. & CHEN, J. 1992). Um típico gerador de resíduos é ilustrado na FIG. 2.3, envolvendo o processamento dos dados de entrada e de saída de um sistema.

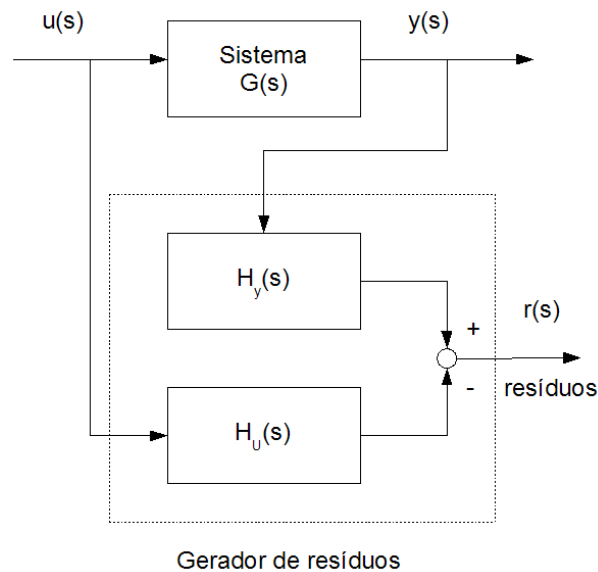


Figura 2.3: Estrutura completa de um gerador de resíduos

Uma descrição matemática completa deste gerador de resíduos pode ser expresso como:

$$r(s) = [H_u(s) \ H_y(s)] \begin{bmatrix} u(s) \\ y(s) \end{bmatrix} = H_u(s)u(s) + H_y(s)y(s) \quad (2.7)$$

onde, $H_u(s)$ e $H_y(s)$ são matrizes de transferência realizáveis, usando sistemas lineares estáveis. O resíduo deve ser independente do estado de operação normal do sistema. No caso do sistema livre de falta

$$\begin{aligned} r(s) &= 0 \\ y(s) &= G(s)u(s) \end{aligned} \quad (2.8)$$

as matrizes de transferência $H_u(s)$ e $H_y(s)$ devem satisfazer a equação 2.9

$$(H_u(s) + H_y(s)G(s))u(s) = 0 \quad (2.9)$$

$$H_u(s) + H_y(s)G(s) = 0 \quad (2.10)$$

ou

$$H_u(s) = -H_y(s)G(s) \quad (2.11)$$

O projeto do gerador de resíduos resulta simplesmente, da escolha de $H_u(s)$ e $H_y(s)$ que deve satisfazer a equação 2.10. Quando ocorre falta na planta monitorada, a resposta do vetor de resíduos é:

$$r(s) = H_y(s)G_f(s)f(s) \quad (2.12)$$

de modo a detectar a i -ésima falta no resíduo $r(s)$, a i -ésima linha da matriz função de transferência $[H_y(s)G_f(s)]$ será diferente de zero, especialmente para valores em regime permanente, isto é, $[H_y(s)G_f(s)]_i \neq 0$ e especialmente $[H_y(0)G_f(0)]_i \neq 0$. $G_f(s)$ é a função de transferência do sistema na condição de falta $f(s) \in \mathbb{R}^g$, onde $f(s) = [f_1(s), f_2(s), \dots, f_g(s)]^T$.

Geração de resíduos baseada em observador

De acordo com Xu e Jiang (XU, Y. & JIANG, J. 1998), a geração de resíduos baseada em observador consiste na reconstrução das saídas do sistema a partir de sua medição, ou de um subconjunto delas, com a ajuda de um observador e utilizando o erro na estimação, como resíduo para a detecção e isolamento de faltas. Para um sistema linear invariante no tempo

$$\dot{x} = Ax + Bu \tag{2.13}$$

$$y = Cx \tag{2.14}$$

Considerando um sistema completamente observável, um observador de estado pode ser projetado como a seguir (Equações 2.15 e 2.16

$$\dot{\hat{x}} = A\hat{x} + Bu + K(y - \hat{y}) \tag{2.15}$$

$$\hat{y} = C\hat{x} \tag{2.16}$$

onde \hat{x} , \hat{y} e K são estados estimados, a saída e o ganho do observador, respectivamente. A diferença entre o valor da medida da saída real y e o da saída estimada \hat{y} , pode ser utilizada como o sinal de resíduo, com o propósito de detectar e isolar faltas. A FIG. 2.4, mostra a configuração de gerador residual baseado em observador; f , d e r representa a falta, o distúrbio e o sinal de resíduo respectivamente.

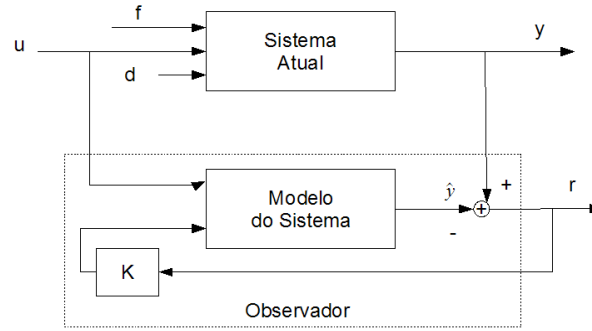


Figura 2.4: Gerador de resíduo baseado em observador

Subtraindo a equação 2.15 da equação 2.13, teremos

$$\begin{aligned}\dot{x} - \dot{\hat{x}} &= Ax - A\hat{x} - K(Cx - C\hat{x}) \\ &= (A - KC)(x - \hat{x})\end{aligned}\quad (2.17)$$

O erro na estimação de estados é:

$$\tilde{x} = x - \hat{x}\quad (2.18)$$

e

$$\dot{\tilde{x}} = (A - KC)\tilde{x}\quad (2.19)$$

Na equação 2.19, que representa a dinâmica do comportamento do sistema, o vetor \tilde{x} é determinado pelos autovalores da matriz $(A - KC)$. Se a matriz $(A - KC)$ é estável, o vetor de erro converge para zero para algum valor inicial $\tilde{x}(0)$. O sinal de resíduo é:

$$r = y - \hat{y} = C\tilde{x}\quad (2.20)$$

Todavia, se existe uma falta ocorrendo no sensor, que pode ser modelada como uma alteração na matriz C , isto é, $C' = C + \Delta C$, o resíduo será:

$$r = C\tilde{x} + \Delta C\tilde{x}\quad (2.21)$$

Faltas no atuador e no sistema podem ser modelados de maneira similar como alterações nas matrizes A e B , respectivamente.

Geração de resíduos através da estimação de parâmetros

Detecção e isolamento de faltas baseados em modelos, também podem ser através do uso de técnicas de identificação de parâmetros, caso a estrutura básica do modelo seja conhecida (ISERMANN, R. 1984), (ISERMANN, R. 1997). Para isto, considera-se que as faltas reflitam nos parâmetros físicos do processo. Os parâmetros do processo são estimados *online*, utilizando os métodos de estimação de parâmetros; e os resultados são, então, comparados com os parâmetros obtidos inicialmente sob condições livres de faltas. Alguma discrepância que se caracterizar, indica uma falta. Considerando-se o modelo do sistema como sendo

$$y(t) = f(\theta, u(t)) \quad (2.22)$$

onde θ é um vetor cujos componentes são os parâmetros do sistema, é possível estimar os parâmetros do modelo no tempo discreto $k-1$ como $\hat{\theta}_{k-1}$, através da identificação de parâmetros *online*. Assumindo que o coeficiente estimado no tempo k é $\hat{\theta}_k$, o resíduo pode ser definido como

$$\begin{aligned} r(k) &= \hat{\theta}_k - \theta_0 \text{ ou} \\ r(k) &= y(k) - f(\hat{\theta}_{k-1}, u(k)) \end{aligned} \quad (2.23)$$

A FIG. 2.5 ilustra o processo de identificação de parâmetros para detecção e isolamento de faltas.

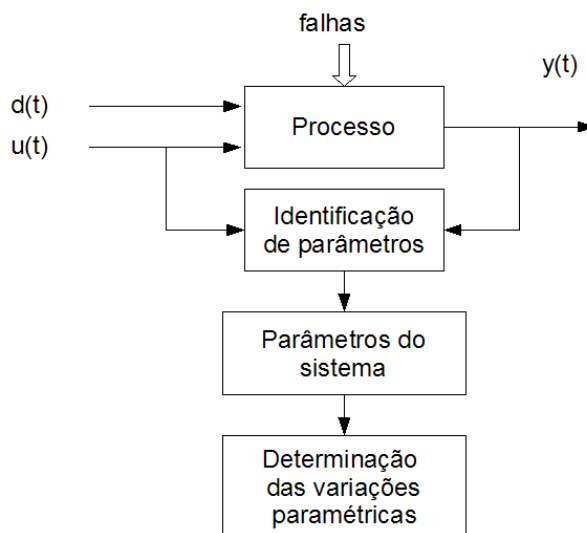


Figura 2.5: Geração de resíduos via identificação de parâmetros

Geração de resíduos utilizando equações de paridade

Este método foi primeiro proposto por Chow e Willsky (CHOW, S.Y. & WILLSKY, A.S. 1984) empregando as relações redundantes de um sistema dinâmico. A idéia básica é providenciar uma conferência de paridade (consistência) de medidas para um determinado sistema a ser monitorado.

Uma maneira simples de generalizar a obtenção de resíduos para um sistema linear dinâmico envolve o rearranjo do modelo de entrada-saída, onde esta nova descrição produzida pelo rearranjo é chamada *equações de paridade*. Alternativamente, estas novas relações podem ser obtidas diretamente da estrutura desejada, a partir das descrições do espaço de estados da planta (GERTLER, J.J. 2000). Descreve-se, abaixo o desenvolvimento do modelo, de acordo com o trabalho de Huo e outros (HUO, Y. et al. 2001). Considerando o sistema discreto no tempo

$$\begin{cases} x(k+1) = Ax(k) + Bu(k) + R_1 f(k) \\ y(k) = Cx(k) + Du(k) + R_2 f(k) \end{cases} \quad (2.24)$$

As relações de redundância são especificadas matematicamente como

$$\underbrace{\begin{bmatrix} y(k-s) \\ y(k-s+1) \\ \vdots \\ y(k) \end{bmatrix}}_{Y(k)} - H \underbrace{\begin{bmatrix} u(k-s) \\ u(k-s+1) \\ \vdots \\ u(k) \end{bmatrix}}_{U(k)} = Wx(k-s) + M \underbrace{\begin{bmatrix} f(k-s) \\ f(k-s+1) \\ \vdots \\ f(k) \end{bmatrix}}_{F(k)} \quad (2.25)$$

onde

$$H = \begin{bmatrix} D & 0 & \dots & 0 \\ CB & D & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ CA^{s-1}B & CA^{s-2}B & \dots & D \end{bmatrix}; M = \begin{bmatrix} R_2 & 0 & \dots & 0 \\ CR_1 & R_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ CA^{s-1}R_1 & CA^{s-2}R_1 & \dots & R_2 \end{bmatrix}; W = \begin{bmatrix} C \\ CA \\ \dots \\ CA^s \end{bmatrix} \quad (2.26)$$

Um sinal de resíduo pode ser definido como

$$\begin{aligned} r(k) &= V[Y(k) - HU(k)] \\ &= VWx(k-s) + VMF(k) \end{aligned} \quad (2.27)$$

Ainda segundo Huo e outros (HUO, Y. et al. 2001), para satisfazer o critério de detectabilidade de faltas, a matriz deve também atender a condição

$$VW = 0 \quad (2.28)$$

$$VM \neq 0 \quad (2.29)$$

Uma vez obtida a matriz V , o sinal de resíduo poder ser gerado. Para um s suficientemente grande, uma solução da Equação 2.28 sempre existe. Isto significa que um gerador de resíduos para detecção de faltas baseado em relações de paridade sempre existe (CHEN, J. & PATTON, R.J. 1999).

2.1.2 Técnicas para avaliação de resíduos

Depois dos resíduos gerados, segue-se a sua avaliação para que se possa distinguir uma falta em particular. Pode-se estabelecer um conjunto estruturado de resíduos que são sensíveis para uma falta específica e insensíveis para outras (GERTLER, J.J. 1993). Uma outra maneira é projetar um vetor residual direcional, que fixa uma direção que corresponde a uma falta particular no espaço residual.

Esquema de observador dedicado

Neste tipo de esquema (DOS), a principal questão é a utilização de um conjunto de sinais residuais. Cada sinal é sensível a um determinado tipo de falta e insensível ao resto (FIG. 2.6). A tarefa de isolamento da falta pode ser alcançado pela comparação de cada sinal de resíduo com o conjunto inicial de valores e o resultado é obtido através de uma tabela de decisão booleana. O isolamento lógico da falta pode ser representado por

$$\begin{cases} r_i(t) > T_i \Rightarrow f_i(t) \neq 0; \\ r_i(t) \leq T_i \Rightarrow f_i(t) = 0; \end{cases} \quad i = 1, 2, \dots, q \quad (2.30)$$

onde T_i é um limiar.




Figura 2.6: Esquema dedicado (Conjunto estruturado de resíduos)

Este esquema é conveniente somente para uma falha sensível ao observador. Todavia, não é um esquema robusto para sinais desconhecidos, tais como distúrbios, incertezas e ruídos- (WUENNENGERG, J. 1990); (FRANK, P.M. 1990).

Vale observar neste caso que a adoção de um limiar T_i pequeno, aumenta a indicação de alarme falso. Quando T_i possui um valor maior, o sistema pode falhar na detecção de falta. Isto é, a falta está ocorrendo e não se consegue detecta-la; no outro caso ele indica a existência de falta quando, na realidade, é um ruído.

Esquema de observador generalizado

De acordo com Huo e outros (HUO, Y. et al. 2001), o *esquema de observador generalizado* (GOS), também utiliza um conjunto estruturado de resíduos. No entanto, a diferença em relação ao observador dedicado é o fato de que todos os resíduos do conjunto obtido são sensíveis a todos os observadores com exceção de um, isto é,

$$\begin{cases} r_i(t) \leq T_i \\ r_i(t) > T_j \forall j \in \{1, i-1, i+1, \dots, q\} \end{cases} \Rightarrow f_i(t) \neq 0 \quad (2.31)$$

A FIG. 2.7 mostra o esquema descrito acima para o caso de 3 possíveis faltas




Figura 2.7: Esquema de observador generalizado

Esquema que utiliza o conjunto residual direcional

A terceira possibilidade de isolar faltas é a utilização de um vetor residual direcional. Consiste em projetar o sinal de resíduo de maneira a convergir na direção de uma assinatura, $\vec{l}(f)$, da falta f . A assinatura da falta é um vetor no espaço residual que representa a falta específica. O isolamento da falta é obtido pela comparação do vetor residual e as assinaturas de diferentes tipos de faltas (HUO, Y. et al. 2001) (vide FIG. 2.8).




Figura 2.8: Isolamento de falta com conjunto residual direcional

2.1.3 Robustez na detecção e isolamento de faltas em sistemas baseados em modelo

O problema da robustez na detecção e isolamento de faltas é geralmente definido como a maximização da capacidade de detecção e isolamento de faltas, aliado à minimização dos efeitos das incertezas e distúrbios, inevitáveis nos processos reais gerando os erros de modelagem. A tarefa, portanto, consiste em projetar sinais de resíduos que são totalmente sensíveis as faltas, mas são desacoplados dos distúrbios e incertezas. A sua importância se deve ao efeito que estas distorções trazem para os resíduos gerados.

Várias propostas de projetos desta natureza tem sido apresentadas, e engoblam desde a utilização de métodos baseados na redundância analítica, passando pelas alternativas qualitativas e outros esquemas que combinam abordagens quantitativas e qualitativas. Conforme mencionado anteriormente, a geração de resíduos pode ser obtida utilizando estimação de parâmetros, observadores de estado ou equações de paridade, enquanto a tomada de decisão é feita por uma

máquina de inferência fuzzy ou neurofuzzy (CALADO, J.M.F. et al. 2001).

Um dos grandes problemas no campo da detecção e isolamento de faltas é causado pelas incertezas nos valores dos parâmetros físicos do sistema monitorado (tais como propriedades de massa, momentos de inércia, parâmetros de circuitos elétricos, momentos e forças de aerodinâmica e hidrodinâmica, propriedades de transferência de calor, etc).

Se os parâmetros são conhecidos com precisão, os resíduos obtidos representam com correção os problemas do sistema, tornando possível a detecção e isolamento de faltas incipientes ou leves, ao mesmo tempo que torna o esquema de monitoramento imune aos alarmes falsos (PATTON, R.J. & CHEN, J. 1992). Em consequência disto, os estados ou parâmetros devem ser designados somente em termos nominais para os parâmetros incertos, ou utilizar algum mecanismo de acomodação visando compensar as incertezas.

Na presença de variações de parâmetros do processo, a equação de estados pode ser representada como:

$$\dot{x}(t) = (A - \Delta A)x(t) + (B + \Delta B)u(t) + R_1 f(t) \quad (2.32)$$

$$y(t) = (C + \Delta C)x(t) + (D + \Delta D)u(t) + R_2 f(t) \quad (2.33)$$

onde ΔA , ΔB , ΔC e ΔD representam as matrizes de erros de modelagem e de perturbações nos parâmetros (PATTON, R.J. & CHEN, J. 1992).

O erro na estimação de estados e equação residual são:

$$\dot{e}(t) = (A - KC)e(t) + R_1 f(t) - KR_2 f(t) + \Delta Ax(t) + \Delta Bu(t) - K\Delta Cx(t) - K\Delta Du(t) \quad (2.34)$$

$$r(t) = WCe(t) + WR_2 f(t) + W\Delta Cx(t) + \Delta Du(t) \quad (2.35)$$

Agora, os termos $\Delta Ax(t)$, $\Delta Bu(t)$, $\Delta Cx(t)$ e $\Delta Du(t)$ forçarão o vetor residual $r(t)$ a crescer de maneira uniforme, se nenhuma falta ocorrer no sistema. De fato, os efeitos das incertezas nos parâmetros e faltas são misturados, dificultando a distinção nos resíduos. Claramente, como os termos das perturbações são usualmente desconhecidos para as aplicações reais, isto pode tornar de difícil solução o problema da robustez em sua plenitude. Todavia, é possível minimizar os

efeitos dos termos não desejados nos resíduos, para produzir predominantemente a informação relativa à falta.

Outra questão relevante é quando uma falta ocorre durante a fase transiente, $e(0)$ diferente de zero nas condições iniciais fará com que o resíduo seja diferente de zero. Se $e(0)$ é conhecido, o problema da geração de resíduos torna-se trivial. Todavia, como em geral $e(0)$ não é conhecido, torna-se também um dificultador na solução do problema.

Plantas dinâmicas são não-lineares, embora muitas se comportem aproximadamente de maneira linear, desde que não se requeira que se desviem das imediações da região estabelecida em torno de determinadas condições de operação. No entanto, fora destas condições, a não linearidade da planta produz sinais que não são modelados de maneira precisa e que podem ser muitas vezes interpretados como faltas. Conseqüentemente, um sistema de monitoração de faltas deve ser testado, para funcionar em um conjunto de pontos de operações da planta monitorada.

Muitos sistemas têm fatores não-lineares, embora uma representação linear seja freqüentemente usada para modelar um sistema para pequenas perturbações em torno de um ponto de operação. Pode-se considerar um erro de linearização $\Delta f(x, u)$ como representado na equação 2.36.

$$\dot{x}(t) = Ax(t) + Bu(t) + R_1 f(t) + \Delta f(x, u) \quad (2.36)$$

$$y(t) = Cx(t) + Du(t) + R_2 f(t) \quad (2.37)$$

Deste modo

$$\dot{e}(t) = (A - KC)e(t) + R_1 f(t) - KR_2 f(t) + \Delta f(x, u) \quad (2.38)$$

$$r(t) = WCe(t) + WR_2 f(t) \quad (2.39)$$

O erro na linearização pode afetar os resíduos que, muitas vezes, causam falsos alarmes. A dinâmica dos sistemas está sujeita, sempre, a outras entradas que não aquelas pretendidas pelo projetista do mesmo. Estas entradas, conhecidas como distúrbios, usualmente são aleatórios, tais como flutuações no tempo. Além disto, os sensores usualmente têm ruídos eletrônicos sobrepostos aos seus sinais. Estes ruídos são também aleatórios, mas originam-se de fontes

diferentes e não têm relação com os distúrbios. A maior parte das técnicas de processamento utilizada por projetistas para avaliar as flutuações aleatórias assume que ruídos e, algumas vezes, distúrbios, são processos Gaussianos estacionários com parâmetros conhecidos. Se os distúrbios e ruídos não são estacionários nem Gaussianos, então o sistema de detecção e isolamento de faltas trabalhará abaixo do nível previsto (PATTON, R.J. & CHEN, J. 1992).

As equações do sistema são:

$$\dot{x}(t) = Ax(t) + Bu(t) + G\xi(t) + R_1f(t) \quad (2.40)$$

$$y(t) = Cx(t) + Du(t) + \varepsilon(t) + R_2f(t) \quad (2.41)$$

onde, $\xi(t)$ é um vetor de distúrbio e $\varepsilon(t)$ representa ruídos nos sensores. Deste modo, as equações da estimação de erro e do resíduo são:

$$\dot{e}(t) = (A - KC)e(t) + R_1f(t) - KR_2f(t) + G\xi(t) - K\varepsilon(t) \quad (2.42)$$

$$r(t) = WCe(t) + WR_2f(t) + W\varepsilon(t) \quad (2.43)$$

Na prática, a maioria dos sistemas tem uma dinâmica de alta ordem. No projeto do sistema pode-se utilizar um modelo de baixa ordem para aproximar o sistema de ordem mais alta. Por esta razão, a dinâmica dos erros aparece no modelo.

$$\dot{x}(t) = Ax(t) + Bu(t) + A_1x_h(t) + R_1f(t) \quad (2.44)$$

$$y(t) = Cx(t) + Du(t) + R_2f(t) \quad (2.45)$$

onde A_1x_h é um termo do modelo da redução do erro.

$$\dot{e}(t) = (A - KC)e(t) + R_1f(t) - KR_2f(t) + A_1x_h(t) \quad (2.46)$$

$$r(t) = WCe(t) + WR_2f(t) \quad (2.47)$$

As faltas em um equipamento podem ser classificadas de acordo com a sua localização (sensores, atuadores, faltas intermitentes, de comunicação, em um componente, como uma válvula por exemplo, dentre outros). As faltas podem ser classificadas, em relação ao tipo de sinal de falta, como sendo: alterações abruptas, faltas estocásticas, dentre outras PATTON, R.J. & CHEN, J. (1992). São exemplos desses tipos de faltas: um sensor que sofre uma mudança no fator de escala; uma não linearidade devido a desgaste ou atrito, excesso de ruídos ou histerese, dentre outras possibilidades. Muitos destes sistemas são projetados para detectar somente alguns tipos específicos de faltas, o que os leva a não identificar problemas não previstos na base de conhecimento de diagnóstico de faltas. O ideal é ter um esquema que detecte todas as faltas e os componentes defeituosos, mesmo que o tipo específico de falta não seja identificado. O mais importante é isolar os eventos de uma falta causados por incertezas nos processos internos ou por distúrbios externos.

O tipo de falta afeta principalmente o processo de tomada de decisões, o que é especialmente verdadeiro para o caso de sistemas estocásticos. Um monitoramento robusto para todos os tipos de faltas pode incluir geração e teste de hipóteses. Os procedimentos para gerações de hipóteses devem construir um repertório de defeitos ou faltas conhecidas, ou hipoteticamente possíveis, em componentes do sistema ou em instrumentos (sensores). As abordagens mais consistentes de geração de hipóteses estão baseadas na combinação de raciocínio qualitativo e quantitativo, explorando as vantagens de cada abordagem.

Uma das abordagens mais promissoras para a obtenção de robustez no diagnóstico de faltas, denominada de desacoplamento dos distúrbios, utiliza a estruturação das incertezas em termos de distúrbios, atuando na dinâmica do modelo.

2.2 Aplicação das técnicas baseada em modelos qualitativos no diagnóstico de faltas

Os métodos mencionados até agora são dependentes do modelo do sistema dinâmico, portanto, aplicáveis somente quando estes modelos são conhecidos. Na ausência deste, ou quando incompleto ou pouco consistente, uma alternativa é a utilização das chamadas técnicas *livres de modelos* (HUO, Y. et al. 2001). Por exemplo, em muitos casos, os sintomas de faltas não podem ser obtidos por medições, mas podem receber informações a partir de observações de operadores

humanos de um determinado sistema. Neste caso, são chamados de sintomas heurísticos (IS-ERMANN, R. & ULIERU, M. 1993). Estes métodos são atrativos por não necessitarem dos modelos matemáticos explícitos da planta a ser monitorada.

O diagnóstico de faltas pode também ser obtido através de conhecimentos declarativos, relativo ao comportamento do sistema, chamado de *modelo qualitativo*. Não há o uso de resíduos quantitativos para gerar os sintomas das faltas, mas a utilização do conhecimento qualitativo (IS-ERMANN, R. 1994). 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. Esta representação qualitativa do conhecimento inclui *árvores de faltas*, isto é, as associações dos sintomas com os respectivos tipos de faltas, o histórico do processo e a estatística das faltas. Baseiam-se na avaliação do conhecimento heurístico, podendo-se adotar a estratégia de *encadeado para frente* ou o *encadeado para trás*, normalmente aplicados nos mecanismos de inferência em Sistemas Especialistas¹.

Sistemas Especialistas é uma das áreas da Inteligência Artificial, e diferem dos sistemas convencionais pelo fato de separar o conhecimento de um domínio específico. Enquanto num sistema convencional estas duas questões estão interrelacionadas, num sistema especialista a base de conhecimento e a interface com o usuário² encontram-se separadas, sendo que a segunda age como um receptáculo da primeira.

Tipicamente, a base de conhecimento é construída a partir de regras do tipo *SE..ENTÃO*. Cada regra especifica o que fazer, ou que conclusão extrair, diante um conjunto de circunstâncias bem definidas. Alguns dos diferentes conjuntos de regras típicas são: as que representam fatos, as que identificam sintomas, as que propõem procedimentos de reparo, as que priorizam a manutenção, dentre outras.

Portanto, esta categoria de sistemas baseados em conhecimento tem como característica a capacidade de raciocinar sobre os dados e projetar conclusões empregando regras heurísticas. Com várias regras heurísticas codificadas em sua base de conhecimento, juntamente com um mecanismo chamado de máquina de inferência, o sistema pode *raciocinar* sobre situações de um determinado problema e apresentar um conjunto de prováveis soluções. Em alguns casos, poderá prover uma estimativa das probabilidades de sucesso para cada hipótese ou conclusão

¹Sistemas Especialistas, são programas de computadores que têm como característica representar o conhecimento especialista humano de uma determinada área

²Identificada como a Shell do sistema

gerada. Para esta abordagem é necessário o conhecimento sobre a estrutura do processo, das unidades funcionais e o modelo qualitativo das unidades do processo sob várias condições de faltas.

Os observadores baseados em conhecimento são um outro exemplo de sistema para se processar informações incompletas, fato não factível nos modelos analíticos. Nesta abordagem, o sistema é descrito em termos de um conjunto de fatos e regras que caracterizam o seu comportamento. A sua dinâmica é definida por um número limitado de valores (tais como ligado / desligado; baixo / médio / alto). Uma simulação pode ser feita para determinar possíveis estados futuros do sistema, em decorrência de mudanças permissíveis em vários sinais em um dado intervalo de tempo. Os valores atuais do sistema em um próximo instante de tempo podem ser comparados com os estados gerados, de maneira similar ao observador analítico.

2.2.1 A Lógica Fuzzy em sistemas de diagnóstico de faltas

Os fundamentos matemáticos da Lógica Fuzzy estão fundamentados na teoria dos conjuntos fuzzy, que podem ser vistos como uma generalização da teoria clássica de conjuntos (TSOUKALAS, L.H. & UHRIG, R.E. 1997). Ela foi proposta no ano de 1965 por Lotfi A. Zadeh, esta orientada a modelos de raciocínio aproximado, e foi desenvolvida para prover algoritmos de processamento de informações que podem raciocinar sobre ou utilizar dados imprecisos (BROWN, M. & HARRIS, C. 1994). A idéia básica é prover uma resposta aproximada a uma pergunta, em função de fatos previamente armazenados e que podem ser inexatos, incompletos ou pouco confiáveis.

A mais importante característica da Lógica Fuzzy é a sua capacidade de representar a maneira humana de tratar alguns problemas, a partir de informações linguísticas. Além disto, quando um ser humano está resolvendo um problema, inicialmente tenta estruturar seu conhecimento em termos de conceitos gerais e, posteriormente, observa as relações entre estes conceitos. Esta perspectiva humana de encarar um problema não permite uma definição precisa de uma solução, mas leva a uma classificação ou agregação qualitativa em categorias gerais ou conjuntas. Este tipo de modelagem permite que se converta esta relação imprecisa em algoritmos operacionais detalhados.

A classificação das variáveis de um problema em termos de conceitos qualitativos, no lugar de quantitativos, traduz a idéia de uma variável linguística, entidade utilizada para se representar um conceito ou variável de um dado problema. As variáveis linguísticas admitem como valores,

expressões lingüísticas como *muito grande*, *pouco frio*, *aproximadamente alto*; informações que podem se tornar poderosas se utilizadas por técnicas que trabalham com a inexatidão e a incerteza. Desta maneira, pode-se utilizar os dados coletados de um processo produtivo para a geração de diagnósticos qualitativos sobre o seu funcionamento, através de um sistema difuso de processamento e inferência. Os diagnósticos gerados auxiliam os operadores em caso de ocorrência de faltas ou eventos inesperados, permitindo um tratamento efetivo e padronizado em situações de exceção detectadas no equipamento.

Ao contrário da Lógica Clássica, que trabalha com informação binária (falso ou verdadeiro), a Lógica Fuzzy faz uso de informações aproximadas, admitindo graus de pertinência aos elementos de um conjunto para encontrar possíveis soluções. Entre seus benefícios estão a tolerância a erros e a possibilidade de fornecer respostas a partir de informações ambíguas.

Seu desenvolvimento tem possibilitado a utilização de informações lingüísticas para a solução de problemas de controle de processos. Mas também, pode ser empregada em outros campos onde o conhecimento do especialista humano pode contribuir para completar os resultados conseguidos pelos métodos analíticos. Este é particularmente o caso dos problemas de diagnóstico de faltas (SAUTER, D. et al. 1994). Os modelos fuzzy são, portanto, aplicados em situações onde as informações disponíveis são imprecisas ou sua interpretação depende fortemente do contexto ou da opinião de um especialista humano. Sua utilização pode representar imprecisão associadas com a descrição do comportamento do sistema e incorporar com mais facilidade o conhecimento do especialista sobre sintomas de faltas (DEXTER, A.L. 1995).

A Lógica Fuzzy pertence, essencialmente, a uma subclasse adicional de abordagens baseadas em regras, onde regras de diagnóstico podem ser formuladas a partir de processos estruturados e de unidades funcionais (PATTON, R.J. et al. 2000). Um exemplo é o observador fuzzy baseado no modelo TS. Para um sistema dinâmico não linear descrito pelo modelo TS fuzzy, um observador fuzzy pode ser projetado para estimar o vetor de estado do sistema, assumindo que o modelo fuzzy do sistema é localmente observável. Utilizando a idéia de Compensação Paralela Distribuída (PDC), em que a cada ponto observado corresponde um modelo diferente do sistema, um observador linear invariante no tempo é associado a cada regra do modelo fuzzy.

Recentemente, as aplicações de Lógica Fuzzy para sistemas de diagnóstico de faltas baseados em modelo tem crescido significativamente. Os sintomas podem ser gerados através de um observador, baseado na estimação da saída do sistema. A tomada da decisão pode ser feita a partir de uma máquina de inferência fuzzy.

Apesar do sucesso da aplicação destes modelos em diversas áreas, muitas vezes a tarefa de escolher uma função de pertinência apropriada e de definir um conjunto de regras adequadas ao problema é bastante complexa. No caso das regras, estas podem ser obtidas por meio de métodos de otimização como LMIs, como a proposta de projeto de observador ótimo TS, baseado em condições relaxadas de estabilidade (PATTON, R.J. et al. 1999), ou através da aplicação de algoritmos de aprendizado adaptativos ou RNAs para a obtenção dos parâmetros do sistema fuzzy.

2.2.2 As RNAs em sistemas de diagnóstico de faltas

Enquanto um simples resíduo é suficiente para detectar a ocorrência de uma falta, para o seu isolamento é necessário um conjunto de resíduos. Uma das alternativas mais comuns é a geração de um conjunto estruturado de resíduos. A estrutura deve ser sensível a determinados tipos de faltas e insensível a outros. Todavia, o relacionamento entre faltas e resíduos pode ser não linear, como por exemplo, no caso das faltas multiplicativas, o que dificulta o seu isolamento. As RNAs têm sido uma excelente ferramenta para tratar sistemas não lineares, especialmente em sistemas de diagnóstico de faltas. Esta forma de computação é caracterizada por sistemas que, em algum momento, relembram a estrutura do cérebro humano. Por não ser baseada em regras ou programas, a computação neural constitui alternativa à computação algorítmica convencional (BRAGA, A.P. et al. 2000).

As aplicações utilizando tais estruturas têm sido motivadas desde o começo pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional. O cérebro é um computador altamente complexo, não-linear e paralelo, onde o conhecimento é adquirido através de um processo de aprendizagem atuando nas conexões entre neurônios, conhecidas como sinapses. (HAYKIN, S. 2001).

Uma RNA consiste de neurônios, que representam unidades de processamento, que são ativados quando a soma ponderada de suas entradas excede certo limite ou limiar. Em uma de suas organizações, os neurônios são arranjados em camadas e conectados de tal maneira que os sinais da entrada são propagados através da rede até a saída. A escolha da função de ativação de cada neurônio contribui para representar o comportamento não linear na rede (MARCUS, T. & MIREA, L. 1997).

Esta estrutura sugere um processador maciço e paralelamente distribuído, constituído de

unidades de processamento simples, que tem a propensão de armazenar conhecimento experimental e torná-lo disponível para o uso (HAYKIN, S. 2001). Como suas contrapartes no sistema nervoso biológico, ela pode aprender e, conseqüentemente, ser treinada para encontrar soluções, reconhecer padrões, classificar dados e prever eventos futuros. O seu comportamento é definido pela maneira com que seus elementos computacionais individuais são conectados e pela intensidade destas conexões ou por seus pesos, que são ajustados automaticamente durante o treinamento, de acordo com as regras de aprendizagem especificadas para que execute corretamente uma determinada tarefa.

As redes têm sido importante ferramenta para tratar problemas não lineares, além de oferecer outras propriedades e características úteis, tais como, adaptabilidade de seus pesos sinápticos em relação às modificações do meio ambiente; capacidade de responder a evidência, indicando não somente o padrão selecionado, mas também informando a confiança ou crença na decisão tomada; tolerância a faltas, principalmente no caso de sua implementação na forma física (em hardware); adequação para integração em larga escala VLSI, por sua natureza maciçamente paralela, entre outras.

Uma rede neural típica pode ser classificada como um sistema não linear que consiste de muitas unidades de processamento (ditos neurônios), interligados, formando as camadas. Há uma camada de entrada e uma de saída, cada uma contendo pelo menos um neurônio (HAYKIN, S. 2001).

A solução de problemas através destas estruturas passa, num primeiro momento, por uma fase de aprendizagem, na qual um conjunto de exemplos é apresentado para a rede, que extrai automaticamente as características necessárias para representar a informação fornecida (BRAGA, A.P. et al. 2000). Portanto, extraem as características de um sistema a partir do seu treinamento com dados históricos ou simulados, utilizando algoritmos de aprendizado, o que requer pequeno ou nenhum conhecimento a priori sobre o processo. O aprendizado no contexto das RNAs é um processo pelo qual os parâmetros livres, pesos sinápticos e níveis limiares, são ajustados através de um processo iterativo com um conjunto de dados.

O tipo de aprendizagem é determinado pela maneira como ocorre a modificação dos parâmetros (HAYKIN, S. 2001). Por esta razão, redes neurais podem ser treinadas para representar relações entre valores passados de dados residuais, gerados por outras RNAs e estes, por sua vez, identificados com conhecimento sobre condições de faltas (PATTON, R.J. et al. 2000). Um conjunto pré-estabelecido de regras definido para a solução de um determinado problema de

aprendizagem é denominado de algoritmo de aprendizagem (HAYKIN, S. 2001). Existe uma variedade de algoritmos de aprendizagem que diferem entre si pela maneira como é definido o ajuste dos pesos sinápticos da RNA dentre outros aspectos.

A construção de uma RNA inclui a seleção de diversos itens, tais como entradas, saídas, topologia da rede e pesos associados às conexões entre nós. A seleção das características de entrada é o primeiro passo e requer uma análise cuidadosa sobre o problema, para diminuir ambiguidades e erros nos dados. Os dados coletados devem ser representativos, cobrir amplamente o domínio do problema e representar as diferentes situações da planta em questão, indicando as condições de operação com e sem faltas.

O segundo passo é a definição da configuração da rede, que pode ser dividido nas etapas de seleção do modelo neural apropriado à aplicação, na determinação da topologia da rede a ser utilizada, ou seja, o número de camadas, o número de unidades em cada camada bem como a determinação do algoritmo de treinamento e funções de ativação.

O terceiro passo, de fundamental importância, é o treinamento, ou a fase de aprendizagem mencionada acima, na qual, seguindo o algoritmo de treinamento escolhido, são ajustados os pesos das conexões. Nesta fase é importante considerar alguns aspectos tais como inicialização da rede e de seus pesos, o modo e o tempo de treinamento.

As RNAs empregadas em detecção e isolamento de faltas utilizam diferentes estruturas. As mais usadas são as redes preditoras de sistemas dinâmicos não lineares e as redes classificadoras de padrões. Estas abordagens podem utilizar redes com características dinâmicas, Redes Neurais Recorrentes, dentre outras arquiteturas. Quando se utiliza a abordagem de geração de resíduos, estes podem ser avaliados por um classificador de padrões, possíveis de execução por várias estruturas neurais como Preceptron Multinível estático, redes neurais de Base Radial, redes auto-ajustáveis e redes de estrutura múltipla.

Geralmente, um esquema de RNA aplicado em sistemas de detecção e isolamento de faltas(FDI) consiste de dois módulos, um gerador de resíduos e outro de tomada de decisão. Num primeiro momento o vetor residual r é gerado, representando as características de cada falta. Preferencialmente, a rede identifica todas as classes representativas do comportamento do sistema. Em um segundo momento, ocorre a tomada de decisão, ou processo de classificação do vetor de resíduos r , para determinar a localização das faltas (vide FIG. 2.9).

Existe grande número de possibilidades quanto às arquiteturas de redes utilizadas em sistemas de diagnósticos. Segundo Patton (PATTON, R.J. et al. 1999), algumas das mais comuns

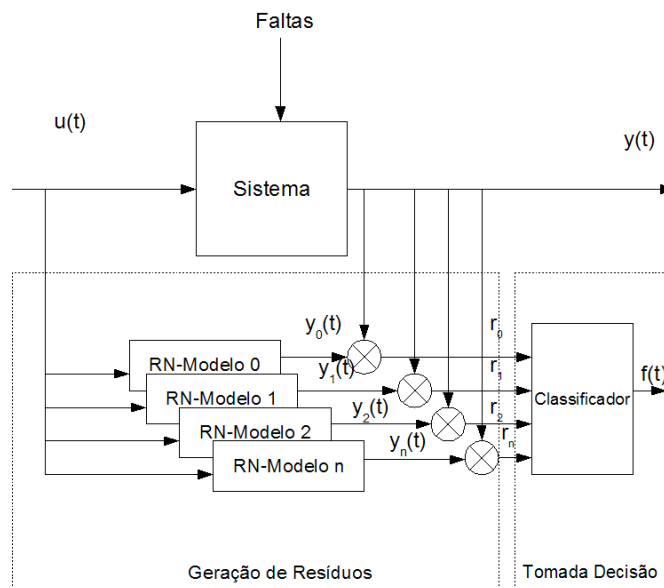


Figura 2.9: Esquema geral de diagnóstico de falhas utilizando RNAs

são classificadas de acordo com o esquema apresentado na FIG. 2.10

Para identificação de sistemas dinâmicos, as RNAs também necessitam de alguma dinâmica envolvida na sua estrutura. As redes dinâmicas ou recorrentes tem estas características nas suas estruturas. Para redes sem elementos dinâmicos internos a opção mais comum tem sido a utilização de linhas de atraso tais como as estruturas de treinamento NARX. A base para estas estruturas é a suposição de que sistemas dinâmicos não lineares podem ser representados pela expressão 2.48.

$$y_N(t) = f(u(t-k), \dots, u(t-k-n_u+1), y(t-1), \dots, y(t-n_y)) + e(t) \quad (2.48)$$

onde y é a saída do processo, u é a entrada do processo, e é o erro, f é a representação da função não linear da rede, $n_u = n_y = n$ é a ordem do modelo e $k-1$ é o modelo do instante anterior. A FIG. 2.11 ilustra um esquema de treinamento NARX.

2.2.3 Abordagens híbridas em diagnóstico de falhas

A integração do conhecimento simbólico e quantitativo, através de um sistema neurofuzzy, combina, por exemplo, a capacidade de aprendizado das RNAs com a possibilidade de representação explícita do conhecimento por parte da Lógica Fuzzy. Esta combinação resulta no aumento

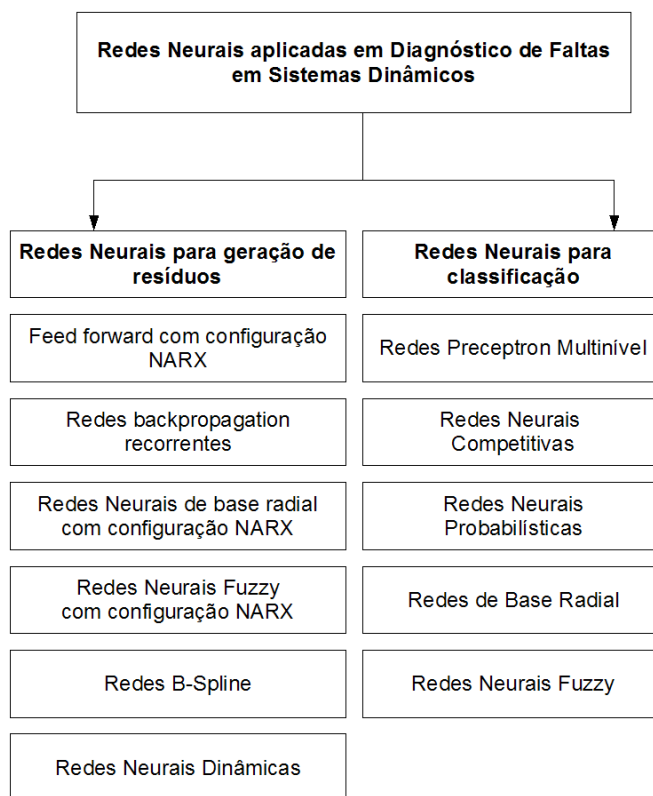


Figura 2.10: Arquiteturas de RNAs para Diagnóstico de Falhas em Sistemas Dinâmicos

da velocidade, da tolerância a erros e da adaptabilidade (CALADO, J.M.F. et al. 2001).

As redes neurofuzzy, valem-se de uma estrutura fuzzy, para combinar Lógica Fuzzy e RNAs. Uma estrutura desta natureza é um processador que recebe dados padrões como entrada e os converte em categorias difusas para uso da Rede Neural. Estas estruturas híbridas podem ser utilizadas tanto para geração como para classificação de resíduos. Uma RNA pode converter conhecimento em regras e funções de pertinência; e a Lógica Fuzzy pode otimizar o número de regras que a rede aprende (FIG. 2.12).

Muitas aplicações de RNAs tratam com processos em regime permanente. No monitoramento em tempo real existe o comportamento transitório dos processos dinâmicos que devem ser levados em conta. Muitas vezes, as redes em questão são utilizadas como simples classificadores considerando somente as saídas do sistema. Isto pode causar informações incorretas sobre uma possível falta, quando houver mudanças na entrada do sistema. A Lógica Fuzzy, que por sua vez, encontra limitações pelo fato do domínio do especialista em questão nem sempre ser

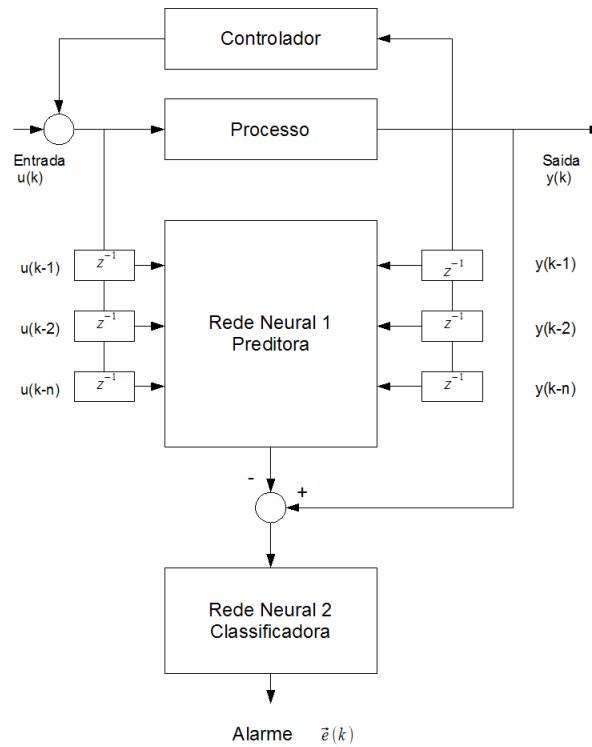


Figura 2.11: Estrutura de treinamento NARX




Figura 2.12: Conceito básico de uma rede neurofuzzy

pensado em termos de regras, além de, em certas circunstâncias, ser de difícil descrição, gerando especificações incorretas (BENKHEDDA, H. & PATTON, R.J.M. Setembro 1996).

Como estruturas que aliam a capacidade de raciocínio dos modelos fuzzy com a capacidade de aprendizado das RNAs, as redes neurofuzzy apresentam-se como alternativa de abordagem para superar as limitações expostas no parágrafo anterior, por aproveitar a habilidade das redes em manipular tais dados e conhecimento simbólico representado em termos de regras heurísticas através da Lógica Fuzzy.

Capítulo 3

Monitoramento de faltas em máquinas elétricas

3.1 Considerações gerais

*T*radicionalmente, os procedimentos de manutenção de equipamentos em plantas de processos têm seguido dois caminhos. O primeiro é a fixação de períodos para a manutenção dos equipamentos, onde são inspecionados; o segundo tem sido simplesmente reagir quando ocorre uma alteração no seu funcionamento. Todavia, tem se consolidado uma nova abordagem do processo de manutenção, a partir da utilização de tecnologias mais recentes. Um aspecto relevante nesta nova tendência é prever a necessidade de manutenção do equipamento ou da planta, a partir do monitoramento de certas características.

As máquinas elétricas estão sujeitas a diferentes tipos de faltas e diferentes métodos para identificá-las têm sido desenvolvidos e utilizados de modo efetivo, para detectar a existência de faltas em seus diferentes estágios. Dentre as grandezas monitoradas incluem: correntes, tensão, velocidade, temperatura, vibração, entre outras.

Desta maneira, aumenta-se a confiabilidade, a segurança e a disponibilidade dos equipamentos, reduzindo os danos, aumentando sua vida útil, diminuindo a reposição de peças, custos e números de manutenções. Um eficiente esquema de monitoramento das condições, possibilita identificar e isolar as possíveis faltas no seu estágio inicial.

Os fabricantes e os usuários de máquinas elétricas, serviram-se por muito tempo, de relés protetores, tais como o relé da sobrecarga, para proteger os equipamentos. Porém, estes dispositivos

não permitem monitorar a evolução das faltas, o que só é possível através do monitoramento de certas características e do desempenho do equipamento, permitindo, desta maneira, detectar as faltas enquanto estas se desenvolvem.

Devido a sua larga utilização, tanto em escala industrial quanto doméstica, as máquinas de indução tem recebido maior atenção nos trabalhos de pesquisa nesta área.

Nos últimos tempos, as técnicas de Inteligência Computacional tem sido empregadas com bastante frequência, no sentido de suportarem sistemas de diagnóstico de faltas. Em um sistema desta natureza, utilizam-se diversas informações qualitativas. Em geral, adotam-se como variáveis a serem monitoradas as correntes e tensões no estator, devido à sua fácil aquisição e permitirem a realização de diagnósticos não invasivos. Existem muitos tipos de técnicas baseadas em Inteligência Computacional; as mais relevantes baseiam-se em RNAs, em Lógica Fuzzy e em sistemas híbridos como as estruturas neurofuzzy (FILIPPETI, F. et al. 2000).

A principal característica das estruturas neurais é sua competência para as aproximações de funções não lineares, obtidas através da utilização de uma determinada topologia de rede, construída a partir de neurônios artificiais conectados através de pesos apropriados.

Já os sistemas baseados em Lógica Fuzzy estruturam-se a partir regras, mas também podem ser considerados um aproximador universal de funções não lineares. Em contraste com as RNAs, este tipo de sistema possui descrição transparente de como a aproximação da função é executada. Por outro lado, sistemas neurofuzzy são basicamente RNAs com características fuzzy (FILIPPETI, F. et al. 2000).

3.1.1 A natureza das faltas em máquinas elétricas

O motor de indução é considerado máquina robusta e tolerante a falhas. No entanto, as razões pelas quais ocorrem faltas em máquinas elétricas rotativas podem ter origem no projeto, no controle de qualidade na fabricação, na montagem, na instalação, no meio ambiente de operação, na natureza da carga e das tarefas. Motores de indução, de maneira similar a outros tipos de máquinas elétricas, estão sujeitos tanto a forças mecânicas quanto eletromagnéticas. O projeto do equipamento deve ser tal que a interação entre estas forças sob condições normais de operação levem à estabilidade com o mínimo de ruído e vibração. Quando as faltas ocorrem, o equilíbrio entre estas forças é alterado, realçando a ocorrência de uma possível anormalidade (SINGH, G. K. & AL KAZZAZ, S. A. S. 2003).

As faltas em motores elétricos podem ser categorizadas, quanto a natureza, em dois tipos (VAS, P. 1993):

- **Mecânicas:**

- alinhamento do mancal;
- curvatura de eixo, que pode resultar em danos aos enrolamentos e ao núcleo do estator;
- faltas no rolamento e na caixa de engrenagens;
- irregularidade de ordem dinâmica, desbalanceamento, provocando vibração excessiva e conseqüente fadiga da estrutura da máquina e isolamento;
- falta na cimentação no leito das esferas ou roletes nos rolamentos, provocando vibração excessiva, levando ao *stress* no isolamento elétrico e deformação plástica permanente nas esferas de maneira acumulativa.

- **Elétricas:**

- faltas no estator oriundas de abertura ou curto circuito no enrolamento de uma ou mais fases;
- problema na conexão dos enrolamentos do estator;
- quebra ou trinca da barra do rotor ;
- curto circuito entre espiras ou abertura do enrolamento do rotor.

Dentre os tipos de faltas relacionados anteriormente, os mais relevantes em virtude de sua maior incidência são: faltas no rolamento, no enrolamento do estator, quebra de barra em máquinas de indução e faltas relativas à excentricidade. Estes tipos de faltas produzem um ou mais dos sintomas relacionados abaixo (NANDI, S. & AHMED, S. 2005):

- desequilíbrio de tensão e corrente entre fases;
- aumento na intensidade do conjugado pulsante;
- decréscimo do valor médio do torque, devido os componentes de seqüências negativas presentes nas tensões e correntes;

- aumento das perdas de origem elétricas e magnéticas e conseqüente redução da eficiência e aumento do aquecimento.

Com o propósito de detectar tais sinais indicativos de faltas, vários métodos têm sido desenvolvidos para este fim. Tais métodos podem envolver diferentes campos da ciência e da tecnologia, tais como (NANDI, S. & AHMED, S. 2005):

- monitoramento do campo magnético, bobinas de busca, detecção do fluxo de dispersão do eixo;
- medição da temperatura;
- reconhecimento com infravermelho de falta utilizando imagem térmica;
- monitoramento com o auxílio de emissões de frequência de rádio;
- monitoramento de ruídos e vibrações;
- análise química;
- medição acústica de ruídos;
- análise de assinatura de corrente;
- técnicas baseadas em modelos e técnicas livres de modelos;

Características extraídas de um ou mais destes métodos são utilizadas para o diagnóstico de faltas, que pode incluir faltas no enrolamento do estator, quebra da barra do rotor ou do anel terminal de fechamento da gaiola, faltas relacionadas à excentricidade, faltas nos componentes do sistema de acionamento, dentre outras. Segundo (SINGH, G. K. & AL KAZZAZ, S. A. S. 2003), as fontes de faltas em motores podem ser classificadas como faltas de origem interna, externa ou do meio ambiente. As faltas internas, por sua vez, podem ser classificadas, a partir de sua origem, como elétricas ou mecânicas vide (FIG. 3.1).

Também de acordo com (SINGH, G. K. & AL KAZZAZ, S. A. S. 2003), as faltas em máquinas de indução podem ser classificadas, pela sua localização, em dois grupos: faltas no estator ou faltas no rotor vide (FIG. 3.2).

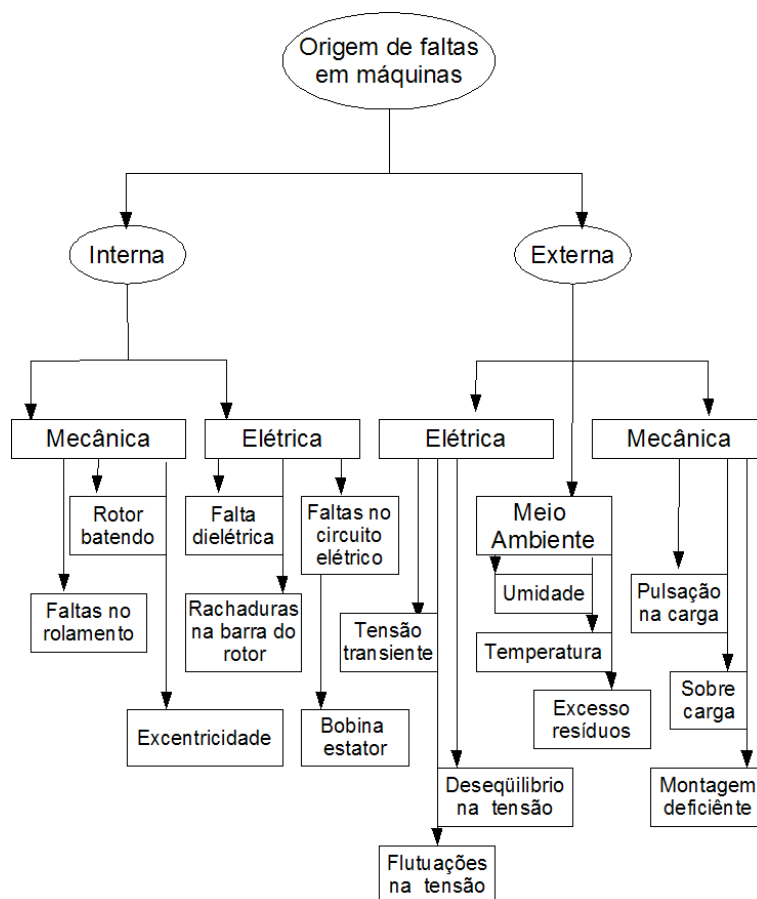


Figura 3.1: Origem de faltas em máquinas de indução

3.2 Tipos de faltas e técnicas de monitoramento e identificação

3.2.1 Faltas no rolamento

A maioria das máquinas elétricas utilizam rolamentos com esferas ou roletes, cuja estrutura consistem de dois anéis - exterior e interior. As esferas giram entre o canal adutor interno aos dois anéis. Faltas no rolamento podem ser atribuídas aos anéis internos e/ou externos, deformação plástica das esferas (roletes) ou ao adutor interno. Em condições normais de operação, com carga balanceada e bom alinhamento, faltas desse tipo podem ocorrer devido à fadiga, o que possibilita sintomas como o aumento do nível de ruído e de vibração. Além destes fatores, outras causas externas, podem levar a este tipo de falta tais como:

- contaminação e corrosão, causadas pela ação abrasiva de partículas sólidas, ou ação cor-



Figura 3.2: Faltas mais comuns em máquinas de indução e suas causas

rosiva de água, ácido, etc.

- lubrificação imprópria, causa da abrasão e/ou aumento de temperatura;
- instalação inadequada do rolamento no eixo ou na carcaça causando desalinhamento.

Apesar de representarem entre 40 a 50% das faltas que ocorrem em máquinas de indução, faltas no rolamento foram pouco exploradas na literatura (AWADALLAH, M.A. & MEDHAT, M. M. 2003). Pode-se alegar como razão para tal lacuna o fato de que defeitos no rolamento são associados à assimetria de eixo e portanto, associados na maioria dos estudos a faltas relativas à excentricidade.

Frequências de vibração do eixo associadas a diferentes faltas no rolamento de esferas podem ser representadas pelas equações 3.1, 3.2, 3.3 e 3.4 (VAS, P. 1993).

$$f_0 = \left(\frac{N}{2}\right) f_r \left[1 - \left(\frac{b_d}{d_p}\right) \cos\beta\right] \quad (3.1)$$

para defeitos no anel externo

$$f_i = \left(\frac{N}{2}\right) f_r \left[1 + \left(\frac{b_d}{d_p}\right) \cos\beta\right] \quad (3.2)$$

para defeitos no anel interno

$$f_b = \left(\frac{d_p}{b_d}\right) f_r \left[1 - \left\{\left(\frac{b_d}{d_p}\right) \cos\beta\right\}^2\right] \quad (3.3)$$

para defeitos nas esferas, e

$$f_t = \left(\frac{f_r}{2}\right) \left[1 - \left(\frac{b_d}{d_p}\right) \cos\beta\right] \quad (3.4)$$

para defeitos no adutor, onde N é o número de esferas, f_r é a frequência rotacional, b_d é o diâmetro da esfera, d_p é o diâmetro do adutor e β é o ângulo de contato da esfera com o adutor.

Schoen e outros (SCHOEN, R.R., HABETLER, T.G., et al. 1995), apresentam um esquema no qual a análise do espectro de corrente do motor é utilizada para detectar danos no rolamento de máquinas da indução. Este trabalho demonstra a praticidade deste método de detecção, correlacionando as frequências características do rolamento aos componentes espectrais de corrente do estator. Monitoram-se os mesmos componentes pela aplicação de um método adaptativo de análise da frequência no tempo e utilizando a transformada de Fourier para o espectro de corrente do motor (YAZICI, B. & KLIMAN, G.B. 1999). Em seu trabalho (SINGH, G. K. & AL KAZZAZ, S. A. S. 2003), apresentam vários métodos que se utilizam de sinais de vibração para monitorar as condições do rolamento. Outros trabalhos significativos, citados por esses autores, são os artigos de (MATHEW, J. & ALFREDSON, R.J. 1984), (PRABHU, B.S 1996), (CARDINALI, R. & WEBER, D. 1992), (SINHA, B.K. 1996), dentre outros.

3.2.2 Faltas na barra do rotor

São razões para faltas do tipo quebra de barra do rotor:

- estresse térmico devido a sobrecarga e desequilíbrio, aquecimento de terminais ou perdas excessivas;

- estresse magnético causado por forças eletromagnéticas, desequilíbrio magnético, ruído eletromagnético e vibração;
- estresse residual devido a problemas de fabricação, formação de bolhas nas barras e terminações das barras com anéis terminais;
- estresse causado pelo meio ambiente através de contaminação e abrasão do rotor devido a agentes químicos ou umidade;

Análises de assinatura de corrente têm sido bastante aplicadas, também neste caso, para detectar faltas oriundas de quebra da barra do rotor em motores de indução (BELLINI, A., FELLIPETI F., et al. 2000), (THOMSON, W.T. & FENGER, M. 2000), (FILIPPETI, F. et al. 1996), (KLIMAN, G.B. et al. 1988), (ELKASABGY, N.M. et al. 1992). Os componentes de frequência na faixa de $(1 \pm 2s)f$ são utilizados para detectar este tipo de falta. Schoen e outros (SCHOEN, R.R. & HABETLER, T.G. 1995), relatam que as cargas variantes no tempo produzem harmônicos referentes às correntes do motor de indução, que sobrepõem os harmônicos produzidos pelas diferentes faltas no rotor. Estes harmônicos relativos são separados do espectro de corrente, possibilitando o diagnóstico de falta no rotor através da sua análise da assinatura.

Milimonfared e outros (MILIMONFARED, J. et al. 1999), desenvolveram uma técnica de detecção baseada na desconexão da máquina da estrutura principal e observação dos componentes do espectro da tensão. Os harmônicos de ordem $(6m \pm 1)$, onde $m = 1, 2, 3, \dots$, tornam-se altos no caso de faltas oriundas da quebra de barra do rotor. Elkasabgy, Eastham e Dawson (ELKASABGY, N.M. et al. 1992), utilizaram bobinas de busca interna e externa e observaram os componentes do espectro harmônico da tensão induzida através da equação 3.5

$$f_{falta} = \left(\frac{2f}{p} \right) (1 - s) \pm sf \quad (3.5)$$

onde f é a frequência da fonte, p é o número de pólos e s é o deslize do motor.

3.2.3 Faltas relacionadas à excentricidade

Quando a excentricidade torna-se significativa, resulta no desequilíbrio das forças radiais. Existem dois tipos de efeitos relacionados a este tipo de problema: a excentricidade estática e a excentricidade dinâmica do entre ferro que, na realidade, tendem a coexistir (VAS, P. 1993).

A presença de excentricidade estática e dinâmica pode ser detectada utilizando análise de assinatura de corrente (VAS, P. 1993). A equação descrevendo as componentes de frequência é descrita a seguir (vide expressão 3.6).

$$f_e = f \left[(kR \pm n_d) \frac{(1-s)}{p} \pm \mathbf{v} \right] \quad (3.6)$$

onde $n_d = 0$ no caso de excentricidade estática e $n_d = 1, 2, 3, \dots$, no caso de excentricidade dinâmica (n_d é conhecido como a ordem da excentricidade), f é a frequência da fonte fundamental, R é o número de ranhuras do rotor, s é o deslize do motor, p é o número de par de pólos, k é um número inteiro, \mathbf{v} é a ordem dos harmônicos de tempo do rotor, presentes no dispositivo gerador da fonte de tensão para o motor ($\mathbf{v} = \pm 1, \pm 3, \pm 5, etc.$) NANDI, S. & AHMED, S. (2005). Dorrell e outros (DORRELL, D.G. et al. 1997), monitoraram os componentes de vibração na faixa de frequência $2f_1 \pm f_r$, para diagnosticar a excentricidade em motores de indução.

Outras abordagens tais como o monitoramento da tensão do estator e a utilização de vetor de Park, apresentadas em (CARDOSO, M.A.J. & SARAIVA, E.S. 1993), assim como Toliyat e Al-Nauim (TOLIYAT, H. A. & AL-NUAIM, N. A. 2001) provaram, através de simulação e resultados de experimentos para máquinas síncronas, faltas relativas à excentricidade dinâmica.

3.2.4 Faltas no estator

Esta categoria de falta pode ter várias causas, dentre as quais citam-se:

- altas temperaturas do núcleo e/ou do enrolamento do estator;
- folgas nas cunhas na fixação do enrolamento nas ranhuras;
- folga no enrolamento;
- espiras em curto circuito;
- descargas elétricas parciais entre espiras;
- problemas no sistema de refrigeração.

Vários estudos conduzidos pelo IEEE e EPRI demonstram que este tipo de falta tem grande incidência em motores e, em motores de indução, representam perto de 30 a 40% do total de faltas. Através de modelagens e simulações, estas situações têm sido observadas tanto em motor

síncrono quanto assíncrono. Os dados obtidos por estes modelos fornecem informações sobre o comportamento elétrico dos motores, na presença destas faltas. Neste contexto, várias técnicas de diagnóstico de faltas no enrolamento do estator têm sido apresentadas pela literatura. Para grandes geradores e enrolamentos de estator em torno de 4kV ou mais, métodos online de testes de descarga parcial têm obtido resultados confiáveis (STONE, G. & KAPLER, J. 1998). No entanto, para motores de baixa tensão, procedimentos estão ainda em fase de padronização.

Estas faltas, são usualmente, curto circuitos entre a fase do enrolamento e terra ou entre fases. Faltas no enrolamento do estator tem um efeito altamente destrutivo para a bobina, o que leva a um esforço maior de investigação. Trabalho apresentado por Bellini e outros (BELLINI, A., FRANCESCHINI, G., & TASSONI, C. 2000), demonstra que, em máquinas de indução controlada em malha aberta, o componente da seqüência negativa da tensão ou corrente, possibilita diagnosticar faltas no estator. Por outro lado, Kliman e outros (KLIMAN, G.B. et al. 1996) observaram que o aumento da corrente na fase leva a variações tanto positivas quanto negativas das correntes. Variação negativa da corrente, não relacionada ao desequilíbrio da fonte, é utilizada como índice para diagnóstico. Cash e outros (CASH, M.A. et al. 1998), discorrem sobre uma técnica para detectar faltas no isolamento em máquinas polifásicas de corrente alternada. Já para Penman e outros (PENMAN, J. et al. 1994), através do fluxo de dispersão resultante do enrolamento do estator pode-se detectar e localizar curto circuitos entre espiras. Alguns espectros de freqüência, oriundos da tensão induzida numa bobina em torno do eixo da máquina, são observados para detectar curtos entre espiras. Estas faixas de freqüências são dadas pela expressão 3.7

$$f_t = \left[k \pm \left(\frac{n}{p} \right) (1 - s) \right] f \quad (3.7)$$

onde $k = 1, 3, n = 1, 2, 3, \dots, (2p - 1)$, p é o número de par de pólos, s é o deslize do motor, f a freqüência da fonte de tensão.

A técnica conhecida como transformação de vetor de Park, projeta em duas dimensões a representação das correntes de um motor de indução trifásico, como nas expressões 3.8 e 3.9.

$$i_d = \sqrt{\frac{2}{3}}i_a - \frac{1}{\sqrt{6}}i_b - \frac{1}{\sqrt{6}}i_c \quad (3.8)$$

$$i_q = \frac{1}{\sqrt{2}}i_b - \frac{1}{\sqrt{2}}i_c \quad (3.9)$$

sob condições ideais, a representação das correntes nas três fases para uma representação de vetor de Park, apresenta os seguintes componentes, como mostrado nas equações 3.10 e 3.11:

$$i_d = (\sqrt{6}/2)i_M \sin(\omega t) \quad (3.10)$$

$$i_q = (\sqrt{6}/2)i_M \sin(\omega t - \pi/2) \quad (3.11)$$

onde, i_M é o valor máximo de pico da corrente para a fase (A), ω é a frequência angular em (rad/s) e t a variável de tempo em (s).

Esta técnica tem sido utilizada com sucesso na detecção de faltas no enrolamento do estator em motores de indução (CARDOSO, M.A.J. & MENDES, A.M.S. 1997). O lugar geométrico descrito pelo deslocamento do vetor de corrente segundo a transformação de Park, é um círculo centrado na origem, quando o motor opera sob condições normais sem falta. Na existência de falta a trajetória descrita pelo deslocamento do vetor de corrente de Park tende para uma forma elíptica, cuja proporção de deformação está associada a intensidade e localização da falta (CARDOSO, M.A.J. et al. 1999), (CARDOSO, M.A.J. & MENDES, A.M.S. 1997).

O vetor de Park estendido - EPVA, foi também utilizado para diagnosticar faltas no enrolamento do estator tanto para máquinas trifásicas síncronas quanto assíncronas (CRUZ, S.M.A. & CARDOSO, A.J.M. 2001). Estes mesmos autores, apresentam em (CRUZ, S.M.A. & CARDOSO, A.J.M. 2005) uma estrutura chamada *múltipla referência*, para diagnosticar faltas no estator de motores de indução trifásico, onde um modelo simplificado do motor, em variáveis $d-q-0$, permite estabelecer os circuitos equivalentes, para observar curto circuitos entre espiras.

Técnicas estatísticas têm sido utilizadas para a detecção de faltas no estator (DISTE, C. J. & SCHIFERL, R. 1994). Um modelo para estimar e detectar curto circuito entre espiras no estator no domínio do tempo foi apresentado em (XIANRONG, C. & COCQUEMPOT, V. 2003).

As observações das correntes e das mudanças de suas características no domínio do tempo e/ou da frequência com e sem faltas, têm sido utilizadas na obtenção de informações importantes nos sistemas de detecção e isolamento de faltas. Este procedimento é chamado de análise da assinatura de corrente (MCSA).

Cruz e outros (CRUZ, S.M.A. & CARDOSO, A.J.M. 2003), apresentaram um sistema de diagnóstico em motores de indução com DTC. Neste trabalho, analisou-se o comportamento

de dispositivos com controle de torque na presença de curto circuitos entre espiras. Como seqüência de estudo, (CRUZ, S.M.A. & CARDOSO, A.J.M. 2003) e (CRUZ, S.M.A. et al. 2003) propuseram monitorar as alterações nas componentes de seqüência positiva da corrente através de uma estrutura de referências múltiplas, como uma técnica para diagnóstico de faltas no estator.

3.3 Aplicações de técnicas de Inteligência Computacional em sistema de monitoramento de máquinas

As relações entre as variáveis de um equipamento e o fenômeno de faltas mostram algum nível de incerteza. As relações se tornam mais complexas se múltiplas faltas de diferentes magnitudes são evidenciadas. As técnicas que se utilizam de modelos matemáticos do equipamento, encontram um desafio, que é a precisão do modelo, quando este existe. Uma alternativa a este problema tem sido a aplicação de técnicas livres de modelo, tais como Sistemas Especialistas, RNAs, Lógica Fuzzy, algoritmos genéticos, etc.

Este trabalho concentra-se-á na discussão do uso das RNAs, Lógica Fuzzy e sistemas híbridos como as estruturas neurofuzzy, para modelagem qualitativa, por se considerar que estas técnicas têm apresentado resultados mais efetivos neste campo.

3.3.1 Redes Neurais

As RNAs são capazes de representar funções com alto grau de não linearidade e de modelar processos com múltiplas entradas e múltiplas saídas. As estruturas de RNA têm sido bastante aplicadas no monitoramento de motores, executando as seguintes tarefas:

- reconhecimento de padrões, estimação de parâmetros e mapeamento não linear para condições de monitoramento;
- treinamento baseado em sinais no domínio do tempo e da freqüência, via simulação e/ou resultados de experimentos;
- diagnóstico com e sem supervisão on-line;
- atualização dinâmica da estrutura sem a necessidade de treinar novamente toda a rede;

- filtragem dos transientes, dos distúrbios e dos ruídos;
- predição de faltas no estágio incipiente;
- agrupamento das condições de operação baseada nos tipos de faltas.

O monitoramento de faltas são supervisionados por RNAs que, por sua vez, podem sintetizar a relação entre diferentes variáveis que constituem os vetores de entrada e as informações sobre diagnóstico nos vetores de saída, a partir da utilização de um algoritmo de treinamento. Dentre os vários trabalhos, é consenso que a escolha de uma configuração de rede que melhor se aplique a um sistema de diagnóstico de faltas, deve levar em consideração vários fatores, dentre os quais:

- os aspectos práticos tais como exatidão, robustez e praticidade de implementação;
- os aspectos relativos ao treinamento da rede, tais como as variáveis de entrada e saída, escolha do tamanho do conjunto de dados de treinamento, pesos de inicialização da rede, escolha das taxas de aprendizado, momentum e seleção de critérios de fim da fase de treinamento;
- projeto da rede, considerando a quantidade de neurônios de entrada e de saída, o número de camadas intermediárias, bem como número de neurônios em cada camada intermediária.

Considerando as questões anteriores, um sistema desta natureza é, em geral uma função que pode aproximar as associações entre as diferentes variáveis que constituem os vetores de entrada e de saída da rede que indicam a gravidade da falta a partir de exemplos utilizados no processo de aprendizagem. Todavia, a sensibilidade de uma RNA para sintetizar o sistema depende da escolha adequada das variáveis de entrada que sejam ótimos indicadores de faltas (FILIPPETI, F. et al. 2000).

(CHOW, M. & YEE, S.O. 1991) e (CHOW, M. et al. 1991) empregou uma RNA para detecção de falta em motores de indução. O diagnóstico se baseou na observação de corrente e velocidade do rotor. Duas funções de custo foram desenvolvidas como critério para avaliar as condições do enrolamento e do rolamento. O sistema usou uma rede MLP, com o algoritmo de aprendizado back propagation. Chow e outros (CHOW, M.-Y. et al. 1993), utilizaram o mesmo motor, os mesmos tipos de faltas e os mesmos parâmetros apresentados em (CHOW, M. & YEE, S.O. 1991), com algumas alterações na configuração da rede neural. Os autores

discutem alguns projetos de rede, seu desempenho, complexidade de implementação, tamanho do conjunto de dados para treinamento, atribuição de valores aos parâmetros de treinamento e critérios de parada, acrescentando uma abordagem de Lógica Fuzzy para otimizar a configuração da rede. A conclusão dos autores é de que as rede não supervisionadas são menos eficientes do que as supervisionadas; mas são mais convenientes para uso em processos automatizados, por não demandarem nenhuma informação a priori em relação à distribuição dos dados. Mostraram também, que a questão relativa às decisões ambíguas no contorno de diferentes regiões não podem ser facilmente resolvidas.

Penman e Yin em (PENMAN, J. & YIN, C.M. 1994), discutem o uso de estruturas neurais sem supervisão, para monitorar condições de operação de motores de indução trifásicos. A rede sem supervisão utilizada é a rede de Kohonen. Os harmônicos gerados pela vibração são os dados de entrada para a rede enquanto a saída mostra as condições da máquina.

Schoen e outros (SCHOEN, R.R., LIN, B.K., et al. 1995) apresentam um método para detecção de faltas em motor de indução, onde uma RNA é treinada para reconhecer as características do espectro de corrente. Este espectro pode conter muitos harmônicos devido à carga em condições normais de operação. Para reduzir o número de harmônicos, utiliza-se um filtro seletivo de frequência por onde passam somente aqueles que são conhecidos e, portanto, de maior importância na detecção da falta, ou aqueles mais frequentes em um certo intervalo de tempo, para um algoritmo neural de agrupamento. Após o treinamento, a estrutura sinaliza um novo tipo de falta em potencial quando um novo grupo é formado e persiste por algum tempo. Então, uma falta é detectada pela comparação com uma condição anterior de funcionamento da máquina.

No trabalho de Di Stefano e outros (DI STEFANO, R. et al. 1994), apresenta-se um sistema *on-line* de diagnóstico de faltas em motores de indução, que monitora correntes do estator para detectar diferentes condições de faltas. Estas faltas são caracterizadas por percentuais que é a razão entre o número de espiras em curto circuito em relação ao total de espiras. Estes valores são os dados de entrada para a fase de treinamento da RNA. O algoritmo adotado foi o EBP proposto por Rumelhart, Hinton e Willians.

Li Bo e outros (LI, B. et al. 2000) apresentam a aplicação de análise de tempo e frequência dos sinais de vibração para detectar faltas no rolamento com o auxílio de uma RNA supervisionada para classificação das faltas. A abordagem baseia-se na simulação do movimento das esferas do rolamento. Em vários outros trabalhos, diferentes estruturas de RNAs propostas

têm se mostrado eficazes na solução de problemas de detecção e isolamento de faltas em motores (CHOW, M.-Y. et al. 1993), (GOODE, P.V. & CHOW, M.Y. 1995a), (FILIPPETTI, F. et al. 1995) e (ALGUINDIGUE, I. et al. 1993).

3.3.2 Sistemas baseados em Lógica Fuzzy e Sistemas Neurofuzzy

Lógica Fuzzy é uma poderosa ferramenta que emergiu na área de Inteligência Computacional nos últimos anos. É uma extensão da Lógica Clássica, onde o conhecimento é representado próximo da maneira humana de representá-lo. O sistema de inferência fuzzy é constituído basicamente numa base de conhecimento e numa base de regras lingüística do tipo SE-ENTÃO. Dentre as aplicações deste modelo no diagnóstico de faltas em motores citam-se:

- avaliação de índices de desempenho utilizando variáveis lingüísticas;
- predição de operação anormal e localização de elementos faltosos;
- utilização da experiência de humanos representados por regras fuzzy SE-ENTÃO;
- monitoramento de sistemas, mapeamento não linear e otimização de parâmetros para sistemas de diagnóstico, através de sistemas fuzzy adaptativos;
- classificação de faltas e prognósticos.

Um sistema baseado em Lógica Fuzzy permite a transformação de termos heurísticos e lingüísticos em valores numéricos, via regras fuzzy e funções de pertinências e é capaz de aproximar relações complexas para a tarefa de diagnóstico (FILIPPETTI, F. et al. 2000). Portanto, a modelagem baseada em regras fuzzy possibilita identificar as estruturas e os parâmetros de regras fuzzy SE-ENTÃO através de um mapeamento de entradas e saídas.

Vários trabalhos encontrados na literatura apresentam implementações que otimizam o raciocínio fuzzy via estruturas de RNA. Parâmetros em sistemas fuzzy têm claro significado físico permitindo que informações lingüísticas e regras possam ser incorporadas de maneira sistemática em sistemas fuzzy adaptativos. Por outro lado, existem algoritmos importantes para treinar vários modelos de RNAs, no sentido de adaptar as dificuldades no mapeamento entre as entradas e as saídas. A idéia que orienta a fusão destas duas tecnologias é utilizar a habilidade de aprendizado das RNAs para implementar e automatizar sistemas fuzzy.

Tanto as RNAs como os sistemas fuzzy têm sido utilizados especificamente para o monitoramento de faltas em máquinas. No caso dos sistemas fuzzy, as estruturas propostas apresentam esquemas estáticos, isto é, a partir de um sistema de inferência geral formado, não é possível mudanças ao longo dos experimentos. Com a combinação de Lógica Fuzzy e RNAs, pode-se alcançar um melhor desempenho do processo de detecção e isolamento de faltas, permitindo também, a adaptação no sentido de buscar soluções mais precisas sob diferentes condições de operação. Uma metodologia detalhada é apresentada em (GOODE, P.V. & CHOW, M.Y. 1995a) e em (GOODE, P.V. & CHOW, M.Y. 1995b). Nestes trabalhos, um sistema híbrido de detecção de faltas é utilizado para monitorar condições de faltas em motores, permitindo não somente um processo mais preciso, mas também incorporando ao mesmo o raciocínio heurístico. O trabalho mostra como a informação quantitativa, obtida a partir da rede neural, pode ser utilizada para gerar informação qualitativa sobre as condições do equipamento. A Lógica Fuzzy é implementada na rede em dois estágios: funções de pertinência e regras fuzzy. O desempenho do sistema neurofuzzy é testado, utilizando um motor de indução, onde são consideradas faltas no rolamento e no enrolamento do estator e o diagnóstico é baseado na observação da corrente no estator e da velocidade do rotor.

Altug e outros (ALTUG, S. et al. 1999), apresentaram duas estruturas para detecção e isolamento de faltas em motores de indução, a FALCON proposta por (LIN, C.T. & LEE, C.G. 1991) e a estrutura ANFIS proposta por (JANG, J.R. 1993). No trabalho de Goddu e outros (GODDU, G. et al. 1998) é apresentada uma metodologia para diagnosticar faltas no rolamento do motor, a partir da análise do espectro de frequência, utilizando Lógica Fuzzy.

3.4 Considerações finais

Uma falta pode causar interrupção inesperada em uma planta industrial, com conseqüências nos custos, na qualidade do produto e na segurança. Como se observou, muitas destas situações de defeito em motores de indução trifásicos têm origem elétrica. Entre as diferentes propostas de sistemas de detecção encontradas na literatura, aquelas baseadas no monitoramento da corrente do estator para análise do espectro de corrente têm sido as mais vantajosas, devido às suas propriedades não invasivas (ACOSTA, G.G. et al. 2006). Uma outra técnica não invasiva é a aproximação extendida do vetor de Park, que permite a detecção de curto circuitos entre espiras no enrolamento do estator. O princípio seguido por estas abordagens é baseado na influência

que defeitos associados ao rotor e ao enrolamento do estator exercem na corrente do estator, que podem ser observados pelo espectro da corrente.

Embora bastante utilizado, este método de detecção enfrenta dificuldades quando a questão é classificar as faltas automaticamente, para que possam ser utilizadas com eficiência em aplicações industriais. Nesta direção, as estruturas neurais têm conseguido resultados bastante importantes, no sentido de possibilitar a construção de sistemas de monitoramento, desacoplando os ruídos e distúrbios das informações sobre faltas.

Apesar dos progressos substanciais alcançados em pesquisas relacionadas com o monitoramento das características das máquinas de indução, muitos problemas e questões, especialmente aqueles relacionados ao desenvolvimento de sistemas eficientes no diagnóstico de faltas incipientes, continuam sendo os maiores desafios. Muito se tem discutido sobre a prevenção e a detecção de faltas desta natureza em diferentes abordagens, invasivas ou não, com o propósito de, ao detectar faltas no seu estágio inicial, reduzir custos de manutenção e melhoria na eficiência dos sistemas de monitoramento.

Muitos dos métodos propostos não consideram os efeitos de um ambiente no qual as condições da fonte de alimentação não são as ideais, gerando harmônicos nos parâmetros medidos. O problema se torna mais importante em situações onde a tensão da fonte principal é desequilibrada e o valor RMS da tensão na fase altera durante todo o tempo. Além do mais, as flutuações na frequência da tensão têm considerável influência no perfil de vibração da máquina. Estas são algumas das questões que geram alarmes falsos em sistemas de monitoramento.

Existem, ainda também, diversas outras técnicas com o propósito de indentificar faltas incipientes como, por exemplo abordagens baseadas em modelo utilizando identificação e estimação de parâmetros.

Este trabalho se propõe apresentar uma alternativa de sistema de monitoramento utilizando técnicas de Inteligência Computacional, como a Lógica Fuzzy e RNAs em oposição às técnicas convencionais.

No próximo capítulo, sugere-se um sistema de detecção e isolamento de faltas no estator de máquinas de indução, e apresenta um estudo comparativo utilizando técnicas de Inteligência Computacional. O interesse pelo monitoramento do estator se deve ao percentual importante de faltas neste componente em motores de indução (vide subseção 3.2.4).

As técnicas aplicadas foram Rede Neural MLP, estruturas Fuzzy e neurofuzzy, a partir de um simulador de máquina de indução, responsável por gerar as informações necessárias para o

treinamento das estruturas neurais utilizadas e simulações necessárias. O intuito é demonstrar que o sistema proposto detecta e isola faltas incipientes, ao mesmo tempo em que se mantém insensível a ruídos e distúrbios externos.

Capítulo 4

Resultados experimentais

4.1 Considerações iniciais

*E*ste capítulo apresenta os resultados experimentais obtidos pela aplicação das técnicas de Inteligência Computacional, descritas anteriormente, ao problema de diagnóstico de faltas no estator de máquinas de indução. Esta abordagem foi utilizada tanto na geração de resíduos, quanto na sua análise para o processo de diagnóstico. Nas seções seguintes serão apresentados os vários tipos de modelos utilizados e os resultados alcançados, sintetizando ao final as situações em que foram consideradas as condições reais de funcionamento do motor.

4.1.1 Variáveis observadas

Conforme citado no capítulo anterior, podem-se observar variáveis com a finalidade de monitorar faltas em máquinas de indução. No caso específico de curtos circuito incipientes no estator das máquinas de indução, os principais efeitos destas faltas podem ser verificados através do comportamento dinâmico das correntes do sistema, tanto na amplitude quanto na defasagem em relação às respectivas tensões.

Desta forma, foram consideradas como entradas para o sistema proposto, o valor eficaz da corrente e o ângulo de defasagem entre a tensão e a corrente, em radianos elétricos, em cada uma das 3 fases, conforme ilustrado na FIG. 4.1, tendo-se assim 6 variáveis de entrada. Tais variáveis foram coletadas a uma taxa de 60 amostras por segundos, para uma tensão de entrada na frequência de 60 Hz.

Para a geração dos dados necessários aos processos de treinamento e teste dos sistemas

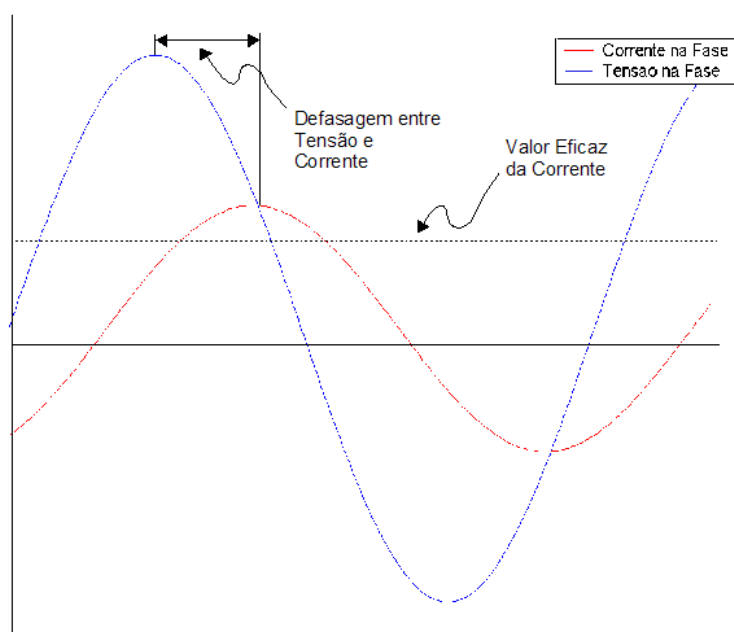


Figura 4.1: Variáveis de Entrada

de diagnóstico propostos, utilizou-se um modelo analítico da máquina de indução, conforme apresentado em (LEITE, D. F. et al. 2006) e suas referências, vide APÊNDICE A. Na síntese deste modelo, foram tomados como dados de entrada informações relativas ao valor instantâneo da tensão em cada uma das fases, considerando-se que a máquina encontrava-se conectada a um barramento infinito, e como dados de saída o valor instantâneo da corrente, também em cada uma das fases. Além disso, o modelo permitia a inserção de curto-circuitos entre espiras do enrolamento das fases, obtendo-se assim o conjunto de dados necessários aos processos de treinamento a serem implementados.

Assim sendo, um conjunto inicial de dados foi gerado com a finalidade de verificar a possibilidade de utilização de algumas técnicas, que apresentaremos neste capítulo, para diagnóstico de faltas incipientes em estator de máquinas de indução. Neste processo foram consideradas condições ideais de operação da máquina, tais como ausência de variações do sinal de tensão (distúrbios externos à máquina), bem como de ruídos de medição nos dados coletados. Foram então gerados dados relativos ao comportamento dinâmico da corrente para todas as possibilidades de condições de falta, em diversas condições de carregamento, variando de 0 (sem carga) até 1,25 (25% de carga acima da carga nominal). Os resultados de diagnóstico obtidos para

estas condições são apresentados na seção 4.2.

Após este primeiro passo, um outro conjunto de dados foi gerado com o intuito de aproximá-los um pouco mais da realidade da operação de máquinas de indução. Nesta nova situação considerou-se a possibilidade de ocorrer variações no sinal de tensão aplicada, o que em geral acontece em situações reais. Como se sabe, estas variações provocam alterações no comportamento dinâmico da corrente e, como são distúrbios externos, não devem ser diagnosticados como falta do equipamento. Entre os distúrbios externos que influenciam o diagnóstico de faltas proposto, estão o surto de tensão (aumento momentâneo da amplitude do sinal de tensão), o afundamento de tensão (redução momentânea da amplitude do sinal de tensão), e o *flicker* de tensão (oscilação da amplitude do sinal de tensão por um determinado período de tempo), conforme apresentados na (FIG. 4.2).

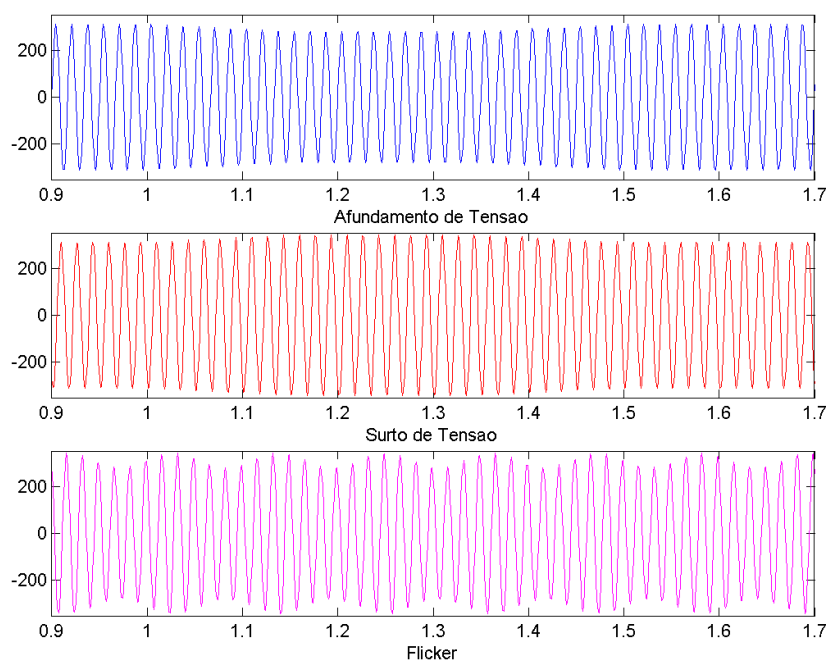


Figura 4.2: Distúrbios externos

Assim, foram gerados novos dados contendo informações da dinâmica da corrente para todas as possíveis condições de falta (0 a 3% de curto-circuito em cada uma das fases) para várias condições de carregamento e ainda para as possíveis ocorrências dos 3 tipos de distúrbios externos apresentados, podendo estes ocorrerem em uma, duas ou até mesmo nas três fases simultaneamente. Os resultados obtidos para estas condições são apresentados na seção 4.3.

Por fim, um terceiro conjunto de dados foi gerado, desta vez tomando-se condições reais de operação da máquina, para validar o método proposto para aplicações reais. Nesta situação, além dos distúrbios externos descritos anteriormente, foi ainda considerada a presença de ruídos de medições no sinal de corrente, tomados como um sinal de ruído branco aleatório, com distribuição Gaussiana e média zero.

Para verificar a aproximação destes dados à condições reais, estes foram comparados aos dados coletados a partir de um protótipo de laboratório, conforme mencionado no (APÊNDICE A). Como pode ser observado na FIG. 4.3 os dados gerados para estas condições são bem próximos dos gerados pela máquina real, possibilitando que o sistema de diagnóstico proposto, caso apresente bom desempenho para esta situação, seja indicado para possíveis utilizações em sistemas reais.

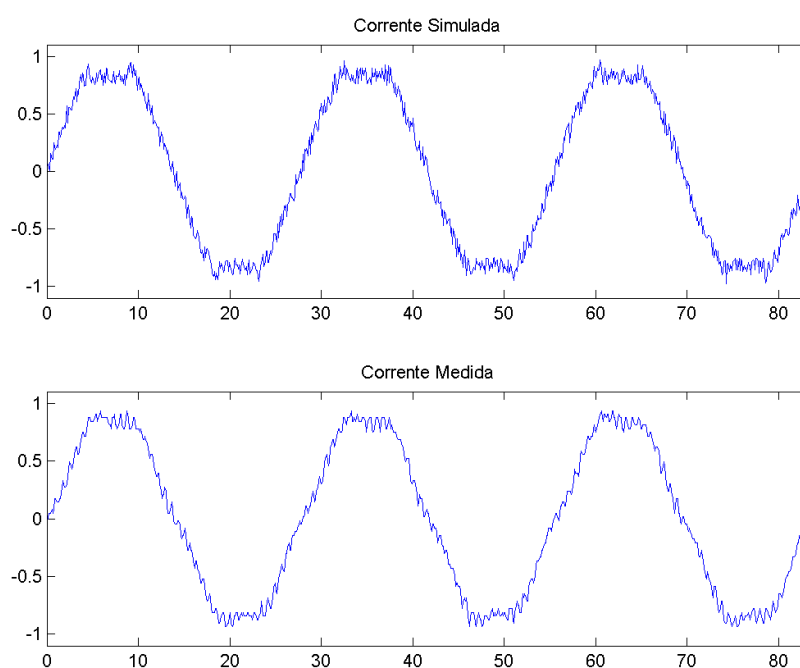


Figura 4.3: Sinal de corrente para condições reais

Mais uma vez, um conjunto de dados foi gerado e utilizado nos processos de aprendizado (treinamento) e testes dos sistemas de diagnóstico propostos por este trabalho. Os resultados para esta situação são apresentados na seção 4.4.

Vale ressaltar que os percentuais de faltas de curto circuito entre espiras, simulados neste trabalho, variam entre 0 e 3%, uma vez que se pretende diagnosticar faltas incipientes e que,

em situações reais, percentuais de curto circuito superiores a 3% já são detectadas pelos relés de proteção da máquina, tirando-a de operação.

Desta forma, várias simulações foram feitas com diversas combinações de faltas e distúrbios externos, gerando assim uma base de dados formada por 8320 amostras. Deste total, 20% foram utilizados nos processos de treinamento e o restante na validação tanto dos modelos de detecção de resíduos, como dos analisadores de faltas propostos. Os resultados obtidos são apresentados nas seções seguintes.

4.2 Sistema de Diagnóstico para Condições Ideais

Conforme mencionado anteriormente, o primeiro passo para a proposição do sistema de diagnóstico tema deste trabalho foi a análise do comportamento das máquinas de indução em condições ideais de funcionamento.

Assim sendo, para tentar identificar as faltas presentes nestes dados foi desenvolvido um protótipo inicial de sistema de diagnóstico onde os valores das variáveis observadas, descritas anteriormente, eram diretamente aplicadas aos analisadores ou identificadores de faltas, conforme pode ser visto no esquema apresentado na (FIG. 4.4).

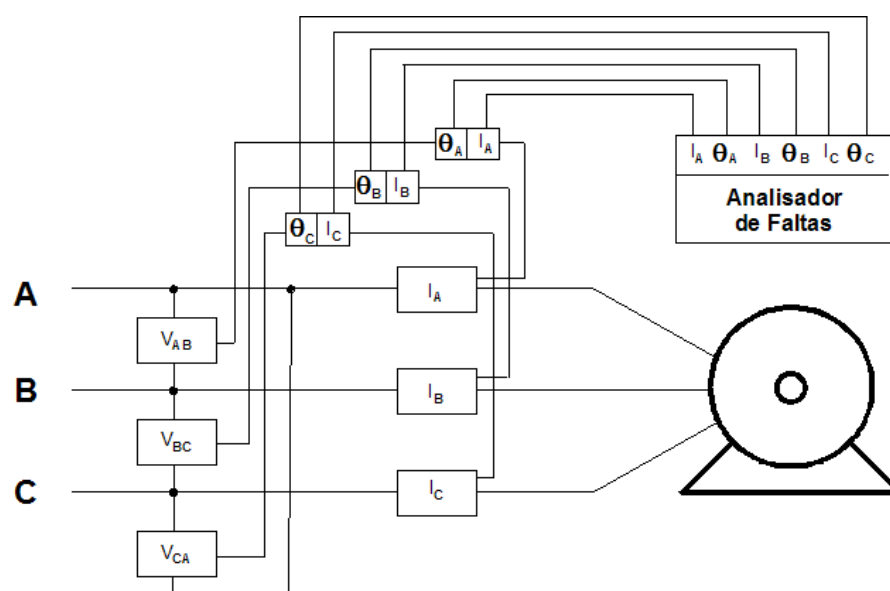


Figura 4.4: Esquema do sistema de diagnóstico em condições ideais

Como analisadores de falta, foram testados três tipos de sistemas baseados em técnicas de Inteligência Computacional. Sendo o primeiro formado por uma rede neural *multilayer perceptron*

(MLP), o segundo baseado em um sistema de inferência fuzzy (FIS) e o terceiro formado por um sistema de classificação baseado no algoritmo fuzzy c-means (FCM). Os princípios teóricos que regem estes sistemas são descritos no APÊNDICE B e as estruturas específicas que foram desenvolvidas para solucionar o problema proposto são descritas a seguir.

4.2.1 Analisador de faltas baseado em uma rede neural MLP

A escolha de rede neural MLP, baseia-se na habilidade deste tipo de sistema de aproximar qualquer função contínua não linear. A estrutura de rede MLP desenvolvida neste trabalho é apresentada na FIG. 4.5 a partir da descrição apresentada na seção B.1 do (APÊNDICE B).

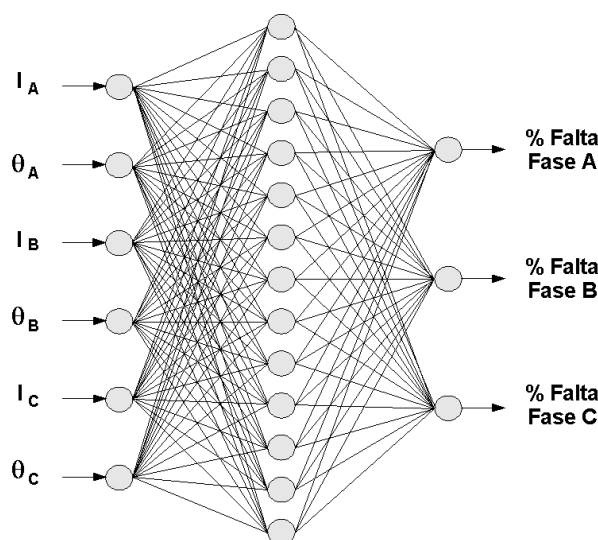


Figura 4.5: Analisador de faltas baseado em rede MLP

Verifica-se que a estrutura recebe como entrada, as variáveis a serem observadas, e gera na saída o percentual de falta em cada uma das fases. Pode-se verificar ainda que a rede MLP possui apenas uma camada intermediária, composta por 13 neurônios. Todos os neurônios desta rede possuem função de ativação do tipo logística sigmoideal, conforme apresentada na expressão 4.1.

$$f(x) = \frac{1}{1 + e^{-\alpha x}} \quad (4.1)$$

No processo de treinamento desta rede foi utilizado o algoritmo EBP. Com a finalidade de evitar que o processo de aprendizagem termine em um mínimo local raso na superfície de erro,

bem como evitar paralisias durante este processo, foram utilizadas ainda técnicas de momento e taxa de aprendizado adaptativa, respectivamente.

Este sistema foi então utilizado para identificar as faltas presentes nos dados gerados anteriormente. Os resultados obtidos neste teste são apresentados na (TAB. 4.1).

4.2.2 Analisador de faltas baseado em um sistema de inferência fuzzy

Da mesma forma que para o sistema de identificação anterior, foi desenvolvido um segundo analisador de faltas baseado em um sistema de inferência nebuloso (fuzzy) (FIS) conforme apresentado na (FIG. 4.6). O desenvolvimento deste sistema teve como propósito o tratamento da incerteza presente nos dados a serem analisados.

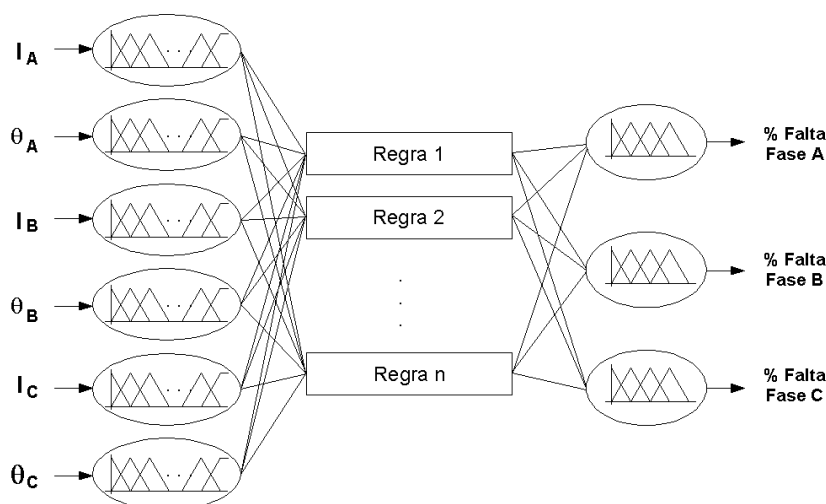


Figura 4.6: Analisador de faltas baseado em sistema de inferência FIS

No seu desenvolvimento foi utilizada a técnica de geração automática apresentada em (WANG, Li-Xin & MENDEL, J. M. 1992) e sumarizada na seção B.2 do APÊNDICE B. É possível verificar que as entradas e as saídas deste sistema são as mesmas utilizadas pelo analisador baseado na rede MLP, descrito anteriormente. Os dados utilizados nos testes deste sistema também foram os mesmos, sendo que os resultados obtido para este analisador são também apresentados na (TAB. 4.1).

4.2.3 Analisador de faltas baseado em agrupamento fuzzy

Com a finalidade de verificar se a identificação das faltas presentes nos dados analisados poderia ser tratada como um problema de classificação de padrões, desenvolveu-se um terceiro analisador de faltas baseado no agrupamento fuzzy *c-means* (FCM). Neste caso, pretendeu-se classificar os dados apresentados em um dos padrões de falta possíveis de ocorrer, conforme pode ser visto na FIG. 4.7 a partir da descrição apresentada na seção B.3 do (APÊNDICE B).

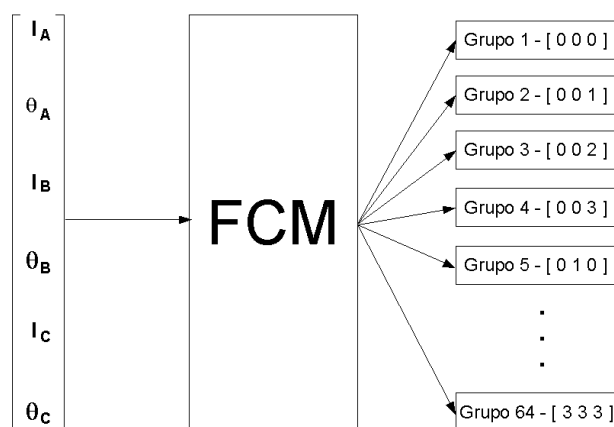


Figura 4.7: Analisador de Faltas Baseado em Agrupamento Fuzzy

É possível verificar pela FIG. 4.7 que os mesmos dados de entrada utilizados pelos sistemas anteriores foram utilizados para formar os vetores a serem agrupados pelo algoritmo FCM, sendo que os grupos de saída foram rotulados como sendo uma das possíveis condições de falta geradas. Como para cada uma das três faltas o percentual de falta poderia variar de 0 a 3%, foram obtidos um total de 64 conjuntos de saída. Mais uma vez os dados gerados anteriormente foram analisados por este sistema e os resultados obtidos também são apresentados na (TAB. 4.1)¹.

¹Nas colunas de percentuais de faltas nas fases, foram consideradas todas as combinações de faltas entre as fases, variando o intervalo de uma unidade. O mesmo critério foi utilizado nas TABELAS 4.2, 4.3, 4.4, 4.5 e 4.6

Tabela 4.1: Resultados obtidos sem observador para condições ideais

% Falta Fase A	% Falta Fase B	% Falta Fase C	Número de Amostras	MLP	FIS	FCM
0	0	0	130	92,3%	96,2%	98,5%
0	0	1-3	390	97,9%	96,7%	99,7%
0	1-3	0	390	96,9%	93,6%	99,2%
0	1-3	1-3	1170	96,0%	92,2%	99,0%
1-3	0	0	390	99,0%	95,1%	96,7%
1-3	0	1-3	1170	96,7%	93,2%	99,1%
1-3	1-3	0	1170	97,8%	92,5%	98,7%
1-3	1-3	1-3	3510	98,8%	94,6%	97,8%
TOTAIS GERAIS			8320	93,9%	97,8%	98,4%
TEMPO DE TREINAMENTO / AJUSTE (em segundos)				888,29	127,63	117,33
TEMPO DE TESTE - TODAS AS AMOSTRAS (em segundos)				0,23	85,08	71,06
TEMPO DE TESTE - AMOSTRA INDIVIDUAL (em segundos)				0,016	0,156	0,011

Observa-se que, os resultados obtidos neste passo foram significativos, indicando que o sistema de diagnóstico proposto apresenta-se como uma solução promissora para o problema proposto. Entretanto, as condições nas quais esta primeira análise foi efetuada não condiz com a realidade de operação das máquinas de indução.

Assim sendo, o próximo passo foi dado com a finalidade de aproximar um pouco mais as condições de análise às condições reais, através da introdução de sinais de distúrbios externos à máquina, conforme mencionado na seção 4.1.1. A intenção era verificar se o sistema de diagnóstico desenvolvido até aqui era imune a estes distúrbios, não diagnosticando-os como falta. O resultado obtido para este teste é apresentado na (TAB. 4.2).

Tabela 4.2: Resultados obtidos sem observador - com distúrbios externos e sem ruídos

% Falta Fase A	% Falta Fase B	% Falta Fase C	Número de Amostras	MLP	FIS	FCM
0	0	0	130	0,0%	0,8%	1,5%
0	0	1-3	390	23,6%	24,9%	27,9%
0	1-3	0	390	29,2%	28,7%	32,8%
0	1-3	1-3	1170	11,3%	10,9%	12,0%
1-3	0	0	390	25,4%	22,3%	27,4%
1-3	0	1-3	1170	10,1%	8,2%	10,5%
1-3	1-3	0	1170	14,3%	11,6%	15,0%
1-3	1-3	1-3	3510	37,6%	36,4%	38,0%
TOTAIS GERAIS			8320	24,6%	23,2%	25,4%
TEMPO DE TREINAMENTO / AJUSTE (em segundos)				888,29	127,63	117,33
TEMPO DE TESTE - TODAS AS AMOSTRAS (em segundos)				0,23	85,08	71,06
TEMPO DE TESTE - AMOSTRA INDIVIDUAL (em segundos)				0,016	0,156	0,011

Os resultados obtidos demonstram que o desempenho dos sistemas em análise diminuíram significativamente. Isso se dá, porque, alterações nas tensões de entrada da máquina causam

conseqüentes alterações nas correntes de saída e estas não foram desacopladas no processo de diagnóstico. Como alternativa escolhida para superar este problema, optou-se pela utilização de observadores no processo, conforme apresentado a seguir.

4.3 Sistema de diagnóstico considerando distúrbios externos

Com a finalidade de retirar dos dados a serem analisados a parcela referente às informações que não se relacionam com faltas internas à maquina, foi introduzido no sistema anterior um gerador de resíduos baseado em um observador analítico, isto é, uma cópia do modelo matemático do motor de indução, conforme apresentado no esquema da (FIG. 4.8).

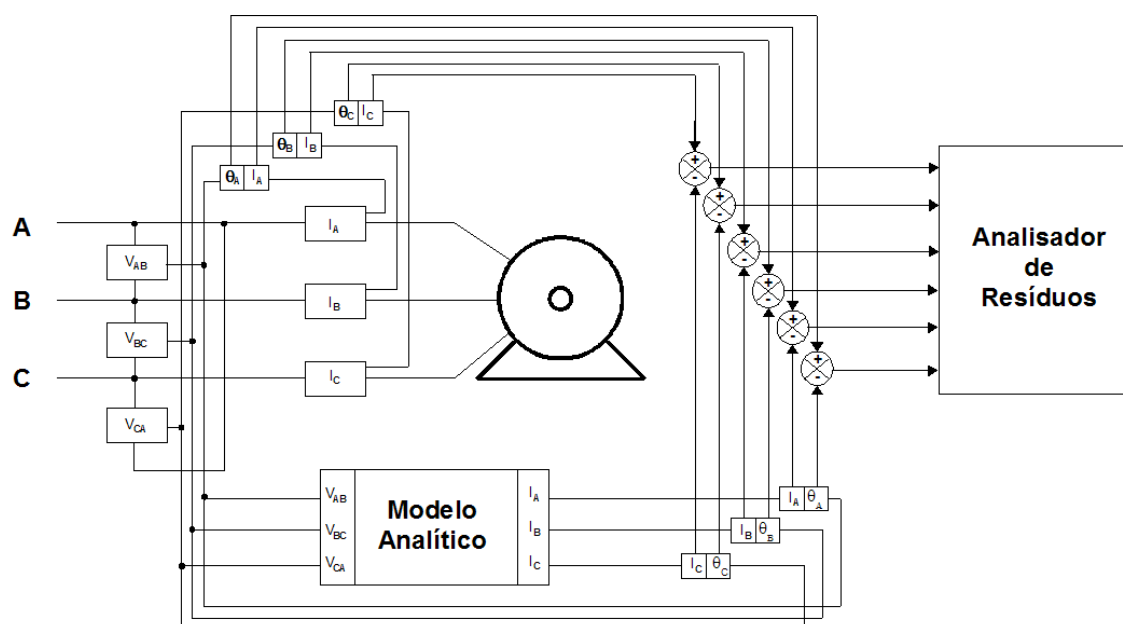


Figura 4.8: Esquema do sistema de diagnóstico considerando distúrbios externos

A idéia principal deste esquema é submeter os sinais de distúrbios externos simultaneamente à planta real e ao modelo analítico. Se a saída de ambos os sistemas responder de forma semelhante ao distúrbio externo, o resíduo é nulo. Entretanto, na ocorrência de uma falta, apenas a saída relativa ao motor real será alterada, gerando resíduos não nulos que podem ser identificados como falta.

Como analisadores de resíduos foram utilizados os mesmos sistemas apresentados como ana-

lisadores de falta na seção 4.2, sendo que agora a entrada destes sistemas não são mais os valores diretos das variáveis observadas, mas sim o resíduo gerado correspondente a estas variáveis.

Então, o segundo conjunto de dados mencionado na seção 4.1.1 foi utilizado para testar este novo sistema de diagnóstico, sendo que os resultados obtidos são apresentados na (TAB. 4.3).

Tabela 4.3: Resultados obtidos com observador - com distúrbios externos e sem ruídos

% Falta Fase A	% Falta Fase B	% Falta Fase C	Número de Amostras	MLP	FIS	FCM
0	0	0	130	93,1%	93,1%	98,5%
0	0	1-3	390	95,1%	99,2%	99,5%
0	1-3	0	390	94,6%	97,7%	99,2%
0	1-3	1-3	1170	92,9%	96,8%	99,1%
1-3	0	0	390	96,7%	98,5%	97,2%
1-3	0	1-3	1170	93,9%	97,2%	99,5%
1-3	1-3	0	1170	94,1%	97,4%	99,1%
1-3	1-3	1-3	3510	95,6%	99,1%	97,9%
TOTAIS GERAIS			8320	94,7%	98,1%	98,6%
TEMPO DE TREINAMENTO (em segundos)				469,14	128,8	115,47
TEMPO DE TESTE - TODAS AS AMOSTRAS (em segundos)				0,24	91,02	70,73
TEMPO DE TESTE - AMOSTRA INDIVIDUAL (em segundos)				0,015	0,157	0,011

Mais uma vez é possível verificar através dos resultados da TAB. 4.3 que o sistema é promissor como solução do problema proposto. Contudo ainda não é possível dizer que este sistema é o mais indicado, uma vez que as condições de análise não são as reais.

Para verificar a aplicação do sistema de diagnóstico desenvolvido a condições reais de funcionamento, gerou-se então um terceiro conjunto de dados contendo, além dos distúrbios externos, também ruídos de medição, conforme mencionado na seção 4.1.1. Estes dados foram então utilizados para testar o sistema de diagnóstico apresentado na (FIG. 4.8). Os resultados deste teste são mostrados na (TAB. 4.4).

Tabela 4.4: Resultados obtidos com observador analítico e para condições reais

% Falta Fase A	% Falta Fase B	% Falta Fase C	Número de Amostras	MLP	FIS	FCM
0	0	0	130	42,3%	54,6%	48,5%
0	0	1-3	390	37,7%	42,1%	46,9%
0	1-3	0	390	40,5%	45,4%	48,2%
0	1-3	1-3	1170	41,8%	48,2%	59,3%
1-3	0	0	390	39,2%	46,4%	43,3%
1-3	0	1-3	1170	45,0%	56,0%	49,1%
1-3	1-3	0	1170	48,0%	52,3%	50,7%
1-3	1-3	1-3	3510	44,3%	46,8%	38,4%
TOTAIS GERAIS			8320	43,8%	48,9%	45,8%
TEMPO DE TREINAMENTO / AJUSTE (em segundos)				469,14	128,8	115,47
TEMPO DE TESTE - TODAS AS AMOSTRAS (em segundos)				0,24	91,02	70,73
TEMPO DE TESTE - AMOSTRA INDIVIDUAL (em segundos)				0,019	0,157	0,012

Neste caso, houve novamente uma redução significativa no desempenho do sistema de diagnóstico ao identificar corretamente as faltas presentes nos dados. Isso se dá devido ao fato de que o modelo analítico consegue modelar o comportamento dinâmico da máquina quando distúrbios externos são adicionados a entrada, porém não modela o efeito do ruído existentes na planta real. Desta forma, quando o resíduo é gerado, este estará corrompido pelo ruído. Uma vez que as diferenças relativas entre as condições com e sem falta são muito pequenas (até 3% de falta), o ruído gerado pode ser suficiente para fornecer uma falsa indicação de falta.

Assim sendo, verificou-se a necessidade de substituir o observador analítico apresentado na FIG. 4.8 por um outro que fosse capaz de levar em consideração o efeito do ruído presente nas medidas. Optou-se então pela utilização de sistemas baseados em Inteligência Computacional que fossem capazes de simular o comportamento dinâmico real das máquinas de indução, incluindo o efeito de ruído, formando um novo sistema de diagnóstico, conforme apresentado a seguir.

4.4 Sistema de diagnóstico para condições reais

Tornou-se necessário o desenvolvimento de um novo sistema de diagnóstico de falta que fosse capaz de separar os resíduos gerados por ruídos, dos resíduos gerados por faltas internas na máquina. Essa opção justifica-se na medida em que existe a possibilidade do desenvolvimento de um modelo dinâmico baseado em observações feitas nos sinais de entrada e saída. Uma vez que estes sinais carregam também informações dos efeitos de ruídos e distúrbios externos, o

modelo gerado possibilitará identificar as faltas de forma mais precisa.

Dentre estas técnicas, as mais comumente utilizadas na modelagem de sistemas dinâmicos incluem recorrências em suas estruturas, uma vez que é necessário armazenar também a informação da dinâmica existente entre diferentes instantes de tempo.

Nesta fase, foram implementados dois sistemas recorrentes baseados em Inteligência Computacional, conforme apresentado a seguir.

4.4.1 Observador Neural - Rede de Elman

A primeira das técnicas recorrentes implementadas foi a rede recorrente de Elman, utilizada como observador, conforme pode ser visto na (FIG. 4.9).

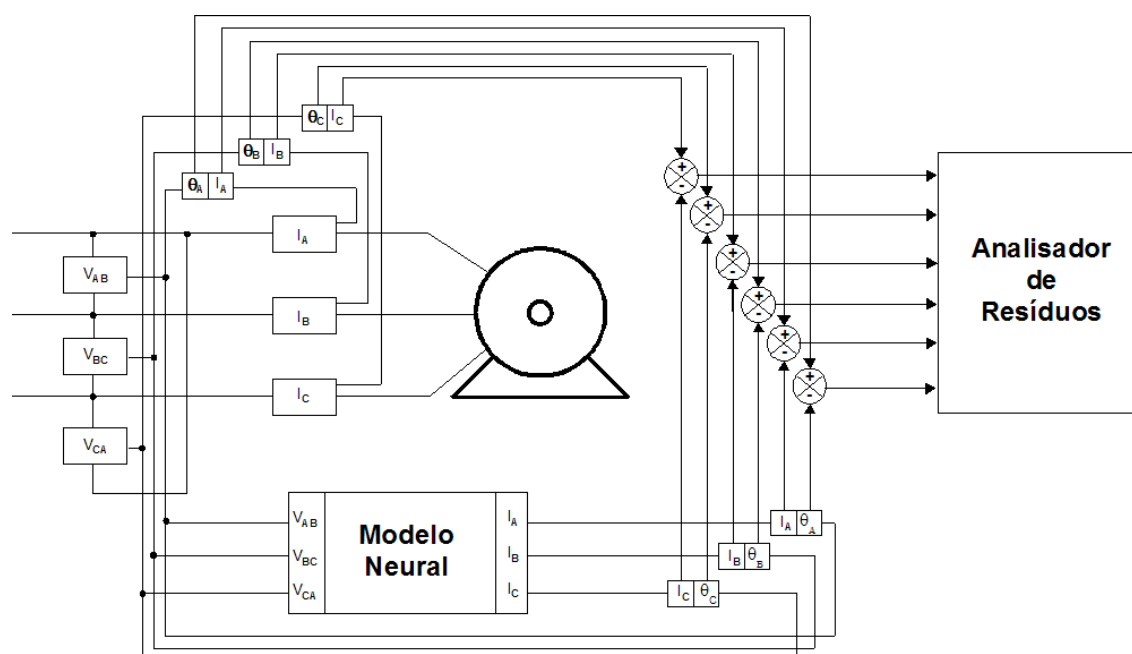


Figura 4.9: Esquema do sistema de diagnóstico para condições reais - observador neural

A base teórica utilizada na formulação deste modelo é apresentada na seção C.1 do APÊNDICE C, sendo que a estrutura da rede implementada é apresentada na (FIG. 4.10).

Este novo esquema de diagnóstico foi então testado na solução do problema proposto, sendo que os mesmos analisadores de resíduos descritos anteriormente foram também utilizados nesta fase. Os resultados obtidos são apresentados na (TAB. 4.5).

É possível verificar que o desempenho do sistema na identificação das faltas presentes nos dados aumentou significativamente, se comparado com aqueles apresentados quando da utiliza-




Figura 4.10: Observador neural de máquina de indução

Tabela 4.5: Resultados obtidos com observador neural de Elman para condições reais

% Falta Fase A	% Falta Fase B	% Falta Fase C	Número de Amostras	MLP	FIS	FCM
0	0	0	130	91,5%	98,5%	93,1%
0	0	1-3	390	90,8%	97,7%	95,4%
0	1-3	0	390	92,1%	97,2%	96,2%
0	1-3	1-3	1170	95,5%	98,3%	95,6%
1-3	0	0	390	91,0%	95,4%	94,6%
1-3	0	1-3	1170	96,5%	98,1%	96,1%
1-3	1-3	0	1170	96,8%	98,2%	95,5%
1-3	1-3	1-3	3510	96,2%	97,1%	98,2%
TOTAIS GERAIS			8320	95,5%	97,5%	96,7%
TEMPO DE TREINAMENTO / AJUSTE (em segundos)				264,26	129,59	119,54
TEMPO DE TESTE - TODAS AS AMOSTRAS (em segundos)				0,23	88,91	70,71
TEMPO DE TESTE - AMOSTRA INDIVIDUAL (em segundos)				0,0150	0,1560	0,0120
TEMPO DE TREINAMENTO / AJUSTE - MODELO NEURAL (em segundos)				3041,13		
TEMPO DE TESTE - AMOSTRA INDIVIDUAL - MODELO NEURAL (em segundos)				0,03		

ção do observador analítico. Entretanto, este novo modelo da máquina apresenta um custo computacional relativamente alto, conforme também mostra a (TAB. 4.5).

Assim, como forma de tentar reduzir o custo computacional do sistema de diagnóstico como um todo, bem como incluir no observador um método para tratamento de incertezas presentes no processo dinâmico modelado, foi implementado um segundo tipo de observador baseado em

Inteligência Computacional, apresentado a seguir.

4.4.2 Observador Neurofuzzy - Rede Neurofuzzy Recorrente

O segundo modelo recorrente utilizado neste trabalho foi baseado na rede recorrente neurofuzzy desenvolvida por BALLINI, R. & GOMIDE, F. (2002), cuja base teórica é sumarizada na seção C.2 do (APÊNDICE C). Mais uma vez esta rede foi utilizada para substituir o modelo analítico como observador no sistema de diagnóstico, formando assim o esquema apresentado na (FIG. 4.11). A estrutura específica desenvolvida é apresentada na (FIG. 4.12).

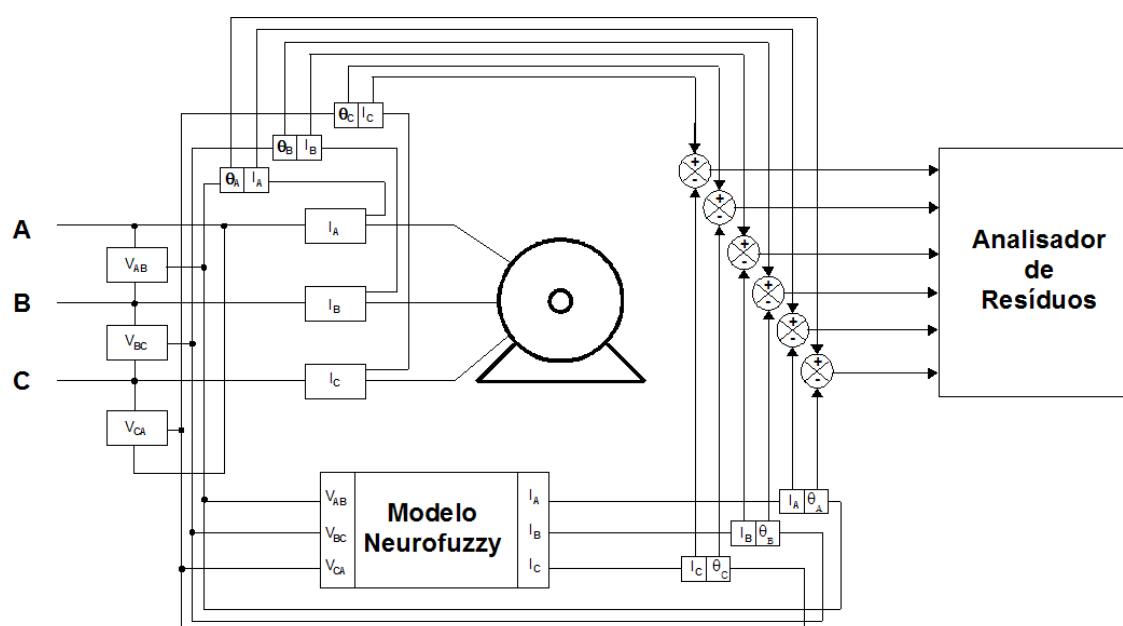


Figura 4.11: Esquema do sistema de diagnóstico para condições reais - observador neurofuzzy

Conforme feito anteriormente, este novo sistema de diagnóstico também foi utilizado na solução do problema proposto, considerando os mesmos analisadores de resíduo citados anteriormente. Os resultados para este sistema são apresentados na (TAB. 4.6).

Houve uma significativa melhoria no desempenho do sistema se comparado àquele cujo observador era formado pelo modelo analítico e ainda uma pequena melhora, se comparado ao sistema cujo observador é baseado na rede de Elman, apresentado na seção anterior.

Vale salientar que todos os sistemas de diagnósticos foram treinados e testados em um mesmo equipamento computacional, com a finalidade de se utilizar o tempo de treinamento/teste como medida de desempenho. Além disso, foram consideradas a média das medida de tempo




Figura 4.12: Observador neurofuzzy da máquina de indução

Tabela 4.6: Resultados obtidos com observador neurofuzzy para condição reais

% Falta Fase A	% Falta Fase B	% Falta Fase C	Número de Amostras	MLP	FIS	FCM
0	0	0	130	98,5%	100,0%	100,0%
0	0	1-3	390	96,7%	100,3%	96,9%
0	1-3	0	390	96,2%	99,2%	96,2%
0	1-3	1-3	1170	97,7%	99,6%	99,1%
1-3	0	0	390	96,9%	99,0%	96,7%
1-3	0	1-3	1170	97,5%	99,8%	99,4%
1-3	1-3	0	1170	97,4%	99,7%	99,0%
1-3	1-3	1-3	3510	97,9%	99,8%	99,3%
TOTAIS GERAIS			8320	97,5%	99,7%	98,9%
TEMPO DE TREINAMENTO (em segundos)				265,14	128,67	119,47
TEMPO DE TESTE - TODAS AS AMOSTRAS (em segundos)				0,24	88,88	71,01
TEMPO DE TESTE - AMOSTRA INDIVIDUAL (em segundos)				0,0150	0,1560	0,0106
TEMPO DE TREINAMENTO / AJUSTE - MODELO NEUROFUZZY (em segundos)				812,36		
TEMPO DE TESTE - AMOSTRA INDIVIDUAL - MODELO NEUROFUZZY (em segundos)				0,006		

em 10 ciclos de treinamento/teste executados, com o objetivo de minimizar a influência da condição inicial no desempenho do sistema. Na TAB. 4.6 é possível observar, nos itens 'TEMPO DE TREINAMENTO/AJUSTE - MODELO NEUROFUZZY(em segundos)' e 'TEMPO DE TESTE - AMOSTRA INDIVIDUAL - MODELO NEUROFUZZY(em segundos)', que o custo computacional na utilização do observador neurofuzzy recorrente reduziu de forma significativa, tornando este novo sistema uma opção promissora para aplicações em tempo real.

A seguir é apresentado um resumo geral de todos os sistemas de diagnósticos testados neste trabalho para facilitar a comparação dos mesmos.

4.5 Quadro geral comparativo

Os resultados apresentados na TAB. 4.7, foram os que levaram em consideração as condições reais, isto é, com ruídos brancos e distúrbios externos sobrepostos aos sinais de entrada. Eles demonstram que as estruturas baseadas em Inteligência Computacional para geração de resíduos apresentam maior robustez (vide TAB. 4.7), permitindo um diagnóstico preciso para qualquer um dos analisadores utilizados. Estes resultados mostram que o observador neurofuzzy recorrente apresenta melhor resultado que os demais observadores, seguido do observador neural rede recorrente Elman, indicando esta estrutura como adequada para construção de sistema de diagnóstico de falta em tempo real.

Tabela 4.7: Resultado geral comparativo

Tipo de Sistema de Diagnóstico		Número de Amostras	Total de Acertos	% de Acertos
Tipo de Observador	Tipo de Analisador			
Observador Clássico	FCM	8320	3811	45,81%
Observador Clássico	FIS	8320	4065	48,86%
Observador Clássico	MLP	8320	3645	43,81%
Observador Neural	FCM	8320	8044	96,68%
Observador Neural	FIS	8320	8114	97,52%
Observador Neural	MLP	8320	7943	95,47%
Observador Neuro-Fuzzy	FCM	8320	8227	98,88%
Observador Neuro-Fuzzy	FIS	8320	8298	99,74%
Observador Neuro-Fuzzy	MLP	8320	8116	97,55%

No capítulo seguinte são apresentadas algumas conclusões e discussões a respeito dos resultados obtidos neste capítulo.

Capítulo 5

Análise dos resultados de simulação

5.1 Considerações finais

*E*ste trabalho concentrou-se na discussão e proposição de um sistema de detecção e isolamento de faltas de curto circuito no enrolamento de estator em máquina de indução trifásica.

Abordagens baseadas em técnicas de Inteligência Computacional para diagnóstico de faltas têm se apresentado como uma poderosa ferramenta para detecção e isolamento de faltas, mostrando-se tão ou até mais eficientes do que as técnicas baseadas em modelos quantitativos.

Os experimentos demonstraram que, em condições ideais, os analisadores de faltas utilizados apresentaram bons resultados em relação aos percentuais de acerto. Neste passo, os geradores de resíduos não foram utilizados, mas como não estavam sendo considerados os ruídos e os distúrbios, o desempenho se manteve a contento.

No entanto, ao aproximar a simulação das condições reais, ou seja, acrescentado ruídos e/ou distúrbios, ao aspecto da robustez foi comprometido. Para superar este problema, testaram-se três tipos de observadores ou geradores de resíduos: o observador analítico, o observador baseado em uma RNA recorrente e o observador baseado em uma rede neurofuzzy recorrente.

Para a situação em que foram considerados somente os distúrbios externos, os três tipos de analisadores de faltas utilizados - o baseado em agrupamento fuzzy, o baseado em um sistema de inferência fuzzy e o baseado na Rede Neural Artificial - MLP apresentaram resultados importantes.

Ao serem considerados além dos distúrbios externos, os ruídos brancos, houve uma queda significativa nos percentuais de acertos de diagnóstico utilizando um observador analítico como

gerador de resíduos. Esta estrutura não foi capaz de desacoplar os ruídos dos sinais relativos à falta. O resultado permaneceu ruim para os três analisadores de faltas.

Com a utilização de observadores neurais e neurofuzzy, o problema foi superado, tornando os resultados mais promissores, o que permite comprovar a eficácia destas estruturas, no sentido de serem sensíveis a determinados tipos de faltas, ao mesmo tempo em que são insensíveis a ruídos brancos e distúrbios externos.

Conforme apresentado na TAB. 4.6, para as condições de monitoramento de faltas *on line* mencionadas anteriormente, os resultados a partir do esquema da FIG. 4.11 que utiliza a rede neurofuzzy recorrente mostrou ser o mais indicado, visto que o tempo de diagnóstico (16.6 mseg) é suficiente para a obtenção de um resultado de diagnóstico antes que uma nova amostra seja fornecida ao sistema (16.7 mseg/amostra). Este melhor desempenho pode ser compreendido a partir da dinâmica da própria estrutura neurofuzzy recorrente, onde apenas um determinado número de neurônios *and* estão ativos para um dado padrão de entrada. Além disso, como apenas os neurônios *and* são utilizados nos cálculos de ajuste de peso e processamento, estes tempos não dependem do número de conjuntos *fuzzy* de cada uma das entradas e conseqüentemente da dimensão da rede. Estas questões aliadas ao fato de que a regra de treinamento utilizada baseia-se na técnica de reforço associativo, torna a rede neurofuzzy mais ágil tanto nos processos de treinamento quanto no processo de saída, se comparadas às redes recorrentes clássicas.

Em síntese, os experimentos permitiram, através da utilização de várias combinações de técnicas, propor uma estrutura baseada em uma abordagem livre de modelo, um sistema de diagnóstico com as seguintes características:

- Sensibilidade para detectar faltas incipientes, na faixa de 0 a 3%, ou seja, monitorar faltas no seu estágio inicial;
- Habilidade para desacoplar ruídos brancos e distúrbios externos dos sinais residuais gerados, evitando assim falsos alarmes de faltas.

Conforme é possível verificar através dos resultados apresentados na TAB. 4.7, o melhor desempenho na solução do problema proposto foi obtido pelo sistema de diagnóstico formado pelo observador neurofuzzy e pelo analisador de resíduo baseado em um sistema de Inferência Fuzzy.

Este sistema se mostrou bastante promissor para aplicações reais, como o monitoramento

em tempo real de máquinas de indução, surgindo como uma poderosa ferramenta auxiliar na manutenção e operação de plantas industriais.

5.2 Contribuições futuras

O Sistema de diagnóstico hora estudado, pode ser estendido para outros tipos de faltas em motores de indução, a partir da utilização das características da assinatura de corrente, ampliando inclusive para o monitoramento de faltas em máquinas síncronas.

Pode-se considerar, também, a utilização deste sistema como um componente de um sistema maior de diagnóstico de faltas em equipamentos elétricos, de maneira a agrupar diversas ferramentas de diagnóstico de faltas em diversos tipos de equipamentos, tais como em máquinas síncronas, assíncronas e turbo-geradores, fornecendo uma estrutura de suporte à manutenção de equipamentos elétricos em geral.

Apêndice A

Modelo analítico do motor de indução

Projetou-se um observador para detecção de falta a partir da descrição do modelo do motor de indução sem falta. Uma cópia deste modelo foi utilizado para simular as faltas de curto circuito nas fases do enrolamento do estator. As saídas destes dois modelos são comparadas para detectar o resíduo, quando da ocorrência ou não de alguma falta. O modelo utilizado foi apresentado no trabalho de Leite (LEITE, D. F. et al. 2006) e suas referências, e é descrito a seguir.

A.1 Motor de indução sem falta

Foi considerado um motor de indução trifásico, com rotor em gaiola de esquilo, eixo magnético entre fases defasado de 120° , com N_s enrolamentos equivalentes por fase e R_s resistências por fase (KRAUSE, P.C. et al. 1995) e (SMITH, J.R. 1990).

As tensões no estator e no rotor podem ser escritas na forma de uma matriz, como em A.1 e A.2 respectivamente.

$$[V_{abcs}] = [R_s][I_{abcs}] + \frac{d[\lambda_{abcs}]}{dt} \quad (\text{A.1})$$

$$[V_{abcr}] = [R_r][I_{abcr}] + \frac{d[\lambda_{abcr}]}{dt} \quad (\text{A.2})$$

onde, as variáveis com o subscrito s e r são relativas ao estator e ao rotor, respectivamente. $[R]$ representa a matriz de resistências, $[I]$ a matriz de corrente e $[\lambda]$ a matriz do fluxo resultante no motor.

A matriz do fluxo resultante é determinada por A.3:

$$\begin{bmatrix} \lambda_{abc} \\ \lambda_{abc} \end{bmatrix} = \begin{bmatrix} L_s & L_{sr} \\ L'_{sr} & L_r \end{bmatrix} \begin{bmatrix} I_{abc} \\ I_{abc} \end{bmatrix} \quad (\text{A.3})$$

Com L_s e L_r , como as matrizes de indutância em A.4, A.5 e A.6, respectivamente.

$$L_s = \begin{bmatrix} l_{ls} + l_{ms} & -\frac{1}{2}l_{ms} & -\frac{1}{2}l_{ms} \\ -\frac{1}{2}l_{ms} & l_{ls} + l_{ms} & -\frac{1}{2}l_{ms} \\ -\frac{1}{2}l_{ms} & -\frac{1}{2}l_{ms} & l_{ls} + l_{ms} \end{bmatrix} \quad (\text{A.4})$$

$$L_r = \begin{bmatrix} l_{lr} + l_{mr} & -\frac{1}{2}l_{mr} & -\frac{1}{2}l_{mr} \\ -\frac{1}{2}l_{mr} & l_{lr} + l_{mr} & -\frac{1}{2}l_{mr} \\ -\frac{1}{2}l_{mr} & -\frac{1}{2}l_{mr} & l_{lr} + l_{mr} \end{bmatrix} \quad (\text{A.5})$$

$$L_{sr} = \begin{bmatrix} l_{sr} \cos(\theta_r) & l_{sr} \cos(\theta_r + \frac{2\pi}{3}) & l_{sr} \cos(\theta_r - \frac{2\pi}{3}) \\ l_{sr} \cos(\theta_r - \frac{2\pi}{3}) & l_{sr} \cos(\theta_r) & l_{sr} \cos(\theta_r + \frac{2\pi}{3}) \\ l_{sr} \cos(\theta_r + \frac{2\pi}{3}) & l_{sr} \cos(\theta_r - \frac{2\pi}{3}) & l_{sr} \cos(\theta_r) \end{bmatrix} \quad (\text{A.6})$$

onde l_{ls} , l_{ms} , l_{lr} , l_{mr} , l_{sr} são, respectivamente, a indutância de dispersão do estator/fase, a indutância de magnetização do estator/fase, a indutância de dispersão do rotor/fase, a indutância de magnetização do rotor/fase e a amplitude de indutâncias mútuas entre estator e rotor/fase.

Desenvolvendo o modelo, obtém-se A.7, que é a equação de estado do motor de indução.

$$[\dot{I}_{abc}sr] = [L]^{-1} [[V_{abc}sr] - [[R] + [\dot{L}]] [I_{abc}sr]] \quad (\text{A.7})$$

onde $[\dot{I}_{abc}sr]$ deve ser calculado pelo algoritmo de *Runge Kutta*. Nesta modelagem foi utilizado o algoritmo de *Runge Kutta* de quarta ordem.

O modelo do motor de indução é completado com a equação mecânica do torque eletromagnético descrita em A.8 e a equação da velocidade do rotor descrita em A.9.

$$\begin{aligned} T_e = & -\left(\frac{P}{2}\right) l_{ms} \{ [i_{as}(i'_{ar} - 0.5i'_{br} - 0.5i'_{cr}) + \\ & + i_{bs}(i'_{br} - 0.5i'_{ar} - 0.5i'_{cr}) + \\ & + i_{cs}(i'_{cr} - 0.5i'_{br} - 0.5i'_{ar})] \sin(\theta_r) + \\ & + \frac{\sqrt{3}}{2} [i_{as}(i'_{br} - i'_{cr}) + \\ & + i_{bs}(i'_{cr} - i'_{ar}) i_{cs}(i'_{ar} - i'_{br})] \cos(\theta_r) \} \end{aligned} \quad (\text{A.8})$$

onde i'_{ar} , i'_{br} e i'_{cr} são as correntes do rotor referenciadas para o estator.

$$\omega_r = \frac{P}{2} \int \frac{T_e - T_l}{J} \quad (\text{A.9})$$

onde P é o número de pólos, T_e é o torque eletromagnético, T_l é o torque de carga e J é a inércia.

A.2 Motor de indução com falta

Uma representação de curto circuitos entre espiras nas fases em um motor de indução é representado na FIG. A.1




Figura A.1: Representação de curto circuito na fase A em um motor de indução

O cálculo da indutância pode ser representado por A.10, (KRAUSE, P.C. et al. 1995).

$$L = \frac{\pi \cdot N_1 \cdot N'_2 \cdot l \cdot r}{4 \cdot g} \mu_0 \quad (\text{A.10})$$

onde N é o número efetivo de espiras no enrolamento, l é o tamanho axial do circuito magnético, r é o raio médio do circuito magnético no entre ferro, g é o tamanho do entre ferro e μ_0 a permeabilidade do ar.

Considerando-se que não há mudanças nas dimensões físicas do motor nas condições de curto circuito no estator, a indutância pode ser expressa através de A.11, A.12 e A.13 (D'ANGELO, M. F. S. V. & COSTA JR, P. P. 2000).

$$L_{(1-k)} = (1-k)^2 L \quad (\text{A.11})$$

$$L_k = k^2 L \quad (\text{A.12})$$

$$L_{k(1-k)} = k(1-k)L \quad (\text{A.13})$$

onde k é a porcentagem de curto circuito, $L_{(1-k)}$ é a indutância da parte do enrolamento da bobina sem falta, L_k é a indutância da parte do enrolamento da bobina com falta. A equação A.13 representa as indutâncias mútuas entre a parte do enrolamento da bobina com falta e a parte sem falta.

De acordo com A.11, A.12 e A.13 e considerando a possibilidade de curto circuitos nas três fases do estator, a matriz de indutância pode ser reescrita como em A.14. Quando a máquina esta sujeita a falta nas três fases simultaneamente a matriz de indutância passa da dimensão (6×6) condição normal sem falta para a dimensão (9×9) condição de falta nas três fases simultaneamente. Envolvendo indutâncias próprias e mútuas relativas ao enrolamento do estator e mútuas entre estator e rotor, e próprias e mútuas entre enrolamentos do rotor.

$$L = \begin{bmatrix} L_s & L_{sr} \\ L_{sr}^t & L_r \end{bmatrix}_{(9 \times 9)} \quad (\text{A.14})$$

onde L_s é uma matriz (6×6) , L_{sr} uma matriz (6×3) , L_{sr}^t uma matriz (3×6) e L_r uma matriz (3×3) .

Em A.14 é importante considerar que a dimensão da matriz varia em função das condições de faltas consideradas na simulação. Quando não existe falta em uma fase, a linha e coluna correspondentes a fase faltosa são eliminadas para possibilitar a inversão da matriz indutância no modelo de estado(A.7).

Desta maneira a dimensão da matriz indutância L pode ter a sua dimensão variando de (9×9) condição de curto nas três fases, para (6×6) condição sem curto nas fases.

Por exemplo, em uma bobina com falta em uma das fases, A.14 será uma matriz 7×7 . Desta maneira A.14 varia da dimensão seis para a dimensão sete (D'ANGELO, M. F. S. V. & COSTA JR, P. P. 2000).

Da mesma maneira que a matriz de indutância, a matriz de resistências é reescrita como em A.15 e A.16, onde $R_{(1-k)}$ é a resistência da parte da bobina sem falta e R_k é a resistência da parte da bobina com falta.

$$R_{(1-k)} = (1-k)R \quad (\text{A.15})$$

$$R_k = kR \quad (\text{A.16})$$

A matriz de resistências é diagonal e varia da dimensão seis até a dimensão nove, pelas mesmas razões que a matriz de indutância.

É importante salientar, que os resultados obtidos por este modelo foram comparados a um protótipo de máquina real, conforme apresentado na (FIG. A.2). Neste esquema, foi introduzido curto circuito entre espiras e feito a medição de resposta da máquina, sendo possível assim validar o modelo descritivo.




Figura A.2: Protótipo de laboratório utilizado no experimento

Apêndice B

Modelos de analisadores de faltas utilizados

Gerado o resíduo, que detecta a existência ou não de uma falta, pode-se utilizar um analisador de faltas, que tem a tarefa de indicar o seu diagnóstico. Foram utilizados como analisadores de faltas três diferentes estruturas: um analisador baseado em uma RNA MLP; um sistema de inferência fuzzy e um agrupamento fuzzy (FCM).

Nos processos de teste e validação dos analisadores propostos, inicialmente utilizou-se como entradas do sistema os dados relativos ao comportamento da corrente (valor eficaz e defasagem com relação a tensão), sem a aplicação dos observadores descritos em 4.4, com a finalidade de se comprovar a sua real necessidade. Neste caso, as saídas dos sistemas de análise foram tomadas como sendo o percentual de curto circuito entre espiras em cada uma das fases.

Após esse primeiro passo, foram introduzidos no sistema de diagnóstico os observadores clássico, neural e neurofuzzy já mencionados. Assim, os analisadores de resíduos passaram a tomar como entrada os resíduos gerados por estes observadores e como saída os mesmos percentuais de curto circuito entre fases do passo anterior.

O detalhamento dos sistemas de análise de faltas utilizados são então apresentados a seguir.

B.1 Rede neural MLP

Redes Neurais de Múltiplas Camadas são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conheci-

mento através da experiência.

Em uma rede neural de múltiplas camadas são identificadas a camada de entrada, as camadas intermediárias (ou camadas ocultas) e a camada de saída, como mostrado na (FIG. B.1).




Figura B.1: Diagrama ilustrativo de uma Rede Neural com duas camadas intermediárias

Neste 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 este sinal de entrada. Este processo é também conhecido como *feedforward*.

As redes neurais de múltiplas camadas, normalmente chamadas de *perceptrons de múltiplas camadas* (MLP's), tem sido aplicadas com sucesso para resolver diversos tipos de problemas de difícil solução, através do seu treinamento de forma supervisionada, que utiliza um algoritmo muito popular conhecido como *Algoritmo Backpropagation*, apresentado a seguir.

B.1.1 O Algoritmo *Backpropagation*

Durante o treinamento com o algoritmo *backpropagation*, a rede opera em uma seqüência de dois passos. Primeiro, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Se esta não estiver correta, o erro é calculado e 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 $\{x(n), d(n)\}$ (para $n = 1, \dots, N$), onde N é o número de amostras de treinamento contidas no conjunto, como segue:

Primeiro Passo \implies Inicialização: Caso não exista nenhuma informação prévia armazenada na rede, é necessário que os pesos sinápticos e limiares sejam iniciados a partir de uma distribuição uniforme dentro de um determinado intervalo pré-estabelecido;

Segundo Passo \implies Apresentação dos Exemplos de treinamento: Após a inicialização um *padrão de treinamento* $\{x(n), d(n)\}$, onde $x(n)$ é o vetor de entrada da rede e $d(n)$ é a resposta que se deseja obter para o estímulo $x(n)$, deve ser apresentado à rede;

Terceiro Passo \implies 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 $y_j^{(\ell)}(n)$, pode ser expressa por:

$$y_j^{(\ell)}(n) = \Phi_j \left(v_j^{(\ell)}(n) \right)$$

onde

$$v_j^{(\ell)}(n) = \sum_{i=0}^m \omega_{ji}^{(\ell)}(n) y_i^{(\ell-1)}(n)$$

e m é o número total de entradas incluindo os limiares, $\omega_{ji}^{(\ell)}(n)$ é o peso que parte da unidade i da camada $\ell - 1$ para a unidade j da camada ℓ , $y_i^{(\ell-1)}(n)$ é a saída do neurônio i na camada anterior $\ell - 1$, na iteração n e $\Phi_j(\circ)$ é a função de ativação associada ao neurônio j . Para $i = 0$, temos $y_0^{(\ell-1)}(n) = +1$ e $\omega_{j0}^{(\ell)} = b_j^{(\ell)}(n)$ que é o limiar aplicado ao neurônio j na camada ℓ ,

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

$$y_j^{(0)}(n) = x_j(n)$$

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

$$y_j^{(L)} = o_j(n)$$

Desta forma é possível calcular o sinal de erro da saída $e_j(n)$

$$e_j(n) = d_j(n) - o_j(n),$$

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

Quarto Passo \implies Propagação para trás (*Backpropagation*): Neste passo os gradientes locais da rede δ são calculados por

$$\delta_j^\ell(n) = \begin{cases} e_j^{(L)}(n)\varphi_j'(v_j^{(L)}(n)) & \text{para o neurônio } j \text{ da camada de saída } L \\ \varphi_j'(v_j^{(\ell)}(n)) \sum_k \delta_k^{(\ell+1)}(n)\omega_{kj}^{(\ell+1)}(n) & \text{para o neurônio } j \text{ na camada intermediária } \ell \end{cases}$$

onde o apóstrofe em $\varphi_j'(\circ)$ 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 segue:

$$\omega_{ji}^{(\ell)}(n+1) = \omega_{ji}^{(\ell)}(n) + \eta \delta_j^{(\ell)}(n) y_i^{(\ell-1)}(n) \quad (\text{B.1})$$

onde η é o parâmetro *taxa de aprendizagem*, que representa a quantidade de modificação dos pesos na iteração n . Quanto menor for o parâmetro da taxa de aprendizagem, menor 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. Por outro lado, se fizermos o parâmetro da taxa de aprendizagem muito grande, para acelerar o processo de aprendizagem, as grandes modificações nos pesos sinápticos resultantes podem tornar a rede instável (i.e., oscilatoria). Um método simples de aumentar a taxa de aprendizagem, evitando no entanto o perigo de instabilidade é modificar a Equação (B.1) da seguinte forma:

$$\omega_{ji}^{(\ell)}(n+1) = \omega_{ji}^{(\ell)}(n) + \alpha \left[\omega_{ji}^{(\ell)}(n-1) \right] + \eta \delta_j^{(\ell)}(n) y_i^{(\ell-1)}(n) \quad (\text{B.2})$$

onde α é usualmente um número positivo chamado de *constante de momento*. A constante de momento controla o laço realimentação que age em torno de $\omega_{ji}(n)$ (HAYKIN, S. 2001), como mostrado na FIG. B.2 , onde z^{-1} é o operador de atraso unitário.

Quinto Passo \implies Iterações: As propagações para frente e para trás, (passos 3 e 4, respectivamente) devem ser calculadas, apresentado-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.




Figura B.2: Fluxo de sinal ilustrando o efeito da constante de momento

O algoritmo *backpropagation* é o algoritmo de treinamento de Redes Neurais mais utilizado em aplicações práticas de previsão, classificação e reconhecimento de padrões em geral. Apesar do grande sucesso do *backpropagation*, existem alguns problemas inerentes à sua aplicação, tais como:

Definição do tamanho da rede: Para se definir o tamanho de uma rede neural deve-se definir o número de camadas intermediárias e o número de neurônios em cada uma dessas camadas. Estes números devem conter um compromisso entre **convergência**, que é a capacidade da Rede Neural de aprender todos os padrões do conjunto de treinamento, e **generalização**, que é a capacidade de responder corretamente à padrões nunca vistos.

Se a rede neural for pequena, não será capaz de armazenar todos os padrões necessários, por outro lado se a rede for muito grande (muitos parâmetros = pesos), esta poderá não responder corretamente aos padrões nunca vistos.

Uma forma de se resolver este problema é a utilização da métrica de Hecht-Nielsen (HECHT-NIELSEN, R. 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 esta métrica, a camada oculta deve ter por volta de $2n + 1$ neurônios, onde n é o número de variáveis de entrada.

Problema de paralisia da Rede Neural: Com o treinamento, os pesos (ω_{ji}) podem alcançar

valores muito altos. Com isso, a soma ponderada de cada processador torna-se também muito alta, uma vez que $\mathbf{v}_j^{(l)}(n) = \sum_{i=0}^m \omega_{ji}^{(l)}(n)y_i^{(l-1)}(n)$. Aplicando-se uma função de ativação não-linear $\varphi(\mathbf{v}_j^{(l)}(n))$ logística, a saída dos neurônios aproximam-se de zero, conforme mostrado na (FIG. B.3). Assim, a derivada da função de transferência $\varphi'(\mathbf{v}_j^{(l)}(n))$ e conseqüentemente a correção dos pesos (ver Equação (B.2)), também se aproximam de zero, fazendo com que a rede pare de "aprender".

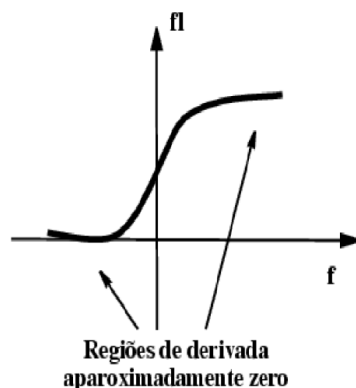


Figura B.3: Exemplo de Função de Ativação

Para resolver o problema de paralisia da rede, é necessário escolher valores iniciais de pesos e limiares uniformemente distribuídos dentro de um intervalo pequeno. Um intervalo muito usado para a inicialização dos pesos com a finalidade de evitar este problema é o intervalo entre $[-0.1,+0.1]$.

Problema de Mínimos Locais: Com a utilização de uma taxa de aprendizagem η muito pequena na Equação (B.2), não é possível calcular uma variação de pesos que faça a Rede Neural sair de um Mínimo Local, conforme apresentado na FIGURA B.4, não atingindo a performance desejada (erro mínimo a ser atingido).

Por outro lado, com a utilização de taxas de aprendizagem muito grandes, a Rede Neural pode nunca conseguir chegar ao Mínimo Global pois as variações nos pesos se tornam muito grandes, gerando instabilidade no processo de treinamento.

Para resolver este problema, é possível utilizar uma taxa de aprendizagem η *adaptativa*. Neste processo o valor de η é inicialmente fixado como um valor alto (próximo de 1) e depois reduzido gradativamente de acordo com a com a convergência do erro.




Figura B.4: Problema de Mínimos Locais

B.2 Sistema de inferência fuzzy (FIS)

Nesta abordagem a máquina de inferência utilizada foi baseada no trabalho de Wang e Mendel (WANG, Li-Xin & MENDEL, J. M. 1992) e suas referências.

Supondo que um dado conjunto de dados de entrada e saída desejados seja:

$$(x_1^{(1)}, x_2^{(1)}; y^{(1)}), (x_1^{(2)}, x_2^{(2)}; y^{(2)}), \dots \quad (\text{B.3})$$

onde x_1 e x_2 são as entradas e y é a saída. Este caso simples de duas entradas e uma saída foi escolhido para explicar o mecanismo de inferência utilizado, visando facilitar o entendimento da abordagem aqui apresentada. O detalhamento será apresentado nos passos a seguir.

B.2.1 Passo 1 - Divisão dos espaços de entrada e saída em regiões fuzzy

Assumindo que os intervalos dos domínios de x_1 , x_2 e y são $[x_1^-, x_1^+]$, $[x_2^-, x_2^+]$ e $[y^-, y^+]$, respectivamente.

Dividindo cada intervalo de domínio em $2N$ regiões (N pode ser diferente para diferentes variáveis e os tamanhos destas regiões podem ser iguais ou não), denotado por SN (N Pequeno), \dots , $S1$ (1 Pequeno), CE (Centro), $B1$ (1 Grande), \dots , BN (N Grande) e nomeando para cada região uma função de pertinência. A FIG. B.5 ilustra o intervalo de domínio de x_1 dividido em 5 regiões ($N = 2$), intervalo de domínio de x_2 dividido em 7 regiões ($N = 3$) e o intervalo de

domínio de y dividido em 5 regiões ($N = 2$). A forma de cada função de pertinência é triangular; um vértice se encontra no centro da região e tem pertinência igual a 1; os outros dois vertices encontram-se nos centros de duas regiões vizinhas, respectivamente, com pertinências iguais a zero.




Figura B.5: Divisão dos espaços de entrada e saída em regiões fuzzy e as correspondentes funções de pertinência. (a) $m(x_1)$, (b) $m(x_2)$ e (c) $m(y)$

B.2.2 Passo 2 - Geração das regras fuzzy a partir dos pares de dados

Primeiro, determinando os graus de pertinência dos dados $x_1^{(i)}$, $x_2^{(i)}$ e $y^{(i)}$ em diferentes regiões. Por exemplo, $x_1^{(i)}$ na FIG. B.5 tem grau de pertinência igual a 0.8 em $B1$, o grau 0.2 em $B2$ e grau zero em todas as outras regiões. Similarmente, $x_2^{(2)}$ na FIG. B.5 tem grau de pertinência igual a 1 em todas as outras regiões.

Segundo, associando um dado $x_1^{(i)}$, $x_2^{(i)}$ ou $y^{(i)}$ para a região, com grau máximo. Por exemplo, $x_1^{(i)}$ na FIG. B.5 é considerado para $B1$ e $x_2^{(i)}$ para CE .

Finalmente, obtendo uma regra para o par de dados de entrada e saída desejado,
 $(x_1^{(1)}, x_2^{(1)}; y^{(1)}) \Rightarrow [x_1^{(1)}(0.8 \text{ em } B1, \text{max}), x_2^{(1)}(0.7 \text{ em } S1, \text{max}); y^{(1)}(0.9 \text{ em } CE, \text{max})] \Rightarrow$

Regra 1 : Se x_1 é B1 e x_2 é S1, ENTÃO y é CE;

$(x_1^{(2)}, x_2^{(2)}; y^{(2)}) \Rightarrow [x_1^{(2)}(0.6 \text{ em } B1, \text{max}), x_2^{(2)}(1 \text{ em } CE, \text{max}); y^{(2)}(0.7 \text{ em } B1, \text{max})] \Rightarrow$

Regra 2: Se x_1 é B1 e x_2 é CE, ENTÃO y é B1.

As regras geradas são do tipo *and*, isto é, todas as condições do antecedente têm que ser validadas para confirmar o seu conseqüente.

B.2.3 Passo 3 - Associação de um grau para cada regra

Normalmente existirão muitos pares de dados e cada par gerará uma regra, o que poderá proporcionar regras contraditórias, isto é, regras com o mesmo antecedente mas com conseqüentes diferentes.

Uma maneira de solucionar este conflito é associar um grau a cada regra gerada a partir de seus pares de dados, aceitando somente a regra de um grupo em conflito que tenha grau máximo. Desta maneira, reduz-se não somente o conflito, mas permite também uma redução significativa no número de regras.

Usou-se a seguinte estratégia para associar um grau a cada regra: para a regra SE x_1 é A e x_2 é B, ENTÃO y é C, o grau desta regra, denotado por $D(\text{Regra})$, é definido como

$$D(\text{Regra}) = m_A(x_1)m_B(x_2)m_C(y) \quad (\text{B.4})$$

como exemplo, a regra 1 tem grau

$$D(\text{Regra 1}) = m_{B1}(x_1)m_{S1}(x_2)m_{CE}(y) \quad (\text{B.5})$$

$$= 0.8 \times 0.7 \times 0.9 = 0.504 \quad (\text{B.6})$$

(vide FIG. B.5) e a regra 2 tem grau

$$D(\text{Regra 2}) = m_{B1}(x_1)m_{CE}(x_2)m_{B1}(y) \quad (\text{B.7})$$

$$= 0.6 \times 1 \times 0.7 = 0.42 \quad (\text{B.8})$$

Na prática, sempre se tem alguma informação a priori sobre um determinado par de dados. Por exemplo, se um especialista opinar sobre alguns pares de dados, poderá sugerir que alguns são relevantes, outros são muito improváveis de ocorrer e podem ter sua origem em erros de medição. Ao se atribuir um grau a um par de dados, esta-se representando a crença quanto a capacidade de figurar uma determinada circunstância. Desta forma, os pares de dados constituem um conjunto fuzzy, definido a partir de medições úteis; um par de dados pertence a este conjunto fuzzy com um grau associado pelo especialista humano.

Supondo que um par de dados $(x_1^{(1)}, x_2^{(1)}; y^{(1)})$ tenha grau $m^{(1)}$, então se é o grau da regra 1 como

$$D(\text{Regra } 1) = m_{B1}(x_1)m_{S1}(x_2)m_{CE}(y) = m^{(1)} \quad (\text{B.9})$$

isto é, o grau de uma regra é definido como o produto dos graus de seus componentes ou o grau dos pares de dados que geraram esta regra.

B.3 Agrupamento fuzzy (FCM)

Análise de agrupamento é a tarefa de classificar dados em certas categorias, dependentes de certas características, e tem sido uma ferramenta muito utilizada em várias áreas de conhecimento. Esta abordagem divide os problemas altamente complexos em vários sistemas relativamente simples, obtendo como resultado menos desperdício de recursos computacionais, de esforço de análise ou de transformação dos dados.

Tradicionalmente os métodos de agrupamento associam cada objeto de estudo em um certo grupo. Todavia, um determinado dado pode ser reconhecido como pertencente a mais de um grupo. Utilizando a teoria de conjunto fuzzy, a classificação pode considerar estes aspectos possibilitando uma análise mais representativa dos sistemas reais. O algoritmo de agrupamento fuzzy, foi inicialmente proposto por Dunn (DUNN, J. 1973) e depois generalizado por Bezdek (BEZDEK, J. & HATHAWAY, R. 1988) e outros autores.

Este foi o algoritmo utilizado para classificar os dados de saída do simulador da máquina de indução, agrupando-os de maneira a possibilitar a análise dos resíduos gerados. A seguir far-se-á uma descrição sucinta do algoritmo, de acordo com o trabalho de Nascimento e outros (NASCIMENTO, S. et al. 2000) e suas referências.

Considerando $X = x_1, \dots, x_n$ como os dados obtidos, onde cada ponto $x_k (k = 1, \dots, n)$ é um vetor em \mathfrak{R}^P , U_{cn} como um conjunto de valores reais representado por uma matriz $c \times n$ e c um inteiro, $2 \leq c \leq n$. Então, a partição fuzzy no espaço de X é o conjunto

$$M_{fcn} = \left\{ U \in U_{cn} : u_{ik} \in [0, 1] \sum_{i=1}^c u_{ik} = 1, \quad 0 < \sum_{k=1}^n u_{ik} < n \right\} \quad (\text{B.10})$$

onde u_{ik} é o valor de pertinência de x_k no agrupamento $i (i = 1, \dots, c)$.

O objetivo do algoritmo de agrupamento é encontrar a partição fuzzy ótima e os correspondentes protótipos, minimizando a função objetivo B.11

$$J_m(U, V; X) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m \|x_k - v_i\|^2 \quad (\text{B.11})$$

Em B.11, $V = (v_1, v_2, \dots, v_c)$ é a matriz centros de agrupamentos desconhecidos $v_i \in \mathfrak{R}^P$, $\|\cdot\|$ é a norma Euclidiana e o expoente de peso m no intervalo de $[1, \infty)$ é uma constante que influencia os graus de pertinência.

Apêndice C

Modelos de observadores utilizados

C.1 Modelo qualitativo utilizando RNA

Utilizou-se nesta estrutura um observador neural, baseado em uma Rede Neural Elman, descrito a seguir (HELL, M. et al. 2006).

A base deste tipo de estrutura é composta por quatro camadas: a camada de entrada, a camada escondida, a camada de contexto e a camada de saída, como descrito na FIG. C.1. Conectando cada duas camadas vizinhas, existem pesos ajustáveis. Geralmente, isto é considerado como um tipo especial de RNA *feedforward*, com neurônios de memória adicionais e retroalimentação local (SASTRY, P.S. et al. 1994).

As autoconexões no contexto da Rede Neural Elman torna-a sensível ao histórico dos dados de entrada, muito usuais em sistemas dinâmicos (NARENDRA, K.S. & PARTHASARATHY, K. 1990).

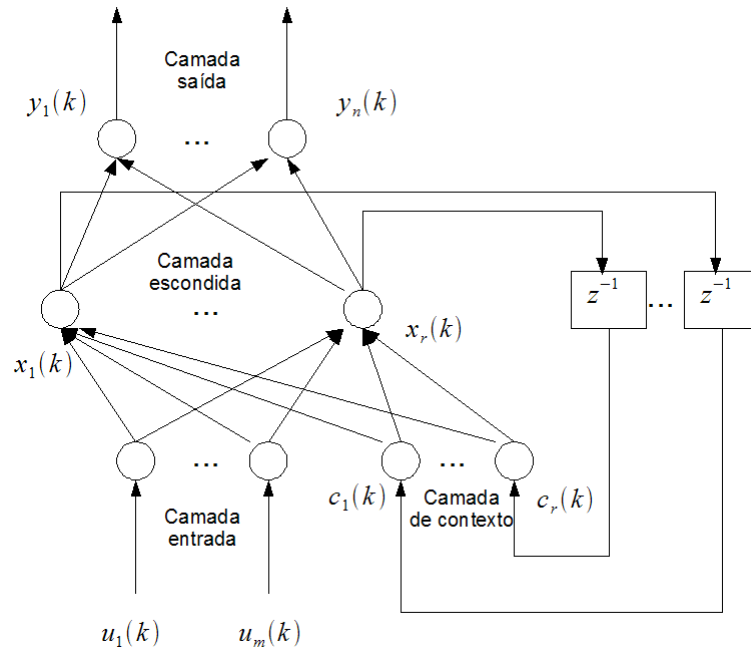


Figura C.1: Estrutura da rede Elman

A notação utilizada nesta seção é dada a seguir:

$W1_{ij}$ = Os pesos que conectam os nodos na camada de entrada aos nodos j na camada escondida.

$W2_{jq}$ = Os pesos que conectam os nodos j na camada escondida aos nodos q na camada de saída.

$W3_{lj}$ = Os pesos que conectam os nodos l da camada de contexto aos nodos j da camada escondida.

m, n, r = Os números de nodos nas camadas de entrada, saída e escondidas respectivamente.

$u_i(k), y_j(k)$ = Entradas e saídas da rede Elman, onde, $i = 1, \dots, m$ and $j = 1, \dots, n$.

$x_i(k)$ = Saída dos nodos $i = 1, \dots, r$, da camada escondida.

$c_i(k)$ = Entrada dos nodos i , da camada de contexto, isto é, a saída do nodo i da camada escondida no tempo anterior.

z^{-1} = Uma unidade de atraso.

Para cada unidade da camada escondida, uma unidade adicional chamada unidade de contexto é incluída. A unidade de contexto é conectada a todos os nodos da camada escondida, em um esquema de retroalimentação. Isto significa que existe um peso para todas as unidades

da camada de contexto. Além disso, existem conexões recorrentes de cada unidade da camada escondida para as unidades de contexto.

Os pesos das conexões recorrentes são fixos e os pesos para frente começam o treinamento utilizando retropropagação. Na fase para frente, as unidades de contexto comportam-se como unidades de entrada. Começa-se calculando os valores das unidades escondidas e das unidades de saída da mesma forma que nas redes *feedforward*. Após o cálculo das saídas das unidades escondidas, os valores atuais começam copiando as unidades de contexto correspondentes, através das conexões recorrentes (com uma unidade de atraso). Estes valores são utilizados no tempo seguinte. No início, eles têm um conjunto de valores. Durante a fase de retrocesso do treinamento, os valores desejados para as saídas são utilizados e os pesos para frente são ajustados pela retropropagação.

As entradas da rede são: $u(k) \in \mathfrak{R}^m$, $y(k) \in \mathfrak{R}^n$, $x(k) \in \mathfrak{R}^r$, as saídas de cada camada pode ser representada como descrito na equação C.1:

$$\begin{aligned} x_j(k) &= f \left(\sum_{i=1}^m w1_{ij}u_i(k) + \sum_{l=1}^r w3_{lj}c_l(k) \right) \\ c_l(k) &= x_j(k-1) \\ y_q(k) &= g \left(\sum_{j=1}^r w2_{jq}x_j(k) \right) \end{aligned} \tag{C.1}$$

onde, $f(\bullet)$ e $g(\bullet)$ são as funções linear e não linear de saída da camada escondida e da camada de saída, respectivamente.

C.2 Redes Neurofuzzy Recorrentes - abordagem híbrida

As redes recorrentes são estruturas neurais com um ou mais laços de realimentação, mais adequadas para modelar sistemas dinâmicos e não necessitam da utilização das linhas de atraso externa, como é o caso das redes "*feedforward*". Elas empregam muito mais esforço computacional para serem implementadas e treinadas, tendo em vista a utilização interna de valores de sinais passados. Neste tipo de estrutura, cada padrão ativado na entrada passa através da rede mais de uma vez antes de ser gerada a saída (FIG. C.2).

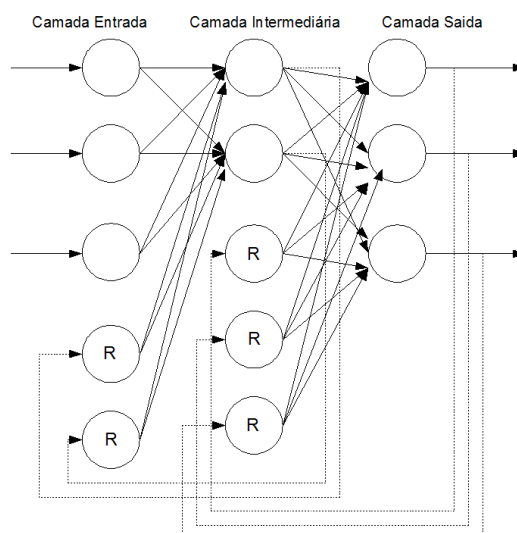


Figura C.2: Rede Neural Recorrente

C.2.1 Estrutura da Rede Neurofuzzy Recorrente

A estrutura da rede recorrente contém duas partes, um sistema de inferência fuzzy e uma RNA clássica compondo uma estrutura neural híbrida (FIG. C.4). Esta estrutura e o processo de aprendizagem, resumidos abaixo, são apresentados em (BALLINI, R. & GOMIDE, F. 2002) e suas referências.

O sistema de inferência é composto pelas camadas de entrada e intermediária. A camada de entrada consiste de neurônios cujas funções de ativação são as funções de pertinência dos conjuntos fuzzy, que formam a partição do espaço de entrada. Para cada dimensão $x_i(t)$ do vetor de entrada n -dimensional $\mathbf{x}(t)$, existem N_i conjuntos fuzzy $A_i^{k_i}, k_i = 1, \dots, N_i$, cujas funções de pertinência são as correspondentes funções de ativação dos neurônios da camada de entrada. A variável t denota o tempo discretizado, isto é, $t = 1, 2, \dots$ e será omitida para simplificar a notação. Deste modo, os graus de pertinência associados aos padrões de entrada são $a_{ji} = \mu_{A_i^{k_i}}(x_i)$, $i = 1, \dots, n$ e $j = 1, \dots, M$; onde M é o número de neurônios da camada intermediária, que por sua vez depende do número de nós de entrada ativados, ou seja, $M = f(k_i)$. A FIG. C.3, mostra porque o número de entradas de neurônios da camada intermediária não é igual ao números de partições de x_i .




Figura C.3: Relação da camada intermediária com os nós de entradas




Figura C.4: Rede neurofuzzy recorrente

Os neurônios da camada intermediária são neurônios lógicos do tipo *and* (FIG. C.5), cujas entradas a_{ji} são ponderadas pelos pesos w_{ji} , e as conexões de realimentação são ponderadas pelos pesos $r_{jl}, l = 1, \dots, M$. Os neurônios lógicos são implementados utilizando as normas triangulares, isto é, o operador *and* é representado por uma t -norma e o operador *or* representado por uma s -norma; diversas definições destas normas encontram-se em (PEDRYCZ, W. & GOMIDE, F. 1998).

Dado que as normas trabalham só com valores no intervalo $[0, 1]$, tanto os pesos w_{ji} como os graus de pertinência a_{ji} , devem pertencer ao intervalo $[0, 1]$ produzindo, assim, um mapeamento não-linear $[0, 1]^n \rightarrow [0, 1]$. A função de ativação Ψ_{and} do neurônio *and* (FIG. C.5), é assumida como a função identidade, ou seja $\Psi_{and}(u) = u$, podendo ser em geral um mapeamento não-linear. Além disso, e sem perda de generalidade, é assumida uma única saída para a rede clássica de agregação.




Figura C.5: Neurônio lógico recorrente

Assumindo $a_{jn+l} = q^{-1}z_j$, onde q^{-1} é o operador de atraso e $w_{jn+l} = r_{jl}, l = 1, \dots, M$, então a estrutura da rede gera um conjunto de regras do tipo *se-então* $R = \{R_j, j = 1, \dots, M\}$ da forma:

- R_j : Se $(x_1 \text{ é } A_1^{k_1} \text{ com certeza } w_{j1}) \dots$
 e $(x_i \text{ é } A_i^{k_i} \text{ com certeza } w_{ji}) \dots$
 e $(x_n \text{ é } A_i^{k_n} \text{ com certeza } w_{jn})$
 então, z é z_j com certeza v_j .

onde $z_j = \mathbf{T}_{i=1}^{n+M} (w_{ji} \mathbf{s} a_{ji})$. Portanto, existe uma dualidade entre esta parte da rede e um sistema

de inferência fuzzy baseado em regras. A segunda parte é uma rede neural clássica, composta por um neurônio de agregação não recorrente, onde a saída y é calculada pela agregação das entradas z_j e os pesos $v_j, j = 1, \dots, M$.

A dinâmica da rede neurofuzzy pode ser resumida da seguinte maneira:

1. N_i é o número de conjuntos fuzzy que constitui a partição da i -ésima entrada;
2. $a_{ji} = \mu_{A_i^{k_i}}(x_i)$ é o grau de pertinência de x_i no conjunto fuzzy $A_i^{k_i}$, sendo a_{ji} a entrada para o neurônio j da camada intermediária;
3. z_j é a j -ésima saída da camada intermediária:

$$z_j = \mathbf{T}_{i=1}^{n+M} (w_{ji} \mathbf{s} a_{ji}) \quad (\text{C.2})$$

4. y é a saída da rede dada por:

$$y = \Psi(u) = \Psi \left(\sum_{j=1}^M (v_j \cdot z_j) \right) \quad (\text{C.3})$$

onde $\Psi: \mathfrak{R}^{n+M} \rightarrow [0, 1]$ é uma função monotonicamente crescente que, neste trabalho, está sendo considerada como: $\Psi(u) = 1/(1 + \exp(-u))$;

5. w_{ji} é o peso entre o j -ésimo neurônio *and* e o i -ésimo neurônio da camada de entrada;
6. v_j é o peso entre a saída y da rede e o j -ésimo neurônio *and*;
7. r_{jl} é o peso da conexão recorrente entre o j -ésimo neurônio *and* e o l -ésimo neurônio da mesma camada;

A arquitetura apresentada tem como vantagens a geração automática da topologia da rede, flexibilidade quanto à utilização de diversas normas triangulares e a possibilidade de extração de regras diretamente da topologia (BALLINI, R. & GOMIDE, F. 2002).

Processo de Aprendizagem

Dois conceitos diferentes são utilizados para o ajuste dos pesos: aprendizagem por reforço associativo para os pesos w_{ji} e r_{jl} , e o método do gradiente para os pesos v_j . O algoritmo de aprendizagem é descrito a seguir:

1. Geração das funções de pertinência;
2. Inicialização dos pesos;
3. Até satisfazer a condição de parada:
 - 3.1 Apresentar um padrão \mathbf{x} à rede, geralmente escolhido aleatoriamente;
 - 3.2 Efetuar a fuzzificação;
 - 3.3 Determinar os neurônios *and* ativos;
 - 3.4 Atualizar os pesos w_{ji}, r_{jl} e v_j ;
 - 3.5 Testar a condição de parada (máximo erro permitido ou número máximo de iterações).

detalha-se, a seguir, cada um dos passos desse algoritmo.

Geração das Funções de Pertinência

As funções de pertinência são definidas como funções triangulares normais e complementares dentro do intervalo $[x_{imin}, x_{imax}]$, $i = 1, \dots, n$. Dado que é possível uma concentração de dados não uniforme na região de x_i , é adequado assumir uma partição não uniformemente distribuída.

Para gerar a partição, técnicas de agrupamento para determinar os centros c_{ir} , $r = 1, \dots, N_i$ são necessárias. O algoritmo de agrupamento utilizado neste trabalho é baseado na rede neural auto-organizada, com algoritmo de treinamento LVQ.

Uma vez determinados os centros $c_{ir}, i = 1, \dots, n$ e $r = 1, \dots, N_i$, onde N_i é o número de funções de pertinência para a entrada x_i , os graus de pertinência $\mu_{A_r^i}(x_i)$ são avaliadas para cada padrão de entrada \mathbf{x} .

Inicialização dos Pesos

Os pesos w_{ji}, r_{jl} e v_j para $i = 1, \dots, n$; $j = 1, \dots, M$; $l = 1, \dots, M$ são inicializados aleatoriamente com valores no intervalo $[0, 1]$.

Determinação dos Neurônios *and* Ativos

Para cada componente do padrão de entrada \mathbf{x} existe no máximo dois subconjuntos fuzzy com graus de pertinência diferentes de zero, denominados conjuntos ativos que, por sua vez, definem os neurônios *and* ativos.

Dado um padrão $\mathbf{x} = (x_1, \dots, x_i, \dots, x_n)$, o número de neurônios *and* ativos são encontrados combinando os índices da função de pertinência para os quais os graus de pertinência são diferentes de zero.

Assim, de M neurônios *and*, no máximo 2^n estarão ativos para cada padrão apresentado à rede. Como apenas os neurônios *and* ativos são considerados nos processos de treinamento e utilização da rede, o tempo de processamento é independente do número de conjuntos fuzzy da partição do espaço de entrada (BALLINI, R. & GOMIDE, F. 2002).

Fuzzificação

Nesta etapa, são calculados os graus de pertinência para os subconjuntos ativos definidos em K^1 para os padrões de entrada. No caso em que $k_i^1 \neq k_i^2$, tem-se $\mu_{k_i^2}(x_i) = 1 - \mu_{k_i^1}(x_i)$, devido à complementaridade das funções de pertinência.

Atualização dos Pesos

O método do gradiente é utilizado para ajustar os pesos da rede neural clássica v_j , enquanto os pesos do sistema de inferência fuzzy e os pesos da realimentação pertencentes à camada intermediária são ajustados utilizando o treinamento por reforço associativo. O primeiro passo é avaliar a saída da rede para um dado padrão de entrada, utilizando as equações (C.2) e (C.3), isto é, calcular as saídas de cada neurônio em cada camada da rede. O objetivo do processo de treinamento supervisionado é minimizar o erro entre a saída atual da rede e a saída desejada, para cada padrão de entrada. Isto é, minimizar:

$$\varepsilon = \frac{1}{2}(y - \hat{y})^2 \quad (C.4)$$

onde \hat{y} é o valor da saída no instante t e y é a saída desejada para o correspondente padrão \mathbf{x} . Assim, se v_j é um peso conectado à unidade de saída, tem-se:

$$\Delta v_j = \eta(y - \hat{y})\psi'(u)z_j \quad (C.5)$$

onde $\psi'(u) = \psi(u)(1 - \psi(u))$ é a derivada da função de ativação avaliada em u , e η é a taxa de aprendizado.

Atualizam-se os pesos da camada intermediária utilizando aprendizado por reforço, isto é, o treinamento destes depende do valor de um sinal de reforço. Conforme apresentado

em (BALLINI, R. & GOMIDE, F. 2002), um sinal de reforço $\delta = 1 - \varepsilon$ é adotado. Assim, os pesos das unidades intermediárias são atualizados da seguinte forma:

$$\Delta w_{ji} = \delta \alpha_1 [1 - w_{ji}] - (1 - \delta) \alpha_2 w_{ji} \quad (\text{C.6})$$

$$\Delta r_{jl} = \delta \alpha_3 [1 - r_{jl}] - (1 - \delta) \alpha_4 r_{jl} \quad (\text{C.7})$$

onde $0 < \alpha_1 \ll \alpha_2 < 1$ e $0 < \alpha_3 \ll \alpha_4 < 1$ são as taxas de aprendizado, com $j = 1, \dots, M$ e $i = 1, \dots, n$.

Bibliografia

- ACOSTA, G.G., VERUCCHI, C.J., & GELSO, E.R. (2006). *A current monitoring system for diagnosis electrical failures in induction motors. Mechanical Systems and Signal Processing*, 20, 953-965.
- ALGUINDIGUE, I., BUCZAK, A.L., & ULRIG, R.L. (1993). *Monitoring and diagnosis element bearing faults using neural networks. IEEE Trans. Ind. Electron.*, 40, 209-217.
- ALTUG, S., MO-YUEN, Chen, & TRUSSELL, H.J. (1999). *Fuzzy Inference System Implemented on Neural Architectures for Motor Fault Detection and Diagnosis. Industry Electronics, IEEE Transactions on*, 6, 1069-1079.
- AWADALLAH, M.A., & MEDHAT, M. M. (2003). *Application of AI tools in fault diagnosis of electrical machines and drives-an overview. Energy Conversion, IEEE Transactions on*, 18(2), 245-251.
- BALLINI, R., & GOMIDE, F. (2002). *Learning in recurrent hybrid neurofuzzy networks. IEEE International Conference on Fuzzy Systems*, 785-791.
- BELLINI, A., FELLIPETI F., FRANCESCHINI, G., & TASSONI, C. (2000). *Closed loop control impact on the diagnosis of induction motors faults. IEEE Transactions on Industry Application*, 36, 1318-1329.
- BELLINI, A., FRANCESCHINI, G., & TASSONI, C. (2000). *Closed-loop control impact on the diagnosis of induction motors faults. Industry Applications, IEEE Transactions on*, 36(5), 1318-1329.
- BENKHEDDA, H., & PATTON, R.J.M. (Setembro 1996). *Fault Diagnosis Using Quantitative and Qualitative Knowledge Integration. UKACC International Conference on Control '96*, 2-5.

- BEZDEK, J., & HATHAWAY, R. (1988). *Recent convergence results for the fuzzy c-means clustering algorithms. Journal of Classification*, 5(2), 237-247.
- BRAGA, A.P., CARVALHO, A.P.L.F., & LUDERMIR, T.B. (2000). *Redes Neurais Artificiais: Teoria e Aplicações*. LTC Editora. Rio de Janeiro. 262p.
- BROWN, M., & HARRIS, C. (1994). *Neurofuzzy Adaptive Modelling and Control*. Prentice Hall International.UK. 508p.
- CALADO, J.M.F., KORBICS, J., PATTON, Ron J., & SÁ COSTA, J.M.G. (2001). *Soft Computing Approaches to Fault Diagnosis for Dynamic Systems. European Journal of Control*, 7, 248-286.
- CARDINALI, R., & WEBER, D. (1992). *Diagnosis on hydroelectric machinery. International Conference on Vibration in Rotating Machinery, Bath*, 461-467.
- CARDOSO, M.A.J., CRUZ, S.M.A., & FONSECA, D.S.B. (1999). *Inter-turn stator winding fault diagnosis in three-phase induction motors, by Park's vector approach. Energy Conversion, IEEE Transactions on*, 14(3), 595-598.
- CARDOSO, M.A.J., & MENDES, A.M.S. (1997). *Converter fault diagnosis in variable speed DC drives by Park's vector approach. Energy Conversion, IEEE Transactions on*, 2(3), 497-500.
- CARDOSO, M.A.J., & SARAIVA, E.S. (1993). *Computer-aided detection of airgap eccentricity in operating three-phase induction motors by Park's vector approach. IEEE Transaction Industry Application*, 29(5), 897-901.
- CASH, M.A., HABETLER, T.G., & KLIMAN, G.B. (1998). *Insulation failure prediction in AC machines using line-neutral voltages. Industry Applications, IEEE Transactions on*, 34(6), 1234-1239.
- CHEN, J., & PATTON,R.J. (1999). *Robust Model-based Fault Diagnosis for Dynamic Systems*. Kluwer Academic Publisher. Boston. USA. 380p.
- CHOW, M., MANGUM, P.M., & YEE, S.O. (1991). *A neural network approach to real-time condition monitoring of induction motors. Energy Conversion, IEEE Transactions on*, 38(6), 448-453.

- CHOW, M., & YEE, S.O. (1991). *Methodology for on-line incipient fault detection in single-phase squirrel-cage induction motors using artificial neural networks*. *Energy Conversion, IEEE Transactions on*, 6(3), 536-545.
- CHOW, M.-Y., SHARPE, R.N., & HUNG, J.C. (1993). *On the application and design of artificial neural networks for motor fault detection. I. Industry Electronics, IEEE Transactions on*, 40(2), 181-188.
- CHOW, S.Y., & WILLISKY, A.S. (1984). *Analytical Redundancy and Design of Robust Failure Detection System*. In *Ieee transaction and automatic control* (Vol. 29, p. 603-614).
- CRUZ, S.M.A., & CARDOSO, A.J.M. (2001). *Stator winding fault diagnosis in three-phase synchronous and asynchronous motors, by the extended Park's vector approach*. *Industry Applications, IEEE Transactions on*, 37(5), 1227-1233.
- CRUZ, S.M.A., & CARDOSO, A.J.M. (2003). *Diagnosis of stator inter-turn short circuits in DTC induction motor drives*. In *Proceeding 38th industry application annual meeting conf. salt lake city, ut* (p. 1332-1339).
- CRUZ, S.M.A., & CARDOSO, A.J.M. (2005). *Multiple Reference Frames Theory: A New Method for the Diagnosis of Stator Faults in Three-Phase Induction Motors*. *IEEE Transactions on Energy Conversion*, 20(3), 611-619.
- CRUZ, S.M.A., CARDOSO, A.J.M., & TOLIYAT, H. A. (2003). *Diagnosis of stator, rotor, and airgap eccentricity faults in three-phase induction motors based on the multiple reference frames theory*. In *Proceeding 38th industry application annual meeting conf. salt lake city, ut* (p. 1340-1346).
- DALTON, T. (1999). *Introduction to Fault Diagnosis*. Dept. of Measurement and Control - University of Duisburg. Duisburg, Germany.
- D'ANGELO, M. F. S. V., & COSTA JR, P. P. (2000). *Simulator of Faults in the Stator Windings in Induction Machines*. *IV Industry Applications Conference IEEE INDUSCON*, 76-80.
- DEXTER, A.L. (1995). *Fuzzy Model Based Fault Diagnosis*. *IEE Proc.-Control Theory Application*, 142(6), 545-550.

- DI STEFANO, R., MEO, S., & SCARANO, M. (1994). *Induction motor faults diagnostic via artificial neural network (ANN)*. In *Industrial electronics, 1994. symposium proceedings, isie '94., 1994 ieee international symposium on* (p. 220-225).
- DISTE, C. J., & SCHIFERL, R. (1994). *Using temperature, voltage, and/or, speed measurements to improve trending of induction motor rms currents in process control and diagnostics*. *IEEE Industry Applications Soc. Annual Meeting Conf.*, 1, 312-318.
- DORRELL, D.G., THOMSON, W.T., & ROACH, S. (1997). *Analysis of airgap flux, current, and vibration signals as a function of the combination of static and dynamic airgap eccentricity in 3-phase induction motors*. *IEEE Transactions on Industry Applications*, 33(1), 24-34.
- DUNN, J. (1973). *A fuzzy relative of the Isodata process and its use in detecting compact, well-separated clusters*. *Journal of Cybernetics*, 3(3), 32-35.
- ELKASABGY, N.M., EASTHAM, A.R., & DAWSON, G.E. (1992). *Detection of broken bars in the cage rotor on an induction machine*. *IEEE Transaction Andustrial Application*, 28, 165-171.
- FILIPPETI, F., GIOVANI, F., TASSONI, C., & VAS, P. (1996). *AI techniques in induction machines diagnosis including the speed ripple effect*. *IEEE Industry Applications Soc. Annu. Meeting Conf., San Diego, CA*, 655-662.
- FILIPPETI, F., GIOVANI, F., TASSONI, C., & VAS, P. (2000). *Recent Developments of Induction Motor Drives Fault Diagnosis Using AI Techniques*. *IEEE Transactions on Industry Electronics*, 47(5), 994-1004.
- FILIPPETTI, F., FRANCESCHINI, G., & TASSONI, C. (1995). *Neural networks aided on-line diagnostics of induction motor faults*. *IEEE Trans. Ind. Applicat.*, 31, 892-899.
- FRANK, P.M. (1990). *Fault Diagnosis in Dynamic Systems Using Analytical and Knowledge-based Redundancy - A survey and Some New Results*. In *Automatica* (Vol. 26, p. 459-474). 3.
- FRANK, P.M. (1994). *Enhancement of Robustness in Observed-based Fault Detection*. In *International journal of control* (Vol. 59, p. 955-981).

- GERTLER, J.J. (1993). *Analytical Redundancy Methods in Failure Detection and Isolation in Complex Plants. Control and Advanced Technology*, 9(1), 259-285.
- GERTLER, J.J. (2000). *Strutured Parity Equations in Fault Detection and Isolation*. In *Issues of fault diagnosis for dynamic systems* (p. 285-313).
- GODDU, G., LI, B., CHOW, M.Y., & HUNG, J.C. (1998). *Motor bearing fault diagnosis by a fundamental frequency amplitude based fuzzy decision system*. Industry Electronics Society, 1998. IECON '98. Proceedings of the 24th Annual Conference of the IEEE, 4, 1961-1965.
- GOODE, P.V., & CHOW, M.Y. (1995a). *Using a neural/fuzzy system to extract heuristic knowledge of incipient faults in induction motors - Part I*. Industry Electronics, IEEE Transactions on, 42, 131-138.
- GOODE, P.V., & CHOW, M.Y. (1995b). *Using a neural/fuzzy system to extract heuristic knowledge of incipient faults in induction motors - Part II*. Industry Electronics, IEEE Transactions on, 42, 139-148.
- HAYKIN, S. (2001). *Redes Neurais - Princípios e prática*. Editora Bookman. Porto Alegre. 2^a edição. 900p.
- HECHT-NIELSEN, R. (1990). *Neurocomputing*. Addison Wesley Publisher - NY - New York-USA. 512 pp.
- HELL, M., GOMIDE, F., SECCO, L., & COSTA JR, P. P. (2006). *Elman Recurrent Neural Network in Thermal Modeling of Power Transformers*. School of Electrical and Computer Engineering - FEEC - UNICAMP and Pos Graduate Program in Electrical Engineering - PUC MG.
- HUO, Y., IOANNOU, P.A., & MIRMIRANI, M. (2001, 11). *Fault-Tolerant Control and Re-configuration for High Performance Aircraft: Review* (CATT Technical Report No. 01-11-01). Los Angeles, CA: Dept. of Electrical Engineering-Systems - University of Southern California; Dept. of Mechanical Engineering - California State University.
- ISERMANN, R. (1984). *Process Fault Detection Based on Modelling and Estimation Methods - A survey*. In *Automatica* (Vols. 20,4, p. 387-404).

- ISERMANN, R. (1994). *Integration of Fault Detection and Diagnosis Methods. Reprints of IFAC Symposium. on Fault Detection, Supervision and Safety for Technical Processes, Espoo, Finland.* In (Vol. 2, p. 575-590).
- ISERMANN, R. (1997). *Supervision and Safety for Fault-detection and Fault-diagnosis Methods - An Introduction. Control Eng. Praticce.* In (Vol. 5, p. 639-652). 5.
- ISERMANN, R., & ULIERU, M. (1993). *Integrated Fault Detection and Diagnosis (Tech. Rep.).* Landgraf-George Str. 4, 64283 - Darmstadt, Germany: Technical University of Darmstadt - Institute of Automatic and Control - Laboratory for Control Engineering and Process Automatic.
- IVONNE, Y. B., SUN, D., & HE, Y. K. (2005). *Fault Diagnosis Using Neural-Fuzzy Technique Based on the Simulation Results of Stator Faults for a Three-Phase Induction Motor Drive System. ECON 02 [Industrial Electronics Society, IEEE 2002 28th Annual Conference of the],* 3, 1966-1971.
- JANG, J.R. (1993). *ANFIS - Adaptive-Network-Based Fuzzy Inference System.* IEEE Transaction Man, Cybern., 23, 665-685.
- KLIMAN, G.B., KOEGL, R.A., ENDICOTT, R.D. STEIN, J. and, & MADDEN, M.W. (1988). *Noninvasive detection of broken rotor bars in operating induction motors. IEEE Transaction Energy Convers.,* 3(4), 873-879.
- KLIMAN, G.B., PREMERLANI, W.J., KOEGL, R.A., & HOEWELER, D. (1996). *A new approach to on-line turn fault detection in AC motors. Industry Applications Conference, 1996. Thirty-First IAS Annual Meeting, IAS '96., Conference Record of the 1996 IEEE, 1,* 687-693.
- KRAUSE, P.C., WASYNCZUK, O., & SUDHOFF, S.D. (1995). *Analysis of Electric Machinery.* New York: IEEE Press, NJ. 564p.
- LEITE, D. F., ARAÚJO, M. V., SECCO, L., & COSTA JR, P. P. (2006). *Induction Motors Modeling and Fuzzy Logic Based Turn-To-Turn Fault Detection and Location.* Pos Graduate Program in Electrical Engineering - PUC MG.

- LI, B., CHOW, M.-Y., TIPSUWAN, Y., & HUNG, J.C. (2000). *Neural-network-based motor rolling bearing fault diagnosis. IEEE Transactions on Industrial Electronics*, 47(5), 1060-1069.
- LIN, C.T., & LEE, C.G. (1991). *Neural-network-based fuzzy logic control and decision system. IEEE Transaction Computer*, 40, 1320-1336.
- MARCU, T., & MIREA, L. (1997). *Robust Detection and Isolation of Process Faults Using Neural Networks. In Control systems magazine, iee* (Vol. 17, p. 72-79).
- MATHEW, J., & ALFREDSON, R.J. (1984). *The condition monitoring of rolling element bearing. Transaction ASMJE J. Vibr. Acoust. Stress Reliab. Des.*, 106, 447-453.
- MILIMONFARED, J., KELK, H.M., NANDI, S., MINASSIANS, A. D., & TOLIYAT, H.A. (1999). *A novel approach for broken-rotor-bar detection in cage induction motors. IEEE Transaction Industry Application*, 35, 1000-1006.
- NANDI, S., & AHMED, S. (2005). *Condition Monitoring and Fault Diagnosis of Electrical Motors - A Review. IEEE Transaction on Energy Conversion*, 20(4), 719-729.
- NARENDRA, K.S., & PARTHASARATHY, K. (1990). *Identification and Control of Dynamic Systems using Neural Networks. IEEE Transactions on Neural Networks*, 1, 4-27.
- NASCIMENTO, S., MIRKIN, B., & MOURA-PIRES, F. (2000). *A fuzzy clustering model of data and fuzzy c-means. The Ninth IEEE International Conference on Fuzzy Systems, 2000.*, 1, 302-307.
- PATTON, R.J., & CHEN, J. (1992). *Robustness in Quantitative Model-Based Fault Diagnosis. IEE Colloquium on Intelligent Fault Diagnosis - Part 2: Model-Based Techniques - Department of Electronics, University of York, YORK, YO1 5DD, England.*
- PATTON, R.J., FRANK, P.M., & CLARK, R.N. (2000). *Issues of Fault Diagnosis for Dynamic Systems. Springer-Verlag Berlin Heidelberg New York. 597p. 1a edição.*
- PATTON, R.J., & KANGETHE, S.M. (1988). *Robust Fault Diagnosis Using The Model-Based Approach. In Condition monitoring and failure diagnosis part 1 iee colloquium* (p. 2/1 - 2/13).

- PATTON, R.J., LOPEZ-TORIBIO, C.J., & UPPAL, F.J. (1999). Artificial Intelligence Approaches to Fault Diagnosis. Control and Intelligent Systems Engineering Research Group, School of Engineering, The University of Hull, Cottingham Road HU6 7RX, UK. 18p.
- PEDRYCZ, W., & GOMIDE, F. (1998). An Introduction to Fuzzy Sets: Analysis and Design. MIT Press Complex Adaptive Systems. 465p.
- PENMAN, J., SEDDING, H.G., LLOYD, B.A., & FINK, W.T. (1994). *Detection and location of interturn short circuits in the stator windings of operating motors. Energy Conversion, IEEE Transactions on*, 9(4), 652-658.
- PENMAN, J., & YIN, C.M. (1994). *Feasibility of using unsupervised learning artificial neural networks for the condition monitoring of electrical machines. IEE Proc. Electr. Power Application*, 141(6), 317-322.
- PRABHU, B.S. (1996). *Rolling bearing diagnosis. Indo-US Symposium on Emerging Trends in Vibrations and Noise Engineering, Delhi*, 311-320.
- SASTRY, P.S., SANTHARAM, G., & UNNIKRISHNAN, K.P. (1994). *Memory Neuron Networks for Identification and Control of Dynamic Systems. IEEE Transactions on Neural Networks*, 5, 306-319.
- SAUTER, D., MARY, N., SIROU, F., & THIELTGEN, A. (1994). *Fault Diagnosis in Systems Using Fuzzy Logic. In Proceedings of the 3rd IEEE conference on control applications (Vol. 2, p. 883-888).*
- SCHOEN, R.R., & HABETLER, T.G. (1995). *Effect of time varying loads on rotor fault detection in induction machines. IEEE Transaction Industry Application*, 31, 900-906.
- SCHOEN, R.R., HABETLER, T.G., KAMRAN, F., & BARTFIELD, R.G. (1995). *Motor bearing damage detection using stator current monitoring. IEEE Transactions on Industry Applications*, 31(6), 1274-1279.
- SCHOEN, R.R., LIN, B.K., HABETLER, T.G., SCHLAG, J.H., & FARAG, S. (1995). *An unsupervised, on-line system for induction motor fault detection using stator current monitoring. Industry Applications, IEEE Transactions on*, 31(6), 1280-1286.

- SINGH, G. K., & AL KAZZAZ, S. A. S. (2003). *Induction machine drive condition monitoring and diagnostic research - a survey*. *Electric Power Systems Research*, 65(3), 145-158.
- SINHA, B.K. (1996). *Condition monitoring and machine fault diagnosis*. *Indo-US Symposium on Emerging Trends in Vibrations and Noise Engineering, Delhi*, 18-20.
- SMITH, J.R. (1990). *Response Analysis of A.C. Electrical Machines: Computer Models and Simulations*. *Research Studies Press, NJ*, 239p.
- STONE, G., & KAPLER, J. (1998). *Applying Radial Basis Functions*. *IEEE Industry Applications Magazine*, 4(5), 15-20.
- THOMSON, W.T., & FENGER, M. (2000). *Industrial application of current signature analysis to diagnose faults in 3-phase squirrel cage induction motors*. In *Proc. IEEE pulp. and paper ind. tech. conf.* (p. 205-211).
- TINÓS, R. (1999). *Detecção e Diagnóstico de Falhas em Robôs Manipuladores via Redes Neurais Artificiais* (Master's thesis, Escola de Engenharia de São Carlos. 129p). .
- TOLIYAT, H. A., & AL-NUAIM, N. A. (2001). *A novel method for modeling dynamic air-gap eccentricity in synchronous machines based on modified winding function theory*. *IEEE Transaction Energy Conversion*, 591-596.
- TSOUKALAS, L.H., & UHRIG, R.E. (1997). *Fuzzy and Neural Approaches in Engineering*. John Wiley and Sons. 587p.
- VAS, P. (1993). *Parameter Estimation, Condition Monitoring and Diagnosis of Electrical Machines*. Clarendon Press - Oxford, U.K. 384p.
- WANG, Li-Xin, & MENDEL, J. M. (1992). *Generating Fuzzy Rules by Learning from Examples*. *IEEE Transactions on System, Man and Cybernetics*, 22(6), 1414-1427.
- WUENNENGER, J. (1990). *Observed-based Fault Detection in Dynamic Systems* (Doctoral dissertation, University of Duisburg, Germany). .
- XIANRONG, C., & COCQUEMPOT, V. (2003). *A model as asynchronous machines for stator fault detection and isolation*. *IEEE Transaction Industry Electronics*, 50(3), 578-584.

XU, Y., & JIANG, J. (1998). *Implementation of an Observer-based Fault Detection Scheme on a Lab-scale Power System. Electrical and Computer Engineering, 1998. IEEE Canadian Conference on*, 2(2), 573-576.

YAZICI, B., & KLIMAN, G.B. (1999). *An adaptive statistical time-frequency method for detection of broken bars and bearing faults in motors using stator current. IEEE Transactions on Industry Applications*, 35(2), 442-452.

Abstract

The objectives of this work are to propose and discuss a faults detection and isolations system of short circuit between stator winding of induction machines using Computational Intelligence techniques.

The characteristics observed to faults detect and isolate in stator was the power factor and current effective value in one of the phases where they were obtained by an induction machine simulator, considering the machine behavior in several situations, with and without faults. After, a laboratory prototype proved the simulation results.

About the structure of the diagnostic system, several combinations of Artificial Neural Networks Techniques, Fuzzy Logic and Neuroffuzzy structures were showed to implement waste generator and faults analyzer that perform robustness and capacity to diagnose incipient faults. It was considered a waste generator based in an analytical model, with one of the tool possible to compose the diagnostic system proposed.

The results performed with the utilization of observers based in Neural Networks and Neuroffuzzy, together with waste neural analyzer and fuzzy structures, performed very promising, permitting to prove the effectiveness of this explanation in faults diagnostic system in induction engine or, in the utilization of this techniques in general electrical machines.

Índice

- afundamento de tensão, 64
- agrupamento fuzzy, 87
- algoritmos genéticos, 55
- análise da assinatura de corrente, 54
- análise de assinatura de corrente, 47, 52
- análise de sinais, 13
- Análises de assinatura de corrente, 51
- analíticas ou funcionais, 13
- ANFIS, 59
- assinatura da falta, 30

- bservadores de estado, 15

- campo magnético, 47
- checagem de limites, 13, 22
- circuitos elétricos, 31
- Compensação Paralela Distribuída, 37
- conhecimento heurístico, 35
- conjuntos fuzzy, 36
- curto circuito, 65, 82, 86
- curto circuitos, 53, 54, 59, 84, 85
- curtos circuito, 62

- Detecção e isolamento de faltas, 26
- detecção e isolamento de faltas, 13, 15, 17–19, 24, 26, 30, 31, 40, 54, 58–60
- diagnóstico, 16
- Diagnóstico de Faltas, 13

- diagnóstico de faltas, 12, 16, 34, 35, 37, 45, 47, 53, 56–58, 60, 62
- Direct Torque Control, 54
- distúrbio, 24, 33
- distúrbios, 13, 16, 22, 29, 30, 33, 34, 56
- distúrbios externos, 34

- EBP, 57, 67
- EPRI, 16, 52
- equações de paridade, 15, 27, 30
- espectro de corrente, 60
- estator, 16–18, 45–47, 53, 54, 57, 59, 60, 62, 82–85
- estimação de estados, 15, 19
- estimação de parâmetros, 15, 26, 30, 55

- FALCON, 59
- faltas incipientes, 12, 60, 61, 65
- FCM, 87, 96
- FDI, 13
- feedforward, 98, 100
- filtros de Kalman, 15
- FIS, 93
- flicker de tensão, 64
- fluxo de dispersão do eixo, 47

- Gaussiana, 65
- Gaussianos, 33

- geração de resíduos, 13
- identificação de parâmetros, 19, 26
- IEEE, 16, 52
- incertezas, 12, 15, 29–31, 34
- incipiente, 56
- index, 85
- inferência fuzzy, 15, 31, 37
- Inteligência Artificial, 35
- Inteligência Computacional, 15–18, 45, 58, 60, 62
- Kohonen, 57
- Lógica Clássica, 15, 37, 58
- Lógica Fuzzy, 15–18, 36, 37, 41–43, 45, 55, 57–60
- LMIs, 38
- Lotfi A. Zadeh, 36
- máquina de indução, 17, 60, 63
- máquinas da indução, 50
- máquinas de indução, 16–18, 45–47, 49, 53, 60, 62
- Máquinas elétricas, 44
- máquinas elétricas, 16, 17, 44, 45, 48
- métodos analíticos, 37
- métodos conexonistas, 15
- métodos estatísticos, 22
- métodos híbridos, 15
- métodos qualitativos, 15
- métodos quantitativos, 15
- MCSA, 54
- MLP, 56, 60, 87
- modelagem qualitativa, 35
- modelo matemático, 13, 15, 19, 21
- modelo qualitativo, 35, 36
- modelo quantitativo, 15
- modelos híbridos, 16
- Motor de indução, 84
- motor de indução, 53, 57, 82–84
- Motores de indução, 45
- motores de indução, 51, 52, 54, 57, 59
- NARX, 41
- Neurofuzzy, 17
- neurofuzzy, 16–18, 31, 41–43, 45, 55, 59, 60
- observador, 24, 29
- observador analítico, 36
- observador de estado, 24
- observador fuzzy, 37
- observador neural, 98
- observadores de estado, 30
- observadores de estados, 15
- PDC, 37
- Preceptron Multinível, 40
- programação evolucionária, 16
- Rede Neural, 42
- Rede Neural Elman, 98
- Redes Neurais Recorrentes, 40
- redundância analítica, 13, 14
- redundância analítica, 30
- redundância de hardware, 13
- regras heurísticas, 35
- relações de paridade, 15, 19, 28

relacionamento funcional, 13
resíduo, 14, 23, 24, 28, 30, 33, 82
resíduos, 15, 19, 21–24, 27–32, 35, 40, 42, 62,
66
RMS, 60
RNA, 15, 40, 42, 56–58, 87, 101
RNAs, 15–18, 38–42, 45, 55, 56, 58–60
robustez, 30, 31, 34, 56
robustos, 13, 15
rotor, 82–85
ruído, 45, 48
ruídos, 15, 22, 29, 32, 33, 47, 56, 65
Runge Kutta, 83

Sistema de Diagnóstico de Falhas, 13
sistemas baseados em conhecimento, 35
Sistemas Especialistas, 35, 55
soft computing, 15
spectrum de corrente, 50
surto de tensão, 64

técnicas livres de modelo, 55
técnicas baseadas em modelos, 47
técnicas livres de modelos, 16, 47
tomada de decisão, 21, 30
tomada de decisões, 34
transformação de Park, 54
transformada de Fourier, 50
TS, 37

vetor de corrente de Park, 54
vetor de Park, 52–54, 59