

UNIVERSIDADE DE SÃO PAULO ESCOLA POLITÉCNICA
DEPARTAMENTO DE ENGENHARIA MECÂNICA

SISTEMA FUZZY PARA DIAGNÓSTICO DE DEFEITOS EM MANCAIS DE
ROLAMENTOS

Rodrigo Yoshiaki Fujimoto

Orientador: Linilson R. Padovese
Co-Orientador: Demétrio C. Zachariadis

São Paulo
2002

Cost: 10,0

DEZ

~~Donald~~
Dimitro C Zadorov
06/12/02

UNIVERSIDADE DE SÃO PAULO ESCOLA POLITÉCNICA
DEPARTAMENTO DE ENGENHARIA MECÂNICA

SISTEMA FUZZY PARA DIAGNÓSTICO DE DEFEITOS EM MANCAIS DE
ROLAMENTOS

Trabalho de formatura apresentada à Escola
Politécnica da Universidade de São Paulo para
obtenção do título de Graduação em Engenharia

Rodrigo Yoshiaki Fujimoto

Orientador: Linilson R. Padovese
Co-Orientador: Demétrio C. Zachariadis

Área de Concentração:
Engenharia Mecânica

São Paulo

2002

AGRADECIMENTOS

A meus pais e meus irmãos por terem me apoiada em toda a minha vida acadêmica.

Aos meus colegas de laboratório que me inspiraram para alcançar os resultados.

RESUMO

Este projeto visou o desenvolvimento e o aperfeiçoamento de um sistema automático de diagnóstico de defeitos em rolamentos. No sistema aqui proposto, utilizou-se a teoria de conjunto fuzzy (ou nebuloso) para detecção, localização e classificação de defeitos em um mancal de rolamento. Como uma das principais desvantagens na criação de um sistema de inferência fuzzy é a ampla necessidade de um especialista em diagnóstico, procurou-se o desenvolvimento de uma metodologia para criação automática de um sistema fuzzy baseada na utilização de um banco de dados. Para realizar os testes apresentados neste trabalho, foi feito um programa em MatLab® que permite a utilização de conhecimentos analíticos (utilizando a metodologia apresentada neste mesmo trabalho) e também de conhecimentos heurísticos (adquiridos através de um especialista de diagnóstico). Especificamente neste trabalho, só foram utilizados os conhecimentos analíticos. Os testes dos sistemas fuzzy obtidos foram feitos utilizando um banco de dados de exemplares de sinais de vibração. Estes sinais representam a condição normal e diversos tipos de defeitos em rolamentos. A bancada experimental utilizada está localizada no Laboratório de Análise Dinâmica e Instrumentação (LADIN) do Departamento de Engenharia Mecânica da Escola Politécnica da USP. Os parâmetros escalares característicos necessários para a entrada do sistema fuzzy foram obtidos através do processamento dos sinais de vibração dos mancais. Neste trabalho também foram analisadas as influências de alguns parâmetros utilizados na criação do sistema fuzzy na performance de diagnóstico. Dentre estes parâmetros pode-se destacar o tipo de perfil das funções de pertinência e as características de entrada. Para a determinação da precisão e confiabilidade do sistema fuzzy separou-se o banco de dados em duas partes, sendo uma delas para criação do sistema fuzzy e outra para posterior teste.

ABSTRACT

This project intended to develop and improve an automatic system of faults diagnosis in rolling bearing. In the proposed system, the fuzzy set theory is used to detect, find and classify faults in a rolling bearing. One of the most important disadvantages in creating a fuzzy system is the wide necessity of a diagnoses expert. Thus we developed a methodology to automatically create a fuzzy inference system using the acquired experimental database. We made a MatLab's® program that can use analytic (using the methodology present in this project) and heuristic (from the diagnoses experts) knowledge. In this work we used analytic knowledge only. The fuzzy system's tests used a database composed by samples of vibration signals with several types of faults and a normal condition. The experimental rig is located in Dynamics Analysis Laboratory (LADIN) in Department of Mechanical Engineering of Escola Politécnica of USP. The scalar characteristics parameters used in input fuzzy system were obtained by signal processing of rolling bearing's vibration signals. We also evaluated the influence of some variables of fuzzy system on its reliability. Among those variables it is worth to point out the shape type of membership functions and the characteristics of input. The database was divided in two parts, one of them will be used to develop the fuzzy system, and the other one will be used to verify the accuracy and reliability of the system.

SUMÁRIO

1.	<i>Introdução</i>	1
1.1.	Objetivo	3
1.2.	Metodologia	4
2.	<i>Resumo Bibliográfico</i>	5
2.1.	Manutenção Preditiva	5
2.2.	Defeitos em Mancais de Rolamentos	7
2.3.	Análise de Vibrações para Mancais de Rolamentos	9
2.4.	Sistemas Especialistas	10
2.5.	Sistemas Automáticos de Diagnósticos de Falhas	12
2.6.	Sistemas Inferência Fuzzy	13
3.	<i>Sistema de Inferência Fuzzy</i>	17
3.1.	Lógica Fuzzy	18
3.2.	Operadores Lógicos	22
3.3.	Regras de Inferência	25
3.4.	Operador THEN	26
3.5.	Operador de Agregação	27
3.6.	Operador de Desfuzzificação	27
3.7.	Inferência Fuzzy	28
3.8.	Implantação de um Sistema de Inferência Fuzzy	31
4.	<i>Análise de Vibração</i>	33
4.1.	RMS ou Valor Eficaz	33
4.2.	Skewness	34
4.3.	Kurtosis	34
4.4.	Valor de Pico	35
4.5.	Fator de Crista	35
4.6.	Fator K	35
4.7.	Densidade Espectral de Frequência ou PSD	36
4.8.	Envelope	36
4.9.	ER	37
4.10.	Frequências de Defeitos em Rolamento	37
4.11.	Razão de Pico	38
5.	<i>Criação de Sistema Fuzzy Automatizado</i>	39
5.1.	Metodologia	39
5.2.	Característica do Programa "Sistema_Fuzzy"	42
5.3.	Etapas de Criação de um Sistema Fuzzy	48

6.	<i>Banco de Dados Experimental</i>	50
6.1.	Amostras _____	50
6.2.	Aparato Experimental _____	52
7.	<i>Estratégias de Diagnóstico para Teste do Sistema Fuzzy</i>	58
7.1.	Variação do Banco de Dados de Criação _____	58
7.2.	Variação de Rotação _____	59
7.3.	Formas de Cálculo das Médias e Desvios Padrões das Funções de Pertinência _____	59
7.4.	Detecção x Detecção/Classificação _____	59
7.5.	Análise e Escolha das Características de Entrada _____	60
8.	<i>Testes do Sistema Fuzzy</i>	63
8.1.	Parâmetros de Criação do Sistema Fuzzy _____	63
8.2.	Parâmetros de Análise _____	67
9.	<i>Resultados e Discussão</i>	69
9.1.	Perfil da Função de Pertinência _____	69
9.2.	Valores Característicos _____	71
9.3.	Outras análises _____	73
9.4.	Melhor Performance de Teste dos Sistemas de Inferência Fuzzy _____	78
10.	<i>Conclusão</i>	80
11.	<i>Referência Bibliográfica</i>	82

LISTA DE FIGURAS

<i>Figura 2.1 – Padrão de deterioração ⁽²²⁾.</i>	7
<i>Figura 2.2 – Razões de falhas de rolamentos ⁽³⁶⁾.</i>	8
<i>Figura 2.3 – Estrutura de um sistema especialista</i>	11
<i>Figura 3.1 – Comparação entre lógica clássica e lógica fuzzy ⁽²⁸⁾.</i>	18
<i>Figura 3.2 – Parâmetros da função trapezoidal</i>	20
<i>Figura 3.3 – Parâmetros da função triangular</i>	20
<i>Figura 3.4 – Parâmetros da função gaussiana</i>	21
<i>Figura 3.5 – Parâmetros da função pi</i>	22
<i>Figura 3.6 – Parâmetros da função beta</i>	22
<i>Figura 3.7 – Padrão de regra de inferência</i>	26
<i>Figura 3.8 – Diagrama do processo de inferência fuzzy ⁽²⁸⁾</i>	29
<i>Figura 3.9 – Exemplo do processo de inferência fuzzy com modelo Mandani, considerando alguns tipos de operadores²⁸.</i>	29
<i>Figura 3.10 – Exemplo do processo de inferência fuzzy com modelo Sugeno, considerando alguns tipos de operadores²⁸.</i>	30
<i>Figura 3.11 – Estrutura de um Sistema Fuzzy</i>	31
<i>Figura 5.1 – Exemplo de Conjunto de Função de Pertinência para uma determinada característica. Cada gráfico com um conjunto de curvas está relacionado a uma variável lingüística (Normal, RiscadoExt, etc). O universo de discurso é definido por [-1.1,1.8], como pode ser verificado na coordenada.</i>	41
<i>Figura 5.2 – Regra de Inferência Padrão</i>	42
<i>Figura 5.3 – Exemplo de Conjunto de Função de Pertinência para uma determinada característica. À esquerda (a) está a parte relacionada ao conhecimento analítico e à direita (b) a parte utilizada para aplicação dos conhecimentos heurísticos.</i>	43
<i>Figura 5.4 – Estrutura de uma Regra de Inferência</i>	46
<i>Figura 5.5 – Exemplo da visualização das regras de inferência</i>	47

<i>Figura 5.6 – (a) Exemplo da janela de entrada das variáveis características (Velocidade- 1; Carga- 2; e RMS- 8) e (b) de uma saída com respectiva saída desfuzzificada (9.883) e função de pertinência resultante</i>	47
<i>Figura 5.7 – Propriedades de um sistema de inferência fuzzy</i>	49
<i>Figura 6.1– Rolamento B015TVP da FAG (a) montado e (b) desmontado</i>	50
<i>Figura 6.2 – Geometria do Rolamento</i>	50
<i>Figura 6.3 – Defeitos em Rolamentos na Pista Externa: (a) Furado, (b) Riscado, (c) Corrosão 1, e (d) Corrosão 2</i>	51
<i>Figura 6.4 – Defeitos em Rolamentos na Pista interna: (a) Furado, (b) Riscado, (c) Corrosão 1, e (d) Corrosão 2</i>	52
<i>Figura 6.5 – Esquema da bancada de teste</i>	53
<i>Figura 6.6 – Lay-Out geral da bancada de teste de defeitos de rolamento</i>	53
<i>Figura 6.7 – Detalhe da Bancada de Teste (a) motor utilizado para o teste, e (b) detalhe do mancal de rolamento mostrando o posicionamento do acelerômetro acima e a aplicação da carga através do parafuso (embaixo).</i>	54
<i>Figura 6.8 – Equipamento de filtro, amplificação e conversão A/D</i>	54
<i>Figura 6.9 – Sistema de aquisição de dados</i>	55
<i>Figura 6.10 – Variador de frequência para regular a rotação do motor</i>	55
<i>Figura 6.11 – Sistema de monitoramento da carga aplicada</i>	56
<i>Figura 7.1 – Esquema para obtenção os espectros de frequência</i>	61
<i>Figura 8.1 – As possíveis saídas do sistema fuzzy (Detecção/Classificação)</i>	65
<i>Figura 8.2 – Tipos de funções de pertinências com os parâmetros de entrada para um valor médio 0 e um desvio padrão de 1.</i>	66
<i>Figura 8.3 – Tipos de funções de pertinências com os parâmetros de entrada para um valor médio 0 e um desvio padrão de 1.</i>	67
<i>Figura 9.1 – Funções de pertinência referente à característica Pico para saída Normal para conjunto de banco de dados formado considerando (a) rotação variável (Sistema 1) e (b) rotação constante de 800 rpm (Sistema 4).</i>	75
<i>Figura 9.2 - Funções de pertinência referente à característica RMS para saída Normal com média e desvio padrão obtida por (a) todas as amostras (Sistema 99) e (b) para cada amostra (Sistema 106).</i>	76

LISTA DE TABELAS

<i>Tabela 2.1 – Principais características de sistemas de inferência fuzzy e redes neurais⁽⁴⁴⁾</i>	14
<i>Tabela 3.1 – Propriedades dos operadores lógicos fuzzy</i>	23
<i>Tabela 3.2 – Opções de operadores AND e OR</i>	24
<i>Tabela 3.3 – Opção de operador NOT</i>	25
<i>Tabela 3.4 – Opção de operador THEN</i>	27
<i>Tabela 3.5 – Opção de operador Agregação</i>	27
<i>Tabela 4.1 – Frequência de defeitos em rolamento</i>	38
<i>Tabela 6.1 – Características Geométricas do Rolamento B015TVP</i>	50
<i>Tabela 6.2 – Classes amostradas</i>	51
<i>Tabela 6.3 – Equipamento e Parâmetros de aquisição dos sinais de vibração</i>	56
<i>Tabela 7.1 – Dados dos cálculos para obtenção dos espectros de frequência</i>	62
<i>Tabela 8.1 – Nomes das variáveis lingüísticas das funções de pertinência de saída</i>	65
<i>Tabela 8.2 – Fatores de Proporção de Dispersão</i>	66
<i>Tabela 8.3 – Fatores de Proporção de Dispersão</i>	66

LISTA DE ANEXOS

Anexo A - LayOut do programa

Anexo B – Combinações de Estratégias de Diagnósticos

LISTA DE ABREVIATURAS E SIGLAS

RMS	- (Root mean square) Raiz da Média Quadrática
FFCM	- functional fuzzy c-means
ER	- Energia residual
MOM	- Média dos Máximos
SOM	- Menor dos Máximos
LOM	- Maior dos Máximos
A/D	- conversor analógico para digital
LADIN	- Laboratório de Análise Dinâmica
Sk	- Skewness
Kurt	- Kurtosis
Fc	- Fator de Crista
Fk	- Fator K
PSD	- Densidade Espectral de Potência
TF	- Transformada de Fourier
TFI	- Transformada de Fourier Inversa
Env	- Envelope
Rp	- Razão de Pico
PSD_64	- PSD do sinal de vibração com janela de ponderação de Hanning com 128 pontos
PSD_128	- PSD do sinal de vibração com janela de ponderação de Hanning com 256 pontos
ENVPSD_64	- PSD do envelope do sinal de vibração com janela de ponderação de Hanning com 128 pontos
ENVPSD_128	- PSD do envelope do sinal de vibração com janela de ponderação de Hanning com 256 pontos

LISTA DE SÍMBOLOS

μ	função de pertinência
T	operação T-Norm (Triangular Norm)
T_s	operação T-conorm ou S-norm
OU, OR ou \cup	operador união
E, AND ou \cap	operador intersecção
NÃO, NOT ou \sim	operador negação
α	valor limiar alfa
f_1, f_2	fatores de proporção de dispersão
Δ	dispersão
m	valor médio
S	função sigmodal
min	função mínimo
Max	função máximo
Π	produtória
THEN ou \leftarrow	operador implicação
\leftarrow	operador implicação
μ_{CFR}	função de pertinência de saída da regra de inferência
μ_{PT}	grau de pertinência da oração antecedente da regra de inferência
μ_{CFS}	função de pertinência de uma saída
μ_{CFF}	função de pertinência de saída do sistema fuzzy
$N_{discret}$	número de discretização das funções de pertinência
V_{ef}	valor eficaz
$x(t)$	sinal contínuo no tempo
$x[t]$	sinal discreto no tempo
T	período de amostragem
N	número de pontos de um dado sinal discreto
σ	desvio padrão de um sinal $x[t]$

\bar{x}	valor médio de um sinal $x[t]$
$X_{\text{máx}}$	valor de pico
M	número de amostras de um sinal
x_M	amostra de um sinal x
$X[f]$	PSD de um sinal $x[t]$
N_{spectro}	número de pontos de um PSD
$x_{\text{normal}}[t]$	sinal da condição normal do sistema
f	frequência
ω_G	frequência de gaiola
ω_B	frequência de rotação do elemento rolante
ω_{DE}	frequência de defeito na pista externa
ω_{DI}	frequência de defeito na pista interna
ω_{DB}	frequência de defeito no elemento rolante
ω_s	frequência de rotação do eixo
Z	número de elementos rolantes do rolamento
d	diâmetro do elemento rolante do rolamento
D	diâmetro da trajetória do elemento rolante do rolamento
α_c	ângulo de contato do elemento rolante e a pista do rolamento
B	largura do rolamento

1. INTRODUÇÃO

Em diversos setores de atividades industriais, a importância da otimização da produtividade das máquinas e a melhoria na qualidade dos produtos são cada vez mais crescentes, motivadas pela necessidade do aumento da competitividade em um mercado globalizado. Neste contexto, a diminuição de custos de operação e manutenção pode ter um impacto significativo na produtividade industrial. Como exemplo, pode-se citar o custo anual de uma indústria de papel, estimado em acima de US\$ 1 milhão, somente com a reposição de rolamentos.

Neste contexto, o conceito da manutenção preditiva vem sendo cada vez mais utilizado na rotina de manutenção de plantas industriais, visando justamente à redução dos custos associados à manutenção e o aumento da disponibilidade dos equipamentos.

Uma das principais características da manutenção preditiva é a necessidade de monitoramento do equipamento e a análise das informações obtidas através deste monitoramento com o objetivo de observar o desenvolvimento de um determinado defeito.

Para tanto, como principal ferramenta utilizada nesta área, pode-se citar a análise de vibração mecânica do equipamento. Neste caso, sinais de vibração obtidos através do monitoramento em mancais, transmissões, motores, etc., são analisados objetivando a detecção de uma alteração no estado do equipamento. O diagnóstico de um eventual defeito é realizado, neste caso, através da detecção de alguma alteração da assinatura mecânica normal do equipamento.

O diagnóstico de um componente de um equipamento pode ser um simples “defeito” ou “não defeito” ou, até mesmo, considerações mais completas, como a localização do defeito, a natureza deste defeito, tamanho do defeito, previsão de tempo até uma falha, etc.

A qualidade do processo de diagnóstico está ligada diretamente com a capacidade de tomar decisão do analista, que por sua vez depende de sua capacitação.

Um empecilho neste processo de diagnóstico é o volume de informações que precisam ser analisadas. Como exemplo, na área da indústria de papel, uma única

máquina de fabricação de papel pode ter 1500 mancais de rolamento (este número pode ser superior a 6000 em toda a planta industrial). Como na grande maioria, as medidas de vibração são realizadas em três direções, o volume de informações que precisam ser manipuladas, em toda a planta é enorme.

Diante da impossibilidade de se analisar detalhadamente cada sinal, os programas de diagnósticos automáticos utilizados atualmente em manutenção preditiva adotam configuração de alarme baseada na lógica tradicional (binária) para detectar um possível defeito.

Normalmente são utilizados alarmes baseados apenas no nível global de vibração (RMS) do sinal global ou de certas bandas de frequências. Neste caso, os dados, após serem digitalizados, são armazenados e o sistema de gerenciamento de dados calcula o RMS deste sinal. Este valor é comparado com um dado padrão (obtido do histórico anterior da máquina ou de um valor típico para a família do equipamento), e com base nesta análise, o sistema aciona um alarme. Os casos nos quais o sistema de alarme é acionado requerem uma análise mais profunda de um especialista.

Este sistema depende muito da dedicação e capacitação do analista, para ter um bom grau de confiabilidade.

A prática da utilização deste tipo de sistema, baseado só em RMS, mostra que o número de falsos alarmes pode ser grande, impossibilitando uma análise efetiva correta dos especialistas para todos os casos, e diminuindo o grau de confiabilidade do alarme.

Este projeto visa o estudo e desenvolvimento de um sistema automático de diagnóstico baseado em lógica fuzzy (“nebulosa”) que possibilite um maior grau de automatização na sua criação e confiabilidade do diagnóstico, minimizando a necessidade de intervenção de um analista. Esta solução possibilita:

- a fusão e sinergia de diversos parâmetros característicos da assinatura mecânica da planta;
- trabalhar com grandes volumes e variedades de informações;
- agregar conhecimentos heurísticos ao sistema;

- considerar a imprecisão de uma decisão ou conhecimento, transformando esta imprecisão em mais uma informação a ser levada em consideração no diagnóstico;
- ser descrita em uma linguagem com interpretações subjetivas.

Neste estudo, pretende-se determinar a influência de algumas variáveis, próprias do sistema fuzzy, sobre a sua confiabilidade final. Dentre estas variáveis pode-se destacar o tipo de perfil das funções de pertinência.

Como um exemplo de aplicação deste sistema automático de diagnóstico, foi utilizado o caso de defeitos de mancais de rolamentos. Dentre os pontos críticos em máquinas rotativas, talvez a mais problemática, sobretudo pela quantidade encontrada numa planta industrial e sua diversidade de aplicações em máquinas, são os mancais de rolamento.

O monitoramento de mancais de rolamento é normalmente feito através da medida de vibração por acelerômetros. Os métodos de processamento de sinais tradicionalmente usados são o RMS, espectro de frequência, envelope, etc. ^(13,29,41,42). Neste trabalho pretende-se utilizar um grupo destes parâmetros clássicos para formar o banco de informações a ser utilizado pelo sistema fuzzy de diagnóstico.

1.1. Objetivo

Este projeto visa o estudo e desenvolvimento de um sistema automático de diagnóstico de defeitos em mancais de rolamentos baseado em lógica fuzzy (“nebulosa”) que possibilite um maior grau de automatização na sua criação e o aumento da confiabilidade do diagnóstico. Será estudada a influência do perfil da função de pertinência utilizada sobre a confiabilidade do sistema de diagnóstico. Além deste, também será verificada a importância da escolha dos grupos de parâmetros característicos (obtidos através do pré-processamento dos sinais de vibração) que serão utilizados como entrada do sistema fuzzy.

1.2. Metodologia

Inicialmente é apresentado um resumo, no Capítulo 2, referente ao estado da arte em automação de diagnóstico de defeitos em mancais de rolamentos, caixas de engrenagens, tubos, entre outros; bem como sua importância na manutenção preditiva. Também são apresentados alguns requisitos básicos para estes sistemas automáticos de diagnósticos. Neste Capítulo, tentou-se enfatizar a utilização de sistemas de inferência fuzzy para diagnóstico de defeitos em mancais de rolamentos.

No Capítulo 3 são vistos alguns conceitos necessários para o entendimento do funcionamento de um sistema de inferência fuzzy. Também são listadas as etapas para a criação deste sistema de inferência.

Uma vez que normalmente as possibilidades de combinações possíveis entre os parâmetros que compõe o sistema fuzzy são numerosas, é proposta no Capítulo 5 uma metodologia para automatizar o processo de criação do sistema de inferência fuzzy. Para alcançar este objetivo, foi criado a partir desta metodologia um programa “Sistema_Fuzzy” escrito como script do MatLab®.

Neste trabalho foi utilizado um bando de dados, composto de sinais de vibração obtido de testes com mancais de rolamentos com diversos defeitos, para testar a metodologia de criação automática de um sistema de inferência fuzzy. Os parâmetros nestes testes, bem como o procedimento para executá-los, são descritos no Capítulo 6. Para realizar o pré-processamento do sinal de vibração, alguns candidatos a características escalares e vetoriais são apresentados brevemente no Capítulo 4.

Entre as diversas combinações de parâmetros para teste possíveis, aquelas que serão utilizadas neste trabalho são apresentadas no Capítulo 7. Entre estas, pode-se citar o perfil escolhido para as funções de pertinência de entrada e o tipo de pré-processamento do sinal de vibração utilizado.

No Capítulo 8 são apresentados os parâmetros utilizados para avaliar o sistema fuzzy e os parâmetros gerais para criação destes sistemas de inferência fuzzy.

Por fim, no Capítulo 9 são discutidos os resultados obtidos pelos testes.

2. RESUMO BIBLIOGRÁFICO

Neste capítulo serão apresentadas algumas referências encontradas relacionadas à importância da manutenção preditiva, principalmente quanto aos mancais de rolamentos. Também serão mostradas referências que propõe algumas ferramentas utilizadas para a análise de vibração.

Outro importante aspecto apresentado a seguir é o conceito de sistemas especialistas, principalmente relacionado ao seu emprego em diagnósticos de falhas.

Por fim, são apresentadas algumas referências encontradas que utilizam sistemas de inferência fuzzy para a detecção de defeito em rolamentos.

2.1. Manutenção Preditiva

A manutenção tornou-se importante na economia de hoje. Isto se deve principalmente à crescente exigência dos mercados, de modo a pressionar as empresas para obtenção de produtos de maior qualidade, com entrega mais rápida, e preços competitivos.

Em todos estes aspectos, a manutenção contribui de forma significativa. A maior qualidade é fornecida por um equipamento bem regulado pela manutenção. A entrega mais rápida é obtida com tempos de fabricação otimizados devido à minimização do tempo morto, e meios de transportes trabalhando em seu ponto ótimo e com alta confiabilidade. E os preços competitivos são alcançados com diminuição do tempo de paradas e quebras catastróficas dos equipamentos, o que induziria a um aumento do custo final do produto.

Uma das principais escolhas a ser feita ao se implantar a manutenção em uma planta ou equipamento, é determinar qual a estratégia mais adequada para o sistema em manutenção. Entre estas estratégias, pode-se citar, principalmente, a corretiva, preventiva e preditiva.

A escolha da estratégia que melhor atende à planta deve ser feita levando muitos fatores em consideração, porém, deve-se enfatizar principalmente a questão

de custo-benefício, observando também as questões técnicas do componente a ser enfatizado e questões de segurança pessoal.

Neste contexto, deve-se observar o desempenho esperado (confiabilidade) do equipamento e também as consequências de uma eventual falha (inoperância e influência sobre outros equipamentos). Este pensamento leva a escolha da estratégia manutenção de acordo com as características das funções exercidas pela planta ou equipamento e sua importância no contexto do restante da planta.

Deve-se enfatizar que cada elemento de uma planta pode possuir uma estratégia mais adequada, sendo, portanto, necessário trabalhar no fim, com uma mescla de todas as estratégias.

Em diversos artigos existe a discussão em quais condições é preferível a utilização da manutenção preditiva sobre as manutenções corretiva ou preventiva. Dentre estas, pode-se citar o trabalho de Zeng ⁽⁴⁹⁾ que discute a utilização dos três tipos de estratégias de manutenção dentro de uma indústria, sendo elas a corretiva, preventiva e a preditiva.

Através da pesquisa bibliográfica, foi percebida a importância da manutenção preditiva (gerenciamento da manutenção utilizando monitoramento regular das condições da máquina) para obter uma queda de custo em uma indústria ⁽²⁶⁾, podendo, neste caso, contribuir para uma diminuição de metade dos custos necessários em uma manutenção corretiva.

A manutenção preditiva é baseada no monitoramento da condição de um determinado componente da planta, observando o desenvolvimento do sintoma referente a um determinado defeito, executando tarefas de manutenção antes da condição do componente alcançar um determinado nível crítico, ou seja, a falha.

Para a sua implantação, é necessário inicialmente selecionar os componentes que são mais críticos para o nível de disponibilidade da planta inteira. Conhecendo esta informação, deve-se escolher a estratégia mais adequada para cada componente, baseando-se nas necessidades de segurança e economia ^(12,49).

Dentre as estratégias de manutenção, a preditiva é a que mantém a maior disponibilidade, porém é necessário um alto custo de implantação. Em contraste, a manutenção corretiva é mais barata, porém, deve-se levar em conta as perdas devido à indisponibilidade do equipamento.

Para a manutenção preditiva é essencial a determinação ou detecção do mínimo nível de funcionalidade de um item, por exemplo, o nível de desgaste do componente. Por este critério, deve-se esperar que o componente possua um longo período (Figura 2.1) onde apresenta o sintoma do defeito, permitindo o gerenciamento deste período de modo a encontrar a melhor hora para intervir na planta.




Figura 2.1 – Padrão de deterioração ⁽²²⁾.

2.2. Defeitos em Mancais de Rolamentos

Considera-se falha de um equipamento, a uma situação onde o equipamento ou não pode ser utilizado, ou não produz de forma correta (má qualidade), ou ainda, produz abaixo da capacidade esperada. Defeito refere-se a uma condição da peça, diferente da condição na qual ela foi projetada (uma trinca, por exemplo), que pode ou não estar causando uma falha.

O surgimento de um defeito num mancal de rolamento pode ter um alto impacto nos custos relacionados à uma possível falha do equipamento ^(5,24,25,32,34,42). Estes custos relacionados à falha do equipamento são muito superiores ao custo da troca do rolamento em si.

Um exemplo é o caso de motores elétricos ⁽³⁶⁾, onde cerca de 40 a 50% das falhas identificadas são devidos a mancais de rolamentos, conforme pode ser observado na Figura 2.2.

No catálogo da SKF ⁽³³⁾ são apresentadas diversas falhas que podem ocorrer em um mancal de rolamento. Normalmente, quando estas falhas ocorrem prematuramente (antes do fim da vida útil do rolamento), elas são causadas por falta de cuidados quanto à instalação, má ou falta de lubrificação, penetração de partículas

estranhas entre as pistas, sobrecargas, e influência de calor externo não previsto. Estas falhas podem ser melhor identificadas após a desmontagem do rolamento.




Figura 2.2 – Razões de falhas de rolamentos ⁽³⁶⁾.

Além disso, nesta referência, são apresentados alguns sintomas de falhas em rolamentos, tais como: ruídos metálicos, aumento de temperatura, etc. Além disso, são propostas possíveis causas, e algumas contramedidas aconselhadas pelo fabricante. Neste caso, estes sintomas se referem a um ponto de operação considerado como inadequado (falha), de modo que, ao observá-los, aconselha-se a troca imediata.

Como na estratégia de manutenção preditiva é necessária a observação do defeito antes que ocorra a falha, esta não é uma ferramenta que possa fornecer bons resultados. Na literatura, são apresentadas diversas outras ferramentas que apresentam melhores resultados. A principal ferramenta utilizada é a análise de vibração ^(41,32,42). Esta ferramenta será melhor discutida a seguir. Outra ferramenta também utilizada é o sinal de emissão acústica ⁽⁴²⁾.

Barkov ⁽⁴⁾ realizou um estudo referente à ocorrência de falhas em mancais de rolamentos baseado em um banco de dados russo, fazendo comparação entre mancais de eixos verticais e horizontais, e evolução de falhas.

2.3. Análise de Vibrações para Mancais de Rolamentos

O sinal de vibração de um sistema dinâmico representa suas características dinâmicas, ou seja, um padrão característico de vibração. Este padrão é denominado assinatura mecânica da máquina.

Boa parte da manutenção preditiva de máquinas rotativas se baseia em análise de vibração. Isto ocorre, pois ⁽²⁵⁾:

- o monitoramento pode ser feito durante a operação normal da máquina;
- é economicamente viável. Sensores de vibração e equipamentos de aquisição de dados tem tido seu preço bastante reduzido nos últimos anos;
- pode fornecer informação continuamente (on-line);
- pode ser utilizado para monitorar uma variedade de tipos de máquinas e equipamentos;
- sensores de vibração (acelerômetros) têm resposta confiável e precisa;
- respostas dinâmicas de rolamentos são amplamente conhecidas.

Existem diversos modos de se analisar um sinal de vibração. Um método bastante utilizado é o PSD (Densidade Espectral de Potência) ⁽¹²⁾, onde se transfere o sinal no tempo para o domínio frequencial, e deste modo pode-se observar as frequências que compõe o sinal. Através de uma análise destas frequências consegue-se diagnosticar o defeito.

Esta análise é baseada normalmente em frequências de defeitos ^(5,12,35) que podem ser calculadas previamente, e no estudo da relação entre a evolução do espectro e a progressão da falha. Neste último caso, é amplamente aceito que 80% das falhas em rolamento do tipo localizadas ocorrem passando por quatro estágios ⁽⁵⁾:

1. Neste estágio nenhum defeito é aparente visualmente, porém aparecem picos de energia em alta frequência (>5 kHz).
2. Aparece um pequeno defeito na pista, e as frequências naturais começam a serem excitadas.
3. A partir deste estágio começa a aparecer algumas frequências de passagem de defeito ou modulações de amplitude das frequências naturais.

4. As amplitudes das frequências de rotação e seus harmônicos crescem, e não se pode mais determinar o tempo restante de vida útil do rolamento.

No caso dos rolamentos que estão sendo testados neste trabalho (que possuem defeitos localizados), eles podem ser classificados como estando no 3º estágio, que seria o estágio onde é aconselhável a troca do rolamento.

Além deste método, a análise de rolamentos podem ser baseados em características paramétricas escalares, tais como ^(2,13,41,42): RMS, Valor de Pico, Kurtosis, Skewness, Fator de Crista, ER, o coeficiente da função gamma, entre outros.

Outros métodos utilizados que trabalham com parâmetros vetoriais (como o PSD), são: transformada wavelet ⁽³²⁾, modelos paramétricos auto-regressivos ⁽⁷⁾, distribuição tempo-frequência ⁽³⁰⁾, cepstrum ⁽³⁵⁾, além da análise do envelope ⁽¹⁹⁾.

Também se utilizam parâmetros escalares baseados nestes tratamentos vetoriais, tais como os coeficientes da transformada wavelet ⁽³²⁾ e amplitude de frequências características.

2.4. *Sistemas Especialistas*

Pode-se definir sistema especialista como sendo um programa projetado especificamente para representar um conhecimento humano em um domínio particular (área de especialização) ⁽³¹⁾.

Para que um sistema de diagnóstico automático seja efetivo é necessário que eles sejam capazes de simular o conhecimento e os mecanismos de inferência de especialistas humanos de forma a resolver um problema específico. Este conceito difere de outros programas convencionais uma vez que estes últimos utilizam algoritmos, fórmulas e informações prévias e precisamente definidas.

Um sistema especialista é composto basicamente de uma base de conhecimento, um mecanismo de inferência e uma interface com o usuário, conforme observado na Figura 2.3.

A aquisição de informação para um sistema especialista é feita da revisão da literatura, entrevista com os especialistas e utilizando um histórico de dados

previamente coletados. A chave do sucesso do sistema especialista é encontrar o melhor modelo que traduza estas informações, obtendo uma boa representação deste conhecimento.




Figura 2.3 – Estrutura de um sistema especialista

Como o sistema especialista depende fundamentalmente de mecanismos de inferência, é também desejável que ele seja capaz de apresentar os mecanismos lógicos de sua decisão, de forma que sua lógica possa ser verificada.

Uma das ferramentas mais utilizadas para construir sistemas especialistas eficientes são os chamados algoritmos baseados em inteligência artificial como, por exemplo: redes neurais, algoritmos genéticos e sistemas de inferência fuzzy.

Muitos dos sistemas atuais, baseados em lógica convencional, têm falhado em atender as expectativas pelas seguintes razões ⁽¹⁰⁾:

- incapacidade de imitar os processos de análise executados por especialistas;
- número finito de regras, implicando em incapacidade de atender dinamicamente à necessidade do sistema, ficando facilmente obsoleto;
- os sistemas têm dificuldades de conciliar as diferenças entre os modelos teóricos e os resultados verificados na prática.

Uma breve revisão bibliográfica mostra que além das características descritas anteriormente, sistemas especialistas de sucesso devem ser altamente adaptáveis e dinâmicos ⁽³⁾. Por adaptáveis e dinâmicos entende-se a capacidade do sistema de agregar novas informações conforme o sistema é utilizado, seja para se adaptar melhor à realidade na qual está sendo utilizado, ou para agregar continuamente novas informações que aparecerão com o contínuo monitoramento de um sistema.

No caso de sistemas de diagnóstico, um sistema especialista deve permitir realizar uma atualização contínua. Isto se deve principalmente pelo fato do comportamento físico da planta a ser diagnosticado variar durante a operação. Fica claro, portanto, a necessidade do sistema ter uma boa interface com o usuário (ou seja, amigável). Na literatura é comum encontrar esta característica do sistema fortemente associada ao sucesso do programa ⁽⁴⁵⁾.

Cabe lembrar que sistemas especialistas não dispensam o especialista. O sistema deve servir ao especialista como uma nova ferramenta para que ele possa executar as tarefas de forma mais rápida e eficiente ⁽³¹⁾.

2.5. Sistemas Automáticos de Diagnósticos de Falhas

A necessidade de um sistema automático para diagnóstico fica clara em uma planta industrial onde pode existir uma enorme quantidade diária de dados a serem analisados. Neste caso, o diagnóstico de falhas, implicaria em um custo muito alto relacionado à necessidade de pessoal especializado.

Para que a tarefa de diagnóstico realmente funcione é necessário que ocorra uma pré-análise de dados de forma que os especialistas não fiquem afogados em uma série de tarefas rotineiras e possam ter sua atenção voltada para os casos mais complicados.

Uma técnica muito usada atualmente para esta tarefa de pré-análise, no caso de diagnóstico em mancais de rolamento, é a utilização de um valor limiar de um parâmetro (RMS, Valor de Pico, ...) obtido através de sinais de aceleração (ou de outros sinais: velocidade, deslocamento, envelope, ...) do mancal para acionar um alarme de falha ⁽⁴⁰⁾, e a partir de então um especialista verifica a necessidade da troca. Esta mesma técnica pode ser utilizada para sistemas de diagnósticos de plantas industriais ⁽¹⁷⁾.

A confiabilidade deste tipo de sistema é baixa ^(46,47). Para aperfeiçoá-lo foi proposta a utilização de diversas outras técnicas. Dentre elas, pode-se citar a rede neural ^(24,34) e sistemas fuzzy ^(25,29,46,47).

Existem diversos tipos de redes neurais que foram utilizadas com o objetivo de diagnóstico de falhas em rolamento. Dentre estas, pode-se citar a MLP (Multilayer Perceptron)⁽²⁴⁾, e PNN (Probabilistic Neural Network)^(34,35).

A rede neural pode ser considerada como um grande interpolador que pode ter como entrada uma grandeza vetorial e ter como saída um vetor ou um escalar previamente definido no período de treinamento, classificando a entrada em um conjunto de estados ou padrões⁽⁴⁴⁾.

Um exemplo muito claro da utilização da rede neural com o propósito de diagnóstico de falhas é o programa ADVISOR fornecido pela Bruel & Kjaer^(9,10) que se baseia em redes neurais e sinais de vibração, para analisar e diagnosticar (detectar, classificar e estimar uma progressão) uma falha na planta em que está atuando (por exemplo, indústrias de geração de energia e petroquímicas).

Apesar da rede neural poder alcançar uma alta taxa de acerto de detecção e classificação de defeito (até 100%)⁽³⁵⁾, ela possui uma grande desvantagem pois a sua estrutura não é transparente (modelo caixa-preta ou black-box) para o usuário⁽³⁾, o que não permite a utilização do conhecimento heurístico do usuário, e nem a utilização da rede para a obtenção de uma informação compreensível referente ao problema estudado.

2.6. Sistemas Inferência Fuzzy

Um modo de superar a limitação do modelamento tipo caixa-preta utilizada pela rede neural (como observado anteriormente) é a implantação de sistemas que usam a lógica fuzzy. Uma das ferramentas mais empregadas, que utilizam este conceito, é o sistema de inferência fuzzy.

A Tabela 2.1 apresenta uma comparação geral entre os sistemas fuzzy e neural.

Além de permitir que o usuário utilize seus conhecimentos heurísticos, obtidos anteriormente, e de analisar e verificar as informações contidas dentro do sistema, o sistema de inferência fuzzy também permite o gerenciamento de uma grande quantidade de informação de naturezas diferentes.

Tabela 2.1 – Principais características de sistemas de inferência fuzzy e redes neurais ⁽⁴⁴⁾

<i>Sistemas Fuzzy</i>	<i>Sistemas Neurais</i>
Representação lingüística	Representação do tipo caixa preta
Necessário conhecimento de especialista	Necessários dados de exemplo ou função de performance
Pouca adaptação	Mecanismos de adaptação disponíveis
Tolerante à falha	Tolerante à falha
Custo computacional dependente da aplicação	Custo computacional um tanto alto
Descrições múltiplas possíveis	Descrições múltiplas possíveis

Apesar de possuir diversas vantagens, este sistema possui algumas desvantagens, citando-se, por exemplo, a ‘tediosa’ e cara tarefa de aquisição de base de conhecimento heurístico ⁽³⁾. Outra desvantagem, apesar de discutível, foi apresentada por Jeffries ⁽¹⁶⁾, que aponta a facilidade de implementá-lo sem um profundo conhecimento do funcionamento do sistema fuzzy. Isto pode resultar em sistemas de inferência teoricamente incoerentes que só alcançam o resultado esperado em condições particulares muito estreitas.

Os sistemas de inferência fuzzy não foram muito aplicados em diagnósticos de falhas em mancais de rolamento. Na pesquisa bibliográfica foram encontrados apenas quatro artigos utilizando esta idéia ^(25,29,46,47). Em todos os casos foram utilizados sinais de vibração (parâmetros escalares e vetoriais calculados a partir destes). A utilização de sinais de vibração também é observado amplamente em sistemas baseados em rede neural ^(24,34,35).

Alguns parâmetros escalares utilizadas na etapa pré-processamento (ou seja, que são utilizadas como entradas) para sistemas fuzzy, e que foram encontrados na literatura, podem ser listadas como se seguem: amplitude de frequência em faixas de frequências ou em frequências de passagem de defeito (da pista externa, da pista interna, do elemento rolante e da gaiola), autocorrelação, RMS, Kurtosis, Skewness, ER ^(46,47), entre outros. Também são utilizados estes mesmos parâmetros calculados em sinais filtrados em determinadas bandas ou o envelope dos sinais de vibração.

Além destes, foram encontradas outros parâmetros característicos que podem ser utilizados, tais como: número de picos de amplitude que passam por um

determinado nível de tensão ⁽⁴²⁾, coeficientes da transformada wavelet ⁽³²⁾, fator de crista, coeficiente da função gamma ⁽¹³⁾, valor de pico ⁽⁴¹⁾, entre outros.

Os sistemas de inferência fuzzy para diagnóstico de defeitos em mancais de rolamentos descritos na literatura possuem características limitadas, o que inviabilizaria a sua utilização na prática. O sistema apresentado por Liu ⁽²⁵⁾ só utiliza uma única característica, que não descreve adequadamente o defeito no mancal de rolamento. No apresentado por Mechefske ⁽²⁹⁾, o sistema fuzzy diferencia apenas a localização da falha (pista interna, pista externa e elemento rolante), o que limita as informações apresentadas ao usuário, não permitindo uma decisão adequada. Já em ^(46,47) o sistema é criado utilizando apenas de conhecimentos heurísticos (um trabalho extremamente fatigante, dependendo da quantidade de dados a serem tratados).

Nos casos ^(25,46,47), a entrada do sistema são características escalares obtidos do sinal de vibração. Isto se deve à necessidade de comprimir a grande quantidade de dados existente no sinal, fornecendo apenas características relevantes para descrever o defeito, e, portanto, obter um bom desempenho. Liu ⁽²⁵⁾ faz uma discussão sobre qual característica é mais relevante para este fim.

Mechefske ⁽²⁹⁾ apresentou um outro método de tratar o sistema fuzzy, utilizando o vetor do espectro do sinal de vibração como entrada. Este parâmetro vetorial também já foi utilizado em uma rede neural ⁽³⁵⁾. Porém, este vetor possui muita informação redundante e/ou irrelevante para o desempenho do sistema, aumentando o esforço computacional e, em alguns casos, prejudicando o diagnóstico.

O sistema fuzzy além de ser utilizado no diagnóstico de falhas em mancais de rolamento ^(25,29,46,47), também são encontrados sendo utilizado em diagnóstico de falhas em caixas de redução ⁽¹⁷⁾ e de plantas industriais ^(16,43), além de controles industriais, modelagem de sistemas dinâmicos, reconhecimento de padrão, entre outros ^(6, 21, 28, 38).

Existem diversas variações e combinações de lógica fuzzy e redes neurais com o objetivo de alcançar uma mistura das características apresentadas por ambos (Tabela 2.1). Entre as combinações, pode-se citar a utilização de uma rede neural para um pré-processamento dos dados de entrada do sistema fuzzy, podendo reduzir a quantidade de dados, obter classes de similaridade e/ou reduzir ruído ⁽³⁾.

Esta técnica foi aplicada para detecção de falhas em tubos de trocadores de calor em plantas nucleares ⁽⁴⁵⁾. Na técnica proposta, a rede neural foi utilizada para detectar a ocorrência de falha no tubo, enquanto o sistema de inferência fuzzy foi utilizado para determinar o tamanho da falha.

Além deste, foi proposta a construção da estrutura de uma rede neural de modo que represente diretamente um sistema de inferência fuzzy. Este novo modelo é denominado rede neuro-fuzzy ⁽³⁾.

Entre as variações de sistemas fuzzy, pode-se apresentar o fuzzy c-means (FCM) ⁽²⁸⁾. Esta técnica é um separador automático de classes de similaridades. Uma variação desta técnica é o *funcional fuzzy c-means* (FFCM) ^(17,18), que utiliza uma definição de pertinência diferente da técnica anterior.

Esta última técnica foi implantada para o diagnóstico dinâmico de falha em uma caixa de redução ⁽¹⁷⁾. Na aplicação proposta, não foi necessária a utilização de um banco de dados do equipamento. A partir de um histórico curto (durante um período de funcionamento contínuo), esta técnica determina se ocorre alguma variação significativa do sinal no último período, em relação aos períodos anteriores.

Outros métodos utilizados, ou que podem ser utilizados, para o diagnóstico de falhas são a grafos de causas-efeitos ⁽⁴³⁾, a técnica de dicotomia fuzzy ⁽⁴⁸⁾, *support vector machines* (SVMs) ⁽¹⁵⁾, entre outros.

3. SISTEMA DE INFERÊNCIA FUZZY

Os sistemas inferência fuzzy têm se mostrado bastante confiável e obtido sucesso em casos onde existem incertezas na medição, ou quando ainda não se possui um modelo matemático bem definido para estimar os parâmetros de interesse.

Através de um sistema fuzzy é possível modelar um sistema extremamente complexo de uma forma mais simples e compreensiva. Um sistema de inferência fuzzy é um método para interpretar um vetor de valores de entrada e, baseado em alguns conjuntos de regras, obter valores para o vetor de saída.

Entre as vantagens da lógica fuzzy, pode-se citar ⁽²⁸⁾:

- é conceitualmente fácil de entender;
- é flexível;
- é tolerante a dados imprecisos;
- pode modelar sistemas não-lineares de complexidades arbitrárias
- pode ser construído utilizando conhecimento de especialistas;
- é baseado na linguagem natural.

Além disso, o sistema fuzzy é um modo fácil de agregar conhecimentos de diversos especialistas (por exemplo, um especialista em análise de vibração e o operador da máquina), pelos motivos apresentados acima.

Entre as limitações do sistema fuzzy, pode-se citar ⁽³⁾:

- o seu funcionamento é altamente abstrato e heurístico;
- necessita de especialista para determinar suas regras (relações entre entrada e saída);
- não possui auto-organização e mecanismos de auto-regulação presente na rede neural.

O sistema fuzzy pode ser visto como uma metodologia para trabalhar diretamente com palavras. Com as palavras tem-se uma forma menos precisa para descrever um sistema, porém, em comparação com os números, elas estão mais

próximas à intuição humana. Portanto, trabalhando com palavras explora-se a tolerância à imprecisão.

Os sistemas de inferência fuzzy são baseados no conceito da lógica fuzzy.

3.1. Lógica Fuzzy

A lógica fuzzy (ou nebulosa) é um modo de mapear o espaço de entrada em um espaço de saída. Além deste método, podem-se utilizar outros modos de mapeamento, tais como redes neurais, equações diferenciais, sistemas especialistas, entre outros.

Neste caso, Lotfi Zadeh, o “pai” da lógica fuzzy, cita ⁽²⁸⁾: “Em quase todos os casos você pode construir o mesmo produto sem lógica fuzzy, mas fuzzy é mais rápido e barato”.

A lógica fuzzy pode ser comparada com a lógica clássica. A lógica clássica (ou booleana) trata com a definição clássica de conjuntos. Nesta definição, um certo valor pertence ou não a um determinado conjunto. No caso da lógica fuzzy, um certo valor pode pertencer a um determinado conjunto com um certo grau de pertinência.

Um outro modo de se observar a diferença entre estes dois tipos de lógica é o fato de que a lógica fuzzy é um modo para generalizar a lógica booleana (sim/não, pertencente/não pertencente, ou, 1/0), uma vez que ele trabalha com valores intermediários entre 1 e 0. Esta comparação é melhor exemplificada na Figura 3.1, onde se ilustra a classificação de altura de pessoas.

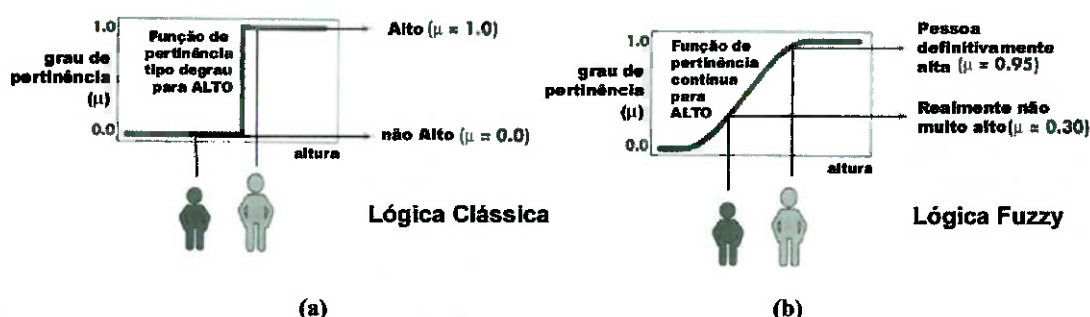


Figura 3.1 – Comparação entre lógica clássica e lógica fuzzy ⁽²⁸⁾.

Estes conjuntos definidos na lógica fuzzy são utilizados para representar conceitos vagos, tais como: próximo, longe, quente, alto, muito quente, bem lento, etc.

Um conjunto fuzzy A pode ser expresso por ⁽⁴⁴⁾:

$$A = \{x, \mu_A(x) \mid x \in X\} \quad \text{Equação 3.1}$$

Sendo X o universo de discurso ao qual o conjunto pertence, x um componente do conjunto fuzzy e μ_A é a função de pertinência.

O universo de discurso indica o domínio em que o modelamento do sistema fuzzy é válido.

A função de pertinência μ_A associa a um dado componente do universo de discurso x, o seu respectivo grau de pertinência a um determinado conjunto fuzzy. Na Figura 3.1.b, a função de pertinência é o perfil que relaciona o valor numérico da altura (x) e o grau de pertinência (μ).

3.1.1. Função de Pertinência

Como foi apresentada anteriormente, a função de pertinência μ_A associa a um dado componente x do universo de discurso X, o seu respectivo grau de pertinência a um determinado conjunto fuzzy.

Dentre os diversos perfis ou funções que são utilizados para este propósito, são apresentados a seguir as mais utilizadas.

3.1.1.1. Trapezoidal

Apresentada na Figura 3.2, ela é definida pela seguinte equação:

$$\mu_{TRAP}(x; a, b, c, d) = \begin{cases} \frac{(x-a)}{(b-a)} & a < x < b \\ 1 & b \leq x \leq c \\ \frac{(x-d)}{(c-d)} & c < x < d \end{cases} \quad \text{Equação 3.2}$$

A função pode ser obtida através dos parâmetros a , b , c e d , ou, para um caso de perfil simétrico, através do valor médio (m) e dispersão (Δ), e de dois fatores de

proporção de dispersão indicando a abertura do trapézio (f_1 e f_2). As relações entre estes fatores são:

$$\begin{aligned} a &= m - f_2 \cdot \Delta \\ b &= m - f_1 \cdot \Delta \\ c &= m + f_1 \cdot \Delta \\ d &= m + f_2 \cdot \Delta \end{aligned}$$

Equação 3.3




Figura 3.2 – Parâmetros da função trapezoidal

3.1.1.2. Triangular

Apresentada na Figura 3.3, ela é definida pela seguinte equação:

$$\mu_{TRI\Delta}(x, a, b, c) = \begin{cases} \frac{(x-a)}{(b-a)} & a < x \leq b \\ \frac{(x-c)}{(b-c)} & b < x < c \end{cases}$$

Equação 3.4

A função pode ser obtida através dos parâmetros a , b e c , ou, para um caso de perfil simétrico, através do valor médio (m) e dispersão (Δ), e de um fator de proporção de dispersão indicando a abertura do triângulo (f_1). As relações entre estes fatores são:

$$\begin{aligned} a &= m - f_1 \cdot \Delta \\ b &= m \\ c &= m + f_1 \cdot \Delta \end{aligned}$$

Equação 3.5




Figura 3.3 – Parâmetros da função triangular

3.1.1.3. Gaussiana

Apresentada na Figura 3.4, ela é definida pela seguinte equação:

$$\mu_{GAUSS}(x; m, \Delta) = e^{-\left(\frac{m-x}{\Delta}\right)^2} \quad \text{Equação 3.6}$$

A função pode ser obtida através do valor médio (m) e dispersão (Δ), e de um fator de proporção de dispersão indicando a abertura da curva gaussiana (f_l). Sendo neste caso, a dispersão Δ da Equação 6, definido pelo Δ fornecido pelo usuário multiplicado por f_l .




Figura 3.4 – Parâmetros da função gaussiana

3.1.1.4. Pi

Apresentada na Figura 3.5, ela é definida pela seguinte equação:

$$\mu_{TRI\Delta}(x; a, b) = \begin{cases} S\left(x; a-b, \frac{(a-b)}{2}, a\right) & x \leq a \\ 1 - S\left(x; a, \frac{(a+b)}{2}, a+b\right) & x > a \end{cases} \quad \text{Equação 3.7}$$

Sendo S a função sigmodal definida por:

$$S(x; a_1, a_2, a_3) = \begin{cases} 0 & x \leq a_1 \\ 2\left(\frac{x-a_1}{a_3-a_1}\right)^2 & a_1 < x \leq a_2 \\ 1 - 2\left(\frac{x-a_3}{a_3-a_1}\right)^2 & a_2 < x \leq a_3 \\ 1 & x > a_3 \end{cases} \quad \text{para } a_2 = \frac{(a_3-a_1)}{2} \quad \text{Equação 3.8}$$

A função pode ser obtida através dos parâmetros a e b , sendo a , o valor médio (m), e b , a dispersão (Δ) multiplicada por um fator de proporção de dispersão que indica a abertura da curva pi (f_I). Sendo neste caso, o Δ da Equação 6, definido pelo Δ fornecido pelo usuário multiplicado por f_I .




Figura 3.5 – Parâmetros da função pi

3.1.1.5. Beta

Apresentada na Figura 3.6, ela é definida pela seguinte equação:

$$\mu_{BETA}(x; m, \Delta) = \frac{1}{1 + \left(\frac{x - m}{\Delta} \right)^2} \quad \text{Equação 3.9}$$

A função pode ser obtida através do valor médio (m) e dispersão (Δ), e de um fator de proporção de dispersão indicando a abertura da curva gaussiana (f_I). Sendo neste caso, o Δ da Equação 8, definido pelo Δ fornecido pelo usuário multiplicado por f_I .




Figura 3.6 – Parâmetros da função beta

3.2. Operadores Lógicos

De modo análogo à lógica clássica, na lógica fuzzy existem os operadores de conjunto ⁽⁶⁾, como por exemplo: União, Intersecção e Complemento; ou na

nomenclatura da lógica booleana, OU(OR), E(AND) e NEGAÇÃO(NOT), respectivamente.

O análogo ao operador AND na lógica fuzzy é conhecido como T-norm (Triangular Norm), e é definido por:

$$\mu_{A \cap B}(x) = T_T(\mu_A(x), \mu_B(x)) \quad \text{Equação 3.10}$$

Analogamente, o análogo ao operador OR é conhecido como S-norm ou T-conorm, e é definido por:

$$\mu_{A \cup B}(x) = T_S(\mu_A(x), \mu_B(x)) \quad \text{Equação 3.11}$$

Existem diversas definições para estes operadores. Normalmente, para obter uma relação com a lógica clássica, procura-se satisfazer as propriedades da Tabela 3.1. Karnik ⁽²⁰⁾ apresenta outras leis ou propriedades que os operadores lógicos devem possuir.

Tabela 3.1 – Propriedades dos operadores lógicos fuzzy (T_T – operador Tnorm; e T_S – operador S-norm), sendo a, b e c graus de pertinência quaisquer de [0,1].

<i>Característica</i>	<i>T-norm</i>	<i>S-norm</i>
<i>Contorno</i>	$T_T(0,0) = 0, T_T(a,1) = T_T(1,a) = a$	$T_S(1,1) = 1, T_S(a,0) = T_S(0,a) = a$
<i>Monotônico</i>	$T_T(a,b) \leq T_T(c,d)$ se $a \leq c$ e $b \leq d$	$T_S(a,b) \leq T_S(c,d)$ se $a \leq c$ e $b \leq d$
<i>Comutativo</i>	$T_T(a,b) = T_T(b,a)$	$T_S(a,b) = T_S(b,a)$
<i>Associativo</i>	$T_T(a, T_T(b,c)) = T_T(T_T(a,b), c)$	$T_S(a, T_S(b,c)) = T_S(T_S(a,b), c)$

A seguir são apresentadas algumas funções que são utilizadas como operadores lógicos. Apesar de algumas delas não obedecerem as propriedades da Tabela 3.1, elas são usadas na prática.

3.2.1. Operador AND

Este operador define a intersecção entre dois conjuntos fuzzy. Para esta operação já foram apresentadas na literatura diversas variações, dentre elas, são descritos alguns tipos ⁽⁶⁾ na Tabela 3.2.

3.2.2. Operador OR

Este operador define a união entre dois conjuntos fuzzy. Análogo ao operador AND, para esta operação já foram apresentadas na literatura ⁽⁶⁾ diversas variações, sendo que, para uma dada definição do operador AND há um equivalente para o operador OR. As diferentes funções que podem definir este operador são descritas na Tabela 3.2.

Tabela 3.2 – Opções de operadores AND e OR

	AND/Intersecção (\cap)	OR/União (\cup)
Zadeh	$\min(\mu_A[x], \mu_B[y])$	$\max(\mu_A[x], \mu_B[y])$
Mean	$\frac{\mu_A[x] + \mu_B[y]}{2}$	$\frac{(2 \min(\mu_A[x], \mu_B[y]) + 4 \max(\mu_A[x], \mu_B[y]))}{6}$
Mean ²	$Mean(\cap)^2$	$Mean(\cup)^2$
Mean ^{1/2}	$\sqrt{Mean(\cap)}$	$\sqrt{Mean(\cup)}$
Produto	$\mu_A[x] \times \mu_B[y]$	$(\mu_A[x] \times \mu_B[y]) - \mu_A[x] + \mu_B[y]$
Bounded Sum	$\max(0, \mu_A[x] + \mu_B[y])$	$\min(1, \mu_A[x] + \mu_B[y])$
Yager	$1 - \min(1, ((1 - \mu_A[x])^k + (1 - \mu_B[y])^k)^{1/k})$	$\min(1, (\mu_A[x]^k + \mu_B[y]^k)^{1/k})$
Zysno	$\left(\prod_{i=1}^n \mu_i[x]\right)^{(1-\gamma)} \left(1 - \prod_{i=1}^n (1 - \mu_i[x])\right)^\gamma$	
Dubois	$\frac{\mu_A[x] \times \mu_B[y]}{\max(\mu_A[x], \mu_B[y], k)}$	$\frac{((\mu_A[x] + \mu_B[y]) - (\mu_A[x] + \mu_B[y]) - \min(\mu_A[x], \mu_B[y], 1 - k))}{\max(1 - \mu_A[x], 1 - \mu_B[y], k)}$

O mais utilizado em sistemas de inferência fuzzy é a definição dada por Zadeh, ou seja, a função de máximo e de mínimo para os Operadores OR e AND, respectivamente. Esta definição será utilizada para os dois operadores nos testes realizados neste trabalho.

3.2.3. Operador NOT

Este operador define o complemento de um conjunto fuzzy em um dado universo de discurso. Para esta operação já foram apresentadas na literatura ⁽⁶⁾ diversas variações, dentre elas, são apresentadas na Tabela 3.3 algumas destas opções.

O mais utilizado em sistemas fuzzy é aquele definido por Zadeh, e também será utilizado nos testes realizados neste trabalho.

Tabela 3.3 – Opção de operador NOT

	<i>NOT/Negação (~)</i>
<i>Zadeh</i>	$1 - \mu_A[x]$
<i>Yager</i>	$(1 - \mu_A[x]^k)^{1/k}$
<i>Sugeno</i>	$\frac{1 - \mu_A[x]}{1 + k \times \mu_A[x]}$
<i>Threshold</i>	$\begin{cases} 1 & \mu_A[x] < k \\ 0 & \mu_A[x] \geq k \end{cases}$
<i>Cosine</i>	$\frac{1}{2}(1 + \cos(\pi \times \mu_A[x]))$

3.3. Regras de Inferência

A lógica fuzzy, de maneira análoga à lógica clássica, pode ser descrita em termos de orações que relacionam causa e consequência. Estas orações são normalmente expressas na forma se-então (ou if-then). Elas são denominadas regras de inferências.

Neste caso, a diferença entre a lógica fuzzy e a clássica, é que uma vez que a segunda considera que um fato é verdadeiro ou falso (1 ou 0, respectivamente), a primeira permite trabalhar em níveis intermediários, ou graus, de veracidade (possui um índice entre 0 a 1).

Uma regra de inferência pode ser apresentada como:

IF x é A **E/OU** y **NÃO** é B **E/OU**... .. w é F **ENTÃO** u é G

Ou

Oração Consequente $\xrightarrow{\text{ENTÃO}}$ *Oração Antecedente*

Uma idéia desta regra é dada por: se a oração consequente (consequência) possui um grau de veracidade de 0,5, isto implica que o grau de pertinência da saída u , em relação ao conjunto G , também é 0,5, ou seja, a oração antecedente (causa) possui grau de veracidade de 0,5.

Na Figura 3.9 são apresentadas como exemplo de regras de inferência, as seguintes orações:

1. *se* o serviço é ruim **ou** a comida é ruim **então** a gorjeta é pouca.
2. *se* o serviço é bom **então** a gorjeta é média.
3. *se* o serviço é excelente **ou** a comida é deliciosa **então** a gorjeta é generosa.

Um outro modo de descrever uma regra de inferência, segue o seguinte padrão:

Se (IF) [Característica] é [Variável Lingüística] E/OU (AND/OR) [Característica] NÃO (NOT) é [Variável Lingüística] E/OU (AND/OR)... ..[Característica] é [Variável Lingüística] ENTÃO (THEN) [Saída] é [Variável Lingüística]

Figura 3.7 – Padrão de regra de inferência

3.4. Operador THEN

Além dos operadores lógicos de intersecção (AND), união (OR) e complemento (NOT), como pode ser observado na Figura 3.7, existe outro operador que é necessário definir, o operador THEN. Este operador define a implicação de cada regra sobre uma dada variável lingüística da saída, ou seja, ele relaciona a oração antecedente e a consequente. Esta influência pode ser definida pelas operações apresentadas na Tabela 3.4.

Na Tabela 3.4, foram utilizadas as seguintes definições: μ_{CFR} é a função de pertinência de saída da regra de inferência, após aplicar o operador THEN; μ_{PT} é o grau de veracidade da oração antecedente da regra de inferência; e μ_{CFS} é a função de pertinência de saída (oração conseqüente).

Nos testes feitos neste trabalho, foi utilizada a função *Mínimo*.

Tabela 3.4 – Opção de operador THEN

	THEN/Implicação (\leftarrow)
<i>Mínimo</i>	$\mu_{CFR}[x_i] \leftarrow \min(\mu_{PT}, \mu_{CFS}[x_i])$
<i>Produto</i>	$\mu_{CFR}[x_i] \leftarrow \mu_{PT} \times \mu_{CFS}[x_i]$

3.5. Operador de Agregação

Outro operador necessário em um sistema de inferência fuzzy é o operador de agregação de regras. Este operador une a influência de todas as regras obtidas após aplicação do operador THEN sobre o resultado final, apresentando a conseqüência do sistema como um todo devido às entradas do sistema fuzzy. Esta conseqüência pode ser definida pelas funções apresentadas na Tabela 3.5.

Tabela 3.5 – Opção de operador Agregação, sendo μ_{CFF} as funções de pertinência resultante do sistema fuzzy.

	Agregação(\leftarrow)
<i>Máximo</i>	$\mu_{CFF}[x_i] \leftarrow \max_{j=1}^n (\mu_{CFR_j}[x_i])$
<i>Soma</i>	$\mu_{CFF}[x_i] \leftarrow \min\left(1, \sum_{j=1}^n \mu_{CFR_j}[x_i]\right)$

Nos testes feitos neste trabalho, foi utilizada a função *Máximo*.

3.6. Operador de Desfuzzificação

Por fim, o operador de desfuzzificação transforma o resultado fuzzy definido no domínio fuzzy em um número escalar, que é mais fácil para o usuário interpretar. Esta transformação pode ser definida por ⁽²⁸⁾:

- Centróide;
- Bisector;
- MOM (média do máximo);
- SOM (menor dos máximos);
- LOM (maior dos máximos).

Nos testes feitos neste trabalho, foi utilizada a *Centróide*.

3.7. Inferência Fuzzy

Inferência fuzzy é o processo de formulação do mapeamento de uma dada entrada para uma saída usando lógica fuzzy. Utilizando esta base fornecida pelo sistema, o usuário pode tomar as decisões adequadas para a situação⁽²⁸⁾.

Pode-se definir dois tipos de sistemas de inferência, o proposto por Mandani e o proposto por Sugeno ⁽²⁸⁾. A diferença entre eles é o modo como modelam as saídas.

O método de inferência fuzzy proposto por Mandani é a metodologia mais utilizada. Ele considera uma função de pertinência na saída com um certo perfil, de modo que a saída desfuzzificada pode ser obtida através das propriedades de área das saídas agregadas de todas as regras.

Um sistema fuzzy pode ser dividido em cinco etapas, sendo eles:

1. Fuzzificação de entrada;
2. Aplicação dos operadores fuzzy AND e/ou OR e/ou NOT (Item 3.2);
3. Aplicação do operador THEN (Implicação – Item 3.4);
4. Agregar as saídas de todas as regras (Oper. de Agregação – Item 3.5);
5. Desfuzzificação (Item 3.6).

Este processo pode ser resumido na Figura 3.8 e exemplificado na Figura 3.9.

Este modelo possui as seguintes vantagens:

- o modelo é intuitivo;
- é amplamente aceito;
- é o mais indicado para trabalhar com entradas fornecidos por pessoas.




Figura 3.8 – Diagrama do processo de inferência fuzzy⁽²⁸⁾




Figura 3.9 – Exemplo do processo de inferência fuzzy com modelo Mandani, considerando alguns tipos de operadores²⁸.

O método de inferência proposto por Sugeno é similar ao proposto por Mandani, porém, ele considera que a saída é uma constante ou uma função linear. Deste modo, tem-se que para um modelo fuzzy Sugeno de ordem zero, a regra de inferência toma o seguinte perfil:

IF x é A E/OU y NÃO é B E/OU... ..w é F ENTÃO u = k

Onde k é um valor constante dentro do universo de discurso da saída.

A Figura 3.10 apresenta um exemplo deste processo, sendo que as saídas podem ser denominadas *singletons*.




Figura 3.10 – Exemplo do processo de inferência fuzzy com modelo Sugeno, considerando alguns tipos de operadores²⁸.

Um outro tipo de modelo Sugeno utilizado é o de primeira ordem, cuja regra de inferência toma o seguinte perfil:

IF x é A **E/OU** y **NÃO** é B **E/OU**... .. w é F **ENTÃO** $u = p.x + q.y + r$

Sendo p , q e r constantes. Neste caso, considera-se que os *singletons* deslocam-se dentro do universo de discurso conforme as entradas do sistema fuzzy. Deste modo, além da amplitude da saída depender da entrada, a sua localização no universo de discurso também dependerá.

Pode-se apresentar como vantagem do modelo Sugeno:

- eficiência computacional;
- um melhor modelamento de sistemas lineares, processos de otimização e técnicas adaptativas;
- garante-se a continuidade da saída do sistema;

3.8. Implantação de um Sistema de Inferência Fuzzy

Conforme visto anteriormente, um sistema de inferência fuzzy é um método que permite modelar um sistema através de regras simples, utilizando os conceitos de lógica fuzzy ^(21,28). A estrutura de um sistema de inferência fuzzy pode ser esquematizado como é mostrado na Figura 3.11.

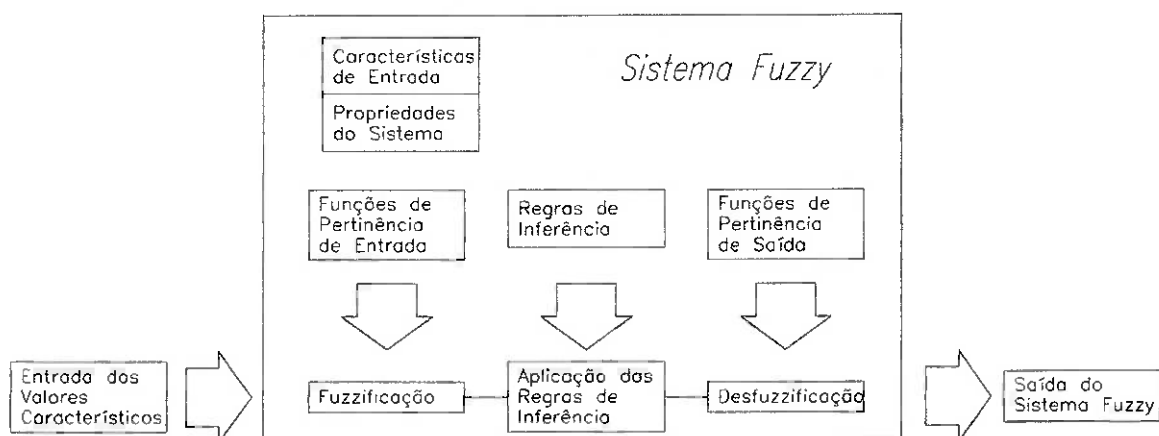


Figura 3.11 – Estrutura de um Sistema Fuzzy

Como pode ser observado pela estrutura acima, o criador do sistema de inferência fuzzy deve fornecer as seguintes informações iniciais:

- definir os valores característicos de entrada do sistema de inferência;
- as funções de pertinência de entrada – para a etapa da fuzzificação dos valores característicos;
- as regras de inferência que regem o sistema fuzzy;
- definir os parâmetros operacionais do sistema fuzzy, para determinar como o sistema se comportará:
 - tipo de operador AND, OR e NOT da regra de inferência;
 - tipo de operador THEN (ou conclusão);
 - tipo de operador de agregação;
 - tipo de operador de desfuzzificação;
 - valor limiar α .

- as funções de pertinência de saída – para a etapa da desfuzzificação da saída do sistema de inferência fuzzy.

Normalmente, na implantação de um sistema de inferência fuzzy deste tipo, são necessários pelo menos dois grupos de especialistas, um na área em questão (por exemplo, manutenção de máquinas – especialistas do problema), e o outro composto por implantadores ou projetistas do sistema fuzzy (especialista do sistema fuzzy).

Inicialmente, os especialistas do problema devem definir quais os valores característicos que melhor definem o fenômeno a ser observado, além das saídas esperadas para o sistema fuzzy (por exemplo, classes de defeitos no caso de um sistema de diagnóstico).

Posteriormente, ele deve fornecer os dados necessários ao especialista do sistema fuzzy para este compor as funções de pertinência de entrada e de saída. Uma outra informação, também muito importante, que o especialista do problema deve fornecer ao implantador, são as regras de inferência deste problema. Ou seja, a relação entre causa e consequência.

Além disso, através de testes, ou experiência do especialista do sistema fuzzy, são definidos os parâmetros operacionais do sistema fuzzy.

Após um projeto inicial, deve-se verificar quais as características que permitirá ao sistema obter a melhor resposta com o menor esforço computacional, bem como, quais as propriedades que melhor simulam o sistema a ser modelado.

Vale ressaltar que no processo de criação do sistema de inferência fuzzy é necessária uma grande interação de informação entre o especialista do problema e o projetista do sistema fuzzy.

Mesmo após a implantação, deve-se haver a preocupação de atualizar os conhecimentos contidos no sistema fuzzy, de modo a adequá-lo às novas condições do fenômeno observado.

4. ANÁLISE DE VIBRAÇÃO

No item 2.3 foram colocadas algumas razões de se utilizar vibração mecânica para o diagnóstico de defeitos em mancais de rolamentos.

Como será usado neste caso um banco de dados de vibração, neste capítulo serão resumidos alguns parâmetros que são normalmente utilizados para este tipo de sinal.

Existem diversas literaturas a respeito de parâmetros característicos utilizados para diagnosticar defeitos em mancais de rolamentos. Estes parâmetros podem ser descritos na forma de valores escalares, ou em termos de valores vetoriais. Como exemplos do primeiro caso, tem-se RMS, Kurtosis, Skewness e ER. No segundo caso, encontra-se, por exemplo, o espectro de frequência. A seguir são apresentadas algumas destas características.

O principal objetivo do estudo destes parâmetros é encontrar um grupo que melhor diagnostique um mancal de rolamento (entre estas tarefas, encontra-se diferenciar a condição normal de uma com defeito e a classificação do tipo de defeito).

Existem diversas fontes na literaturas onde se discute a eficiência destes parâmetros no diagnóstico de defeito em mancais de rolamentos ^(2,13,25,39,41), porém, o que se pode realmente afirmar, é que existem condições particulares onde cada um deles é mais apropriado.

4.1. RMS ou Valor Eficaz

Este é o mais conhecido parâmetro com propósito de diagnóstico, sendo utilizado por normas para especificar níveis de vibração ^(1,14). O RMS fornece um valor relacionado com o nível de energia ou potência de um dado sinal. Ela é obtida pela seguinte fórmula para um sinal contínuo:

$$V_{ef}(x(t)) = RMS(x(t)) = \sqrt{\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T (x(t))^2 dt} \quad \text{Equação 4.1}$$

No caso de um sinal discreto composto por N pontos, esta fórmula se torna:

$$V_{ef}(x(t)) = RMS(x(t)) = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad \text{Equação 4.2}$$

Quando o sinal é centrado, este parâmetro equivale ao momento estatístico de segunda ordem, ou seja, o desvio padrão. Esta condição é normalmente razoável no caso de um sinal de vibração, porque, na maioria destes casos, a máquina permanece parada em um determinado lugar (nível de aceleração média nula).

Nas normas referentes à vibração de máquinas, este parâmetro é utilizado para sinais em termos de velocidade. Neste trabalho, ele será utilizado diretamente no sinal de aceleração que compõe o banco de dados.

Na indústria, o RMS é o parâmetro mais usado para alarme de vibração.

4.2. Skewness

O skewness ⁽¹³⁾ é um parâmetro adimensional que é função do momento estatístico de terceira ordem do sinal, sendo normalizado pelo desvio padrão σ , ou seja:

$$Sk(x(t)) = \frac{1}{N \times \sigma^3} \sum_{i=1}^N \left(x_i - \bar{x} \right)^3 \quad \text{Equação 4.3}$$

Sendo \bar{x} o valor médio do sinal.

Este parâmetro representa a assimetria da função de distribuição de probabilidade do sinal. Neste caso, para um sinal com distribuição gaussiana tem-se um valor nulo.

4.3. Kurtosis

A kurtosis ⁽¹³⁾ é um parâmetro adimensional que é função do momento estatístico de quarta ordem do sinal, sendo normalizado pelo desvio padrão σ , ou seja:

$$Kurt(x(t)) = \frac{1}{N \times \sigma^4} \sum_{i=1}^N \left(x_i - \bar{x} \right)^4 \quad \text{Equação 4.4}$$

Este parâmetro representa o grau de achatamento da função de distribuição de probabilidade do sinal. No caso de um sinal com distribuição gaussiana obtém-se um valor 3.

4.4. Valor de Pico

É o valor de pico máximo de um dado sinal no tempo ⁽²⁵⁾. Uma vez que este parâmetro é altamente sensível ao ruído, normalmente se escolhe uma média de valores de picos máximos de M sinais (Equação 4.5) ou dos valores de picos que ultrapassam 90% do valor de pico global (Equação 4.6).

$$X_{máx}(x(t)) = média \left(\max_{i=1}^M (x_M(t)) \right) \quad \text{Equação 4.5}$$

$$X_{máx}(x(t)) = média(x_i > 0.9 \times \max(x[t])) \quad \text{Equação 4.6}$$

4.5. Fator de Crista

O fator de crista é um parâmetro definido pelo seguinte quociente ⁽¹³⁾:

$$Fc(x(t)) = \frac{X_{máx}(x(t))}{Kurt(x(t))} \quad \text{Equação 4.7}$$

4.6. Fator K

É um fator que combina a kurtosis e o valor eficaz ⁽²⁾, dada pela seguinte função:

$$Fk(x(t)) = V_{ef}(x(t)) \times Kurt(x(t)) \quad \text{Equação 4.8}$$

4.7. Densidade Espectral de Frequência ou PSD

Uma das principais formas de se representar um sinal no domínio frequencial é utilizando a densidade espectral de frequência, ou PSD. Ela é definida como sendo a Transformada de Fourier (TF) da função de autocorrelação do sinal.

Esta representação no domínio frequencial pode ser estimada utilizando os métodos do periodograma, cujo método de Welch pertence. Estes métodos consideram uma média de diversos sinais obtidos a partir da transformada de Fourier do sinal original⁽³⁷⁾.

O método de Welch, em particular, utiliza a seguinte definição:

$$X[f] = \frac{1}{L \times M \times U} \sum_{i=0}^{L-1} \left| TF[x_M^i[l] \bullet \gamma_M[l]] \right| \quad \text{Equação 4.9}$$

Onde:

x_M^i é o sinal com a i ésima porta temporal com dimensão M

M é o tamanho da janela temporal;

L é o número de janelas temporais;

γ_M é a i ésima janela temporal de ponderação;

U é um fator de normalização da energia da janela de ponderação, obtida por:

$$U = \frac{1}{M} \sum_{n=0}^{M-1} (\gamma_M[l])^2 \quad \text{Equação 4.10}$$

Sendo \bullet um operador de multiplicação de cada componente do vetor.

A janela de ponderação normalmente utilizada é a de Hanning.

4.8. Envelope

O envelope⁽³⁵⁾ de um sinal é a sua envoltória, ou seja, um outro sinal no tempo que o envolve. A partir dele, obtém-se as possíveis modulações aplicadas a este sinal. A informação mais utilizada desta ferramenta é o seu espectro, que informa a frequência de modulação de amplitude do sinal.

Como normalmente as frequências excitadas por um defeito são as naturais, ou seja, em altas frequências, e conhecendo, por modelamento, que lateralmente a

estas existe o aparecimento das frequências de defeito (item 4.10) modulando o sinal, esta ferramenta permite observar estas frequências em uma banda mais baixa.

O sinal de envelope pode ser calculado pela transformada de Hilbert ou pela seguinte algoritmo:

$$Env[x[t]] = |TFI(Z[f])| \quad \text{Equação 4.11}$$

Onde TFI é a transformada de Fourier inversa, e Z é obtido por:

$$Z[f] = \begin{cases} 2 \times TF(x(t)) & \text{para } f \geq 0 \\ 0 & \text{para } f < 0 \end{cases} \quad \text{Equação 4.12}$$

Sendo TF a transformada de Fourier.

4.9. ER

ER^(2,35) é a energia residual de um dado sinal. Ela é obtida pela diferença entre o espectro de frequência do sinal ($X[f_i]$) e o espectro de um sinal considerado como sendo normal ($X_{normal}[f_i]$), sendo definido como sendo:

$$ER(x[t], x_{normal}[t]) = \frac{1}{N_{espectro}} \sum_{f_i=1}^{N_{espectro}} |X[f_i] - X_{normal}[f_i]| \quad \text{Equação 4.13}$$

Onde $N_{espectro}$ é o número de pontos do espectro de frequência.

4.10. Frequências de Defeitos em Rolamento

No caso da ocorrência de defeitos localizados em mancais de rolamentos, é possível, através de modelamentos que desconsideram escorregamentos dos elementos rolantes, determinar as frequências das vibrações (radiais e axiais) geradas por estes defeitos, e, portanto, a assinatura mecânica das falhas.

Este modelo é obtido através da análise cinemática do rolamento, considerando a geometria e as características cinemáticas dos componentes do rolamento. As frequências de defeito são obtidas pelas equações apresentadas na Tabela 4.1.

Tabela 4.1 – Frequência de defeitos em rolamento

	<i>Equação</i>
<i>Frequência de gaiola</i>	$\omega_G = \frac{\omega_s}{2} \left(1 - \frac{d}{D} \cos(\alpha_c) \right)$
<i>Frequência de rotação do elemento</i>	$\omega_B = \frac{D \cdot \omega_s}{2 \cdot d} \left(1 - \frac{d^2}{D^2} \cos^2(\alpha_c) \right)$
<i>Frequência de defeito na pista externa</i>	$\omega_{DE} = Z \cdot \omega_G$
<i>Frequência de defeito na pista interna</i>	$\omega_{DI} = Z \cdot (\omega_s - \omega_G)$
<i>Frequência de defeito no elemento</i>	$\omega_{DB} = 2 \cdot \omega_B$

Onde ω_s é a rotação do eixo, d o diâmetro do elemento rolante, D o diâmetro da trajetória do elemento rolante, α_c o ângulo de contato, e Z o número de elemento rolantes.

4.11. Razão de Pico

É um parâmetro definido em relação aos picos de frequência referente a uma dada frequência ⁽³⁵⁾, e, portanto obtido pelo espectro de frequência considerando conhecidas as frequências de defeito de um rolamento. Ele é dado pela seguinte relação:

$$Rp(x(t)) = \frac{N_{\text{espectro}} \times \sum_{j=1}^n X_{f(j)}}{\sum_{j=1}^{N_{\text{espectro}}} X_{f(j)}} \quad \text{Equação 4.14}$$

Ou seja, a razão entre as amplitudes de n harmônicas da frequência característica de defeito e a soma de todas as amplitudes de frequência do espectro do sinal. Onde N_{espectro} é o número de pontos do espectro de frequência.

5. CRIAÇÃO DE SISTEMA FUZZY AUTOMATIZADO

Conforme foi citado na revisão bibliográfica (Capítulo 3), uma das principais desvantagens ou limitações de um sistema fuzzy é a necessidade de um especialista do problema para determinar suas funções de pertinência e regras de inferência. Isto implica na necessidade de um trabalho um tanto ‘tedioso’.

Por isto, está sendo proposta neste trabalho uma nova metodologia para criar um sistema de inferência fuzzy automaticamente. Para tanto, esta metodologia está baseada na utilização de banco de dados, ao contrário da maioria dos sistemas fuzzy onde sua criação é feita através de conhecimentos heurísticos de especialistas.

5.1. Metodologia

Entre os problemas relacionados com a dificuldade de se criar um sistema fuzzy, pode-se destacar dois, a obtenção e construção das funções de pertinência e das regras de inferência.

A seguir, será proposta uma metodologia que permite automatizar estes dois processos. Neste caso, a importância do especialista na criação do sistema de inferência fuzzy é basicamente na escolha dos valores característicos que melhor descreve o fenômeno a ser observado e na verificação da coerência dos resultados obtidos.

5.1.1. Obtenção das Funções de Pertinência

O banco de dados utilizado nesta metodologia é composto de conjuntos de sinais de vibrações para cada *condição a ser identificada* (parâmetros de interesse, neste caso, tipo de defeito do rolamento), e obtidas em diversas *condições experimentais* (parâmetros que não se pretende diagnosticar, tais como rotação do eixo ou carga). Neste trabalho será utilizado o banco de dados que será apresentado no Capítulo 6.

Inicialmente, deve-se escolher os valores característicos dos sinais de vibrações que serão utilizados como entrada do sistema de inferência fuzzy. A partir do banco de dados, são calculados os valores característicos escolhidos, para cada sinal, utilizando as fórmulas citadas no Capítulo 4.

Para uma dada *condição experimental* definida, é calculada a média de cada valor característico e o seu respectivo desvio padrão. Portanto, no fim o usuário possuirá um novo banco de dados composto de médias e desvios padrões para cada *condição a ser identificada* e cada *condição experimental*.

Posteriormente, é definido para cada valor característico um tipo de perfil de função de pertinência, que o represente melhor. Com cada valor médio e desvio padrão é criado uma função de pertinência com as equações apresentadas no item 3.1.1. Antes disto, deve-se definir os fatores de proporção de dispersão (f_1 e f_2) para o perfil da função de pertinência.

Além desta metodologia automatizar a criação das funções de pertinência, ela também fornece um significado estatístico a estas.

As funções de pertinência criadas a partir das características de uma *condição a ser identificada* são agrupadas e relacionadas a uma variável lingüística.

No exemplo da Figura 5.1 é possível ilustrar a aplicação desta metodologia. No caso do valor característico “Skewness”, são apresentadas seis *condições a serem identificadas* ou variáveis lingüísticas (*Normal*, *RiscadoExt*, *Corrosao1Ext*, *Corrosao2Ext*, *FuradoExt* e *RiscadoInt*). Para cada condição a ser identificada, existe um conjunto de funções de pertinência que a descrevem. Cada função de pertinência foi calculada a partir de uma *condição experimental* (neste caso, uma dada rotação e carga – ver Capítulo 6).

Uma das vantagens desta metodologia, é que, por exemplo, uma variável lingüística “PRÓXIMO” pode ser definida em duas posições distintas dentro do universo de discurso.

Em relação à criação de um sistema fuzzy, outra tarefa realizada pelo especialista, seria a criação das regras de inferência que relacionam a entrada com a saída.

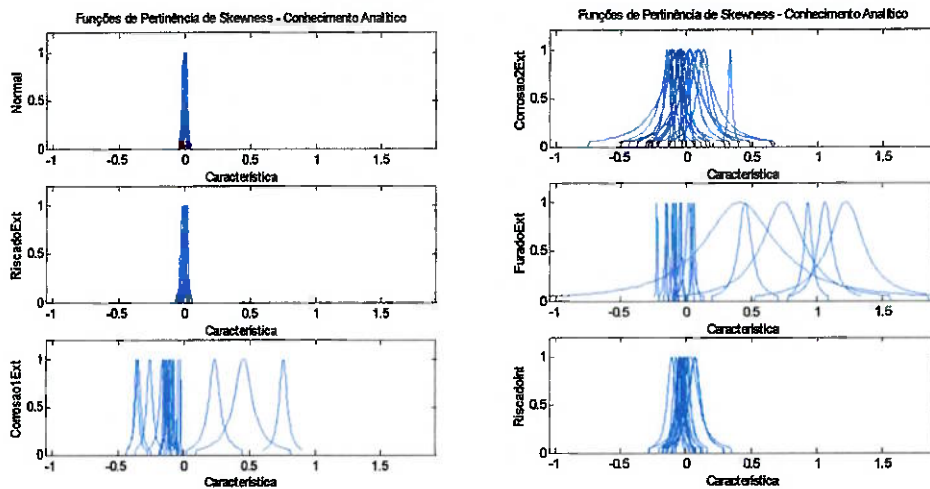


Figura 5.1 – Exemplo de Conjunto de Função de Pertinência para uma determinada característica. Cada gráfico com um conjunto de curvas está relacionado a uma variável linguística (Normal, RiscadoExt, etc).

O universo de discurso é definido por $[-1.1, 1.8]$, como pode ser verificado na abscissa.

5.1.2. Obtenção das Regras de Inferência

Uma vez que as funções de pertinência foram criadas utilizando o procedimento descrito acima, deve-se definir as regras de inferência que regem o sistema fuzzy.

Neste caso, definiu-se uma regra fuzzy padrão. Para descrevê-lo, denominou-se cada *condição a ser identificada* como sendo $Def(i)$, cada valor característico de entrada como sendo $X(j)$, cada função de pertinência relacionada a uma *condição a ser identificada* como sendo $N(i,j,k)$ e a saída como sendo $Y(i)$.

Sendo que:

$i=1...n$ (número de *condições a serem identificadas*);

$j=1...m$ (número de valores característicos de entrada) e;

$k=1...p(i,j)$ (número de funções de pertinência relacionada a uma *condição a ser identificada* e uma característica)

A regra padrão seria:

$$SE \{ [X(1)] \text{ é } [N(i,1,1)] \text{ OU } [X(1)] \text{ é } [N(i,1,2)] \text{ OU ... OU } [X(1)] \text{ é } [N(i,1,p(i,1))] \} E$$

$$\{ [X(2)] \text{ é } [N(i,2,1)] \text{ OU } [X(2)] \text{ é } [N(i,2,2)] \text{ OU ... OU } [X(2)] \text{ é } [N(i,2,p(i,1))] \} E ... E$$

$$\{ [X(m)] \text{ é } [N(i,m,1)] \text{ OU } [X(m)] \text{ é } [N(i,m,2)] \text{ OU ... OU } [X(m)] \text{ é } [N(i,m,p(i,1))] \}$$

$$ENTÃO [Y(i)] \text{ é } [Def(i)]$$

Figura 5.2 – Regra de Inferência Padrão

O sistema de inferência fuzzy seria composto de n (número de *condições a serem identificadas*) destas regras de inferência.

Um modo de interpretar este conjunto de regras de inferência é: se a entrada do sistema fuzzy é próxima a uma condição apresentada na fase de criação do sistema fuzzy, o fenômeno que está sendo descrito por esta entrada é esta condição. Esta verificação de proximidade é feita comparando todas os valores característicos definidos no sistema fuzzy.

O operador E na regra da Figura 5.2, pode ser substituído por um operador OU , mudando a interpretação da regra. Neste trabalho só foi utilizado o operador E , com a interpretação apresentada acima.

5.2. Característica do Programa “Sistema_Fuzzy”

Para implementar a metodologia apresentada anteriormente, foi criado o programa “Sistema_Fuzzy”. Este programa foi feito como script do MatLab[®]. Neste programa teve-se grande preocupação quanto à interface com o usuário. Todas as janelas gráficas apresentadas ao longo deste texto pertencem a este programa.

Este programa foi desenvolvido para obter uma maior flexibilidade do sistema fuzzy de modo a permitir automatizar todos os processos de criação e execução do sistema fuzzy.

A principal característica deste programa é que ele permite utilizar funções de pertinência obtidas tanto através de conhecimento heurístico (denominado no programa como sendo *Conhecimento Heurístico*) quanto através da metodologia apresentada acima (denominada no programa como sendo *Conhecimento Analítico*). Esta diferença é mostrada na Figura 5.3.

Do mesmo modo, neste programa pode-se utilizar também a regra de inferência definida na metodologia apresentada acima e também por regras de inferência obtidas por conhecimento heurístico do especialista.

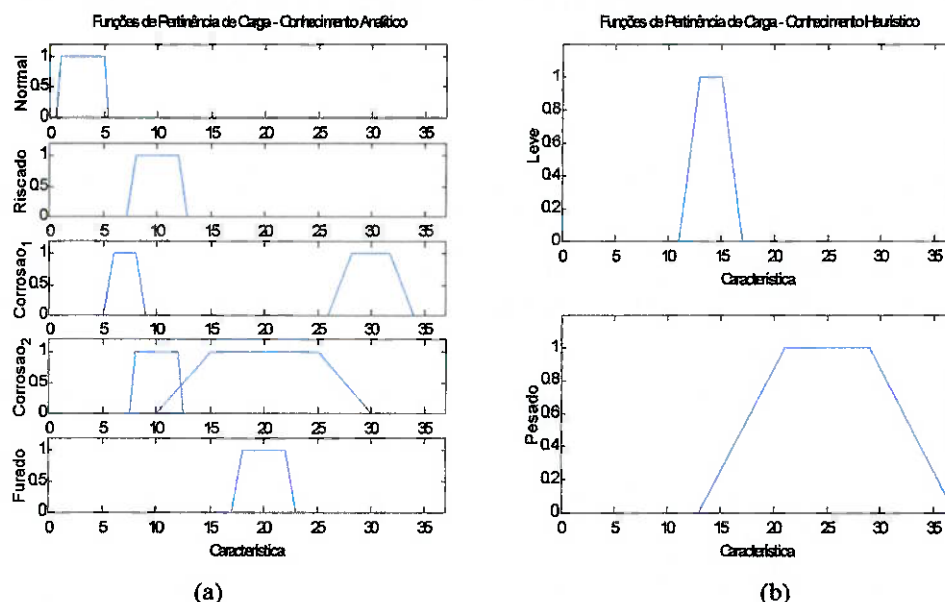


Figura 5.3 – Exemplo de Conjunto de Função de Pertinência para uma determinada característica. À esquerda (a) está a parte relacionada ao conhecimento analítico e à direita (b) a parte utilizada para aplicação dos conhecimentos heurísticos.

Como neste trabalho preocupou-se mais com a implantação da metodologia, só foi utilizada a parte do programa relacionada com os *Conhecimentos Analíticos* (obtidos pela metodologia descrita anteriormente).

A seguir serão descritas algumas características deste programa.

5.2.1. Funções de Pertinência

Cada valor característico de entrada é relacionado com um perfil de função de pertinência. As opções de perfis, que podem ser escolhidas pelo usuário, são as apresentadas no item 3.1.1, ou seja:

- Trapezoidal
- Triangular
- Gaussiana
- Pi

- Beta

Na fase de criação do sistema fuzzy, os parâmetros que descrevem a função de pertinência (valor médio e desvio padrão dos valores característicos) podem ser inseridos no sistema fuzzy através de uma interface gráfica, ou, como foi utilizado neste trabalho, automaticamente, utilizando uma função escrita em MatLab® específica a um grupo de variáveis características.

5.2.2. Operadores Lógicos

Os operadores lógicos que podem ser utilizados neste programa, são os mesmos apresentados no item 3.2, ou seja, para os operadores AND e OR:

- Zadeh
- Mean
- Mean²
- Mean^{1/2}
- Produto
- Bounded Sum
- Yager
- Zysno
- Dubois.

E para o operador NOT:

- Zadeh
- Yager
- Sugeno
- Threshold
- Cosine

5.2.3. Operador THEN

As funções que podem ser utilizadas para este operador, são as mesmas descritas no item 3.4, ou seja:

- Mínimo
- Produto

5.2.4. Operador de Agregação

As funções que podem ser utilizadas para este operador, são as mesmas descritas no item 3.5, ou seja:

- Máximo
- Soma

5.2.5. Operador de Desfuzzificação

As funções que podem ser utilizadas para este operador, são as mesmas descritas no item 3.6, ou seja:

- Centróide
- Bisetor
- MOM (média do máximo)
- SOM (menor dos máximos)
- LOM (maior dos máximos)

5.2.6. Valor Alfa (α)

Este valor define a sensibilidade do sistema fuzzy, de modo que um resultado após as operações lógicas AND ou OR menor que o valor alfa é considerado como sendo nulo. Este valor é escolhido baseado em conhecimentos empíricos do criador do sistema fuzzy.

5.2.7. Discretização (N_{discret})

Uma característica específica do programa “Sistema_Fuzzy”, é a discretização das funções de pertinência. A discretização é necessária para a execução das operações de agregação e de desfuzzificação. Por isso, o usuário deve fornecer ao programa o número de pontos que as funções de pertinência serão discretizadas. Esta escolha deve balancear o fato que um número de pontos muito grande torna o sistema muito lento, porém, ele permite definir mais pontos que compõe o universo de discurso.

5.2.8. Universo de Discurso

Neste programa, o universo de discurso é obtido automaticamente através dos valores máximos e mínimos para cada conjunto de funções de pertinência de uma característica.

5.2.9. Regras de Inferência

Além da regra padrão definida na Figura 5.2, referente aos *Conhecimentos Analíticos*, o usuário também pode definir as regras de inferências baseadas em *Conhecimentos Heurísticos*. Estas regras são escritas com a seguinte estrutura:

Se (IF) [Característica] é [Variável Lingüística] E/OU (AND/OR) [Característica] NÃO (NOT) é [Variável Lingüística] E/OU (AND/OR)... ...[Característica] é [Variável Lingüística] ENTÃO (THEN) [Saída] é [Variável Lingüística]

Figura 5.4 – Estrutura de uma Regra de Inferência

Estas últimas regras são obtidas a partir de conhecimentos adquiridos de especialistas, através, normalmente, de entrevistas.

Cada regra de inferência possui um peso de relevância de 0 a 1 em relação às outras regras (conforme a Figura 5.5), que é escolhido empiricamente pelo usuário. A regra padrão proposta na metodologia é representada nesta mesma figura como

Operador Geral AND, enquanto os outros são descritos em sequência. Ao lado de cada regra são colocados os seus respectivos pesos de relevância.

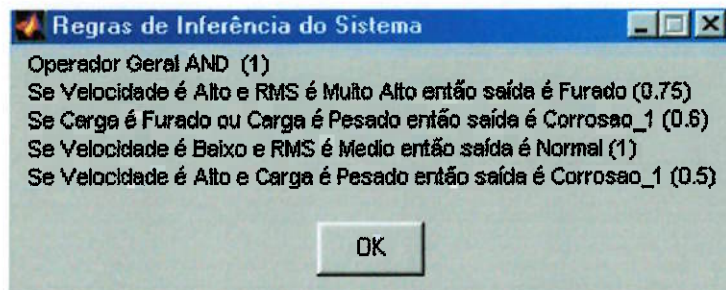


Figura 5.5 – Exemplo da visualização das regras de inferência

5.2.10. Teste com o programa “Sistema_Fuzzy”

Nesta parte do programa, o usuário poderá testar se um dado sinal de vibração é descrito por alguma das *condições a serem identificadas*, representadas no sistema fuzzy criado anteriormente. Como entrada, deve-se fornecer os valores característicos referentes a uma dada condição de teste, obtendo como saída a função de pertinência resultante, bem como o seu respectivo valor desfuzzificado (Figura 5.6).

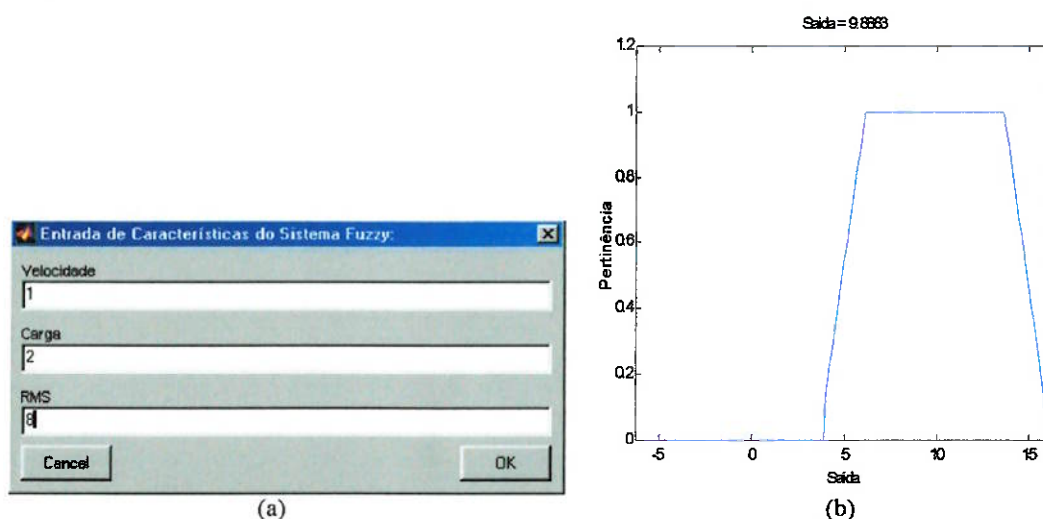


Figura 5.6 – (a) Exemplo da janela de entrada das variáveis características (Velocidade- 1; Carga- 2; e RMS- 8) e (b) de uma saída com respectiva saída desfuzzificada (9.8883) e função de pertinência resultante

No exemplo da Figura 5.6, o valor desfuzzificado é um valor de 0 a 10 que representa o grau de proximidade de algum dos defeitos de rolamentos descritos no sistema fuzzy.

Além deste valor de saída, as amplitudes resultantes das regras de cada possível saída também são fornecidas. Deste modo, o usuário conhecerá não apenas o valor desfuzzificado, mas também todas as funções de pertinência de saída ativadas.

Neste programa também pode ser fornecido o sinal de vibração como entrada, permitindo ao sistema calcular as variáveis características e simplificando o trabalho do usuário, necessitando apenas definir as funções que descrevem as características.

5.3. Etapas de Criação de um Sistema Fuzzy

Para criar um sistema de inferência fuzzy com o programa “Sistema_Fuzzy”, o usuário deve inicialmente definir as características ou valores característicos de entrada do sistema fuzzy. Em seguida o usuário deve escolher um tipo de perfil de função de pertinência relacionada a cada uma destas características e informá-lo ao programa. Nestas funções de pertinência incluem-se tanto às relacionadas aos ***Conhecimentos Analíticos*** quanto aos ***Conhecimentos Heurísticos***.

Analogamente, o usuário deve definir as funções de pertinência relacionadas à saída do sistema fuzzy, definindo também as suas respectivas denominações. Estas funções possuem as mesmas características das funções de pertinência de entrada (ou seja, das características), sendo permitido apenas criar funções de pertinência de um único perfil previamente escolhido.

Posteriormente, as regras de inferência obtidas por ***Conhecimentos Heurísticos*** devem ser definidas pelo usuário, bem como os seus respectivos pesos de relevância.

Por fim, o usuário deve definir os parâmetros ou propriedades que regem o sistema fuzzy. Estes parâmetros são apresentados na Figura 5.7.

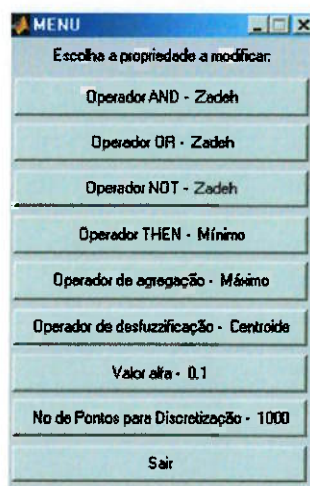


Figura 5.7 – Propriedades de um sistema de inferência fuzzy

6. BANCO DE DADOS EXPERIMENTAL

6.1. Amostras

O banco de dados criado foi obtido utilizando rolamentos rígidos de esferas desmontáveis B015TVP da FAG (Figura 6.1) ⁽⁸⁾, cujas características geométricas são apresentadas na Tabela 6.1.




Figura 6.1– Rolamento B015TVP da FAG (a) montado e (b) desmontado

Tabela 6.1 – Características Geométricas do Rolamento B015TVP

Diâmetro do Elemento Rolante (mm)	d	7,2
Diâmetro da Trajetória do Elemento (mm)	D	27,6
Largura do Rolamento (mm)	B	10,0
Ângulo de Contato ($^{\circ}$)	α_c	0
Número de Esferas	Z	10




Figura 6.2 – Geometria do Rolamento

Ele é composto de sinais de aceleração obtidos de rolamentos normais e com defeitos em classes de condições conforme mostradas na Tabela 6.2. Estes defeitos, localizados tanto na pista externa (Figura 6.3) quanto na pista interna (Figura 6.4), são um pequeno furo, corrosão 1 (faixa transversal exposta a água do mar sintética por 8 horas), corrosão 2 (idem ao anterior, com tempo de exposição de 24 horas) e pista integralmente riscada. Através do controle da rotação do eixo, cada uma destas condições foi estudada em seis diferentes rotações (de 400 a 1400 rpm), e para cada rotação foram aplicadas três diferentes cargas radiais (200 400 e 600 N).

Tabela 6.2 – Classes amostradas

Defeito/Normal	Localização	Rotação (rpm)	Carga (N)
Normal		400	
Riscado	Pista Externa Pista Interna	600	200
Corrosão 1		800	400
Corrosão 2		1000	600
Furado		1200	
		1400	



(a)



(b)



(c)



(d)

Figura 6.3 – Defeitos em Rolamentos na Pista Externa: (a) Furado, (b) Riscado, (c) Corrosão 1, e (d) Corrosão 2




Figura 6.4 – Defeitos em Rolamentos na Pista interna: (a) Furado, (b) Riscado, (c) Corrosão 1, e (d) Corrosão 2

Quanto à sequência de aquisição de sinais, foram obtidas inicialmente, para cada rolamento com um determinado defeito, 5 amostras em cada condição de velocidade de rotação e de carga aplicada. Posteriormente, o rolamento é desmontado e montado novamente, e foi retirado um novo conjunto de 5 amostras. Após realizar a aquisição com todos rolamentos com defeito e com o normal, este mesmo procedimento é realizado novamente. Cada conjunto de 5 amostra é denominado neste trabalho como sequência.

Portanto, obteve-se um banco de dados composto de 20 amostras (4 sequências) de cada condição de sistema mostrado na Tabela 6.2.

6.2. *Aparato Experimental*

Para a aquisição dos sinais que compõem o banco de dados, foi utilizado a bancada de teste apresentado no esquema da Figura 6.5, e na foto da Figura 6.6. O acelerômetro foi montado sobre a caixa de rolamento, sendo que foi tomado o cuidado de montar todos os defeitos localizados (furado e corroídos) na direção do acelerômetro.

O motor utilizado é um motor AC trifásico, de 4 pólos (rotação nominal de 1720 rpm), e 0,33 Watts de potência.




Figura 6.5 – Esquema da bancada de teste

O acelerômetro utilizado foi o 353B02 da PCB, com sensibilidade de 19,74 mV/g. e faixa de frequência de 1 a 7000 Hz. O condicionador é o modelo 480B10 da PCB.

O filtro-amplificador utilizado foi ajustado em uma frequência de corte de 1,5 kHz e amplificação dependendo da amplitude do sinal resultante, de modo a aproveitar o máximo possível a resolução e a faixa útil de leitura do sistema de conversão analógico-digital.



Figura 6.6 – Lay-Out geral da bancada de teste de defeitos de rolamento



Figura 6.7 – Detalhe da Bancada de Teste (a) motor utilizado para o teste, e (b) detalhe do mancal de rolamento mostrando o posicionamento do acelerômetro acima e a aplicação da carga através do parafuso (embaixo).



Figura 6.8 – Equipamento de filtro, amplificação e conversão A/D

Para gravar o sinal no computador foi utilizada a placa de aquisição DAQPad-6070E da National Instruments® com resolução de 12 bits e faixa de ± 10 V. Utilizou-se o programa LabView® para o controle da placa de aquisição.



Figura 6.9 – Sistema de aquisição de dados

Para o controle de rotação do motor utilizou-se o variador de frequência TOSHIBA® TOSVERT VF-S72004P(2) (Figura 6.10).



Figura 6.10 – Variador de frequência para regular a rotação do motor

Através de um outro sistema independente, utilizou-se uma célula de carga de extensômetro, para monitorar a carga radial aplicada sobre o mancal de rolamento.

Esta carga radial foi aplicada utilizando uma barra articulada (que funciona como uma célula de carga) em uma das pontas, tendo o seu ponto médio articulado na caixa de rolamento, e em cujo extremo oposto é aplicado uma carga utilizando um

parafuso. Portanto, tem-se que a carga aplicada ao mancal de rolamento é o dobro da carga aplicada pelo parafuso.

A célula de carga é formada por dois extensômetros presos um em cada lado desta barra articulada, cuja alimentação e condicionamento do sinal, são feitos por uma ponte de Wheatstone, e a leitura da tensão é feita utilizando um multímetro (Figura 6.11).



Figura 6.11 – Sistema de monitoramento da carga aplicada

Como parâmetros de aquisição, foi utilizado uma taxa de amostragem de 5 kHz com 10 segundos de amostragem. A Tabela 6.3 resume o equipamento e os parâmetros de aquisição utilizados.

Tabela 6.3 – Equipamento e Parâmetros de aquisição dos sinais de vibração

Rolamento	B015TVP (FAG)
Acelerômetro (Modelo)	353B02 (PCB)
(Sensibilidade)	19,74 mV/g
(Faixa – erro de 5%)	1 a 7000 Hz
Condicionador (Modelo)	480B10 (PCB)
Frequência de corte	1,5 kHz
Amplificação	(a ajustar)
Sistema A/D (Modelo)	DAQPad-6070E (NI)
(Resolução)	12 bits
(Faixa)	± 10 V
Taxa de amostragem	5 kHz
Período de aquisição	10 seg.

Posteriormente, o sinal foi convertido de Volts para a unidade de aceleração (m/s^2), que será utilizada para se realizar a análise do sinal, e obtenção dos parâmetros escalares que serão a entrada do sistema fuzzy. Nesta mesma etapa, todos os sinais foram centrados em zero.

A bancada experimental está presente no Laboratório de Análise Dinâmica e Instrumentação (LADIN) do Departamento de Engenharia Mecânica da Escola Politécnica da USP.

7. ESTRATÉGIAS DE DIAGNÓSTICO PARA TESTE DO SISTEMA FUZZY

São propostas algumas estratégias de diagnósticos que podem ser utilizadas neste sistema de inferência fuzzy com o objetivo de alcançar maior confiabilidade. Algumas combinações destas estratégias foram feitas nos testes realizados neste trabalho.

7.1. *Variação do Banco de Dados de Criação*

Baseando-se no banco de dados global, foram montados quatro conjuntos de banco de dados contendo diferentes combinações de amostras. Estes conjuntos de dados são chamados de banco de dados de criação.

Estas combinações são propostas para verificar a robustez do sistema, ou seja, se a dispersão das funções de pertinência são adequadas para descrever as características e se uma variação na planta observada interfere consideravelmente na performance do sistema fuzzy.

O primeiro, chamado de (*Amostra-1 a 10*), é composto somente com sinais das duas primeiras seqüências de montagem/desmontagem do rolamento. O segundo, chamado de (*Amostra-1 a 15*), é composto somente com sinais pelas três primeiras seqüências. O terceiro, chamado de (*Amostra-1 a 20*), é composto com todas as amostras do banco de dados. O quarto, chamado de (*Amostra-Variado*), é composto por dez amostras obtidas de elementos de cada uma das quatro seqüências.

Para a etapa de teste foram montadas duas diferentes combinações de amostras, chamadas de conjunto de teste. O primeiro conjunto, chamado de (*Amostra/Tipo-15 a 20*), é composto pela última seqüência de montagem/desmontagem do rolamento, e será utilizado para testar os sistemas fuzzy criados a partir do primeiro, segundo e terceiro conjuntos de criação. O outro, chamado de (*Amostra/Tipo-Variado*), é composto por sete amostras obtidas de elementos de cada uma das quatro seqüências, e será utilizado para testar os sistemas fuzzy criados a partir do quarto conjunto de criação.

7.2. *Variação de Rotação*

Cada um dos conjuntos de dados do item anterior pode ser montado utilizando-se todas as rotações ou apenas uma delas. Tem-se, portanto, uma variação de conjunto de dados relacionada com a rotação, nomeada respectivamente por (*Rotação-##*) e (*Rotação-400, 600, 800, 1000, 1200 e 1400*).

7.3. *Formas de Cálculo das Médias e Desvios Padrões das Funções de Pertinência*

Quanto à criação das funções de pertinência, estas foram construídas com os valores médios e desvios padrões obtidos para cada condição de carga e rotação de cada conjunto de criação do sistema fuzzy, ou seja, das variações experimentais feitas. Neste caso, o cálculo é denominado (*Média/Amostra-Todas*). Além disso, foram também utilizados a média e desvio padrão da característica para cada sinal de vibração, sendo este dividido em dez sinais menores. Neste caso, o cálculo é denominado (*Média/Amostra-Cada*).

7.4. *Detecção x Detecção/Classificação*

Para verificar a influência da complexidade de diagnóstico sobre o sistema fuzzy, foram utilizadas duas estratégias distintas. Na primeira, as funções de pertinências são construídas para todos os defeitos, de modo que ao se fazer o teste possa-se identificar o tipo de defeito do mancal (*Detecção/Classificação*). A outra estratégia é montar as funções de pertinência referentes apenas às condições normais, e definindo um *Valor limiar de índice fuzzy* (de 0 a 1), onde acima dele o rolamento é considerado normal e abaixo dele, ele é considerado com defeito (*Detecção*). Com esta última estratégia, não é possível definir qual o defeito que ocorreu, mas apenas detectar o defeito.

O diagnóstico de *Detecção* é muito similar ao alarme tradicional na indústria, ambos apenas permitem identificar se existe algum defeito no rolamento. Porém, na estratégia apresentada neste trabalho, é permitido trabalhar com diversas variáveis características, ao contrário dos alarmes tradicionais que utilizam apenas o RMS. Além disso, utilizando a lógica fuzzy, existe uma passagem contínua do estado normal para o estado com defeito, e não, abrupta, como ocorre no alarme tradicional.

7.5. *Análise e Escolha das Características de Entrada*

As características foram divididas em cinco grupos com diferentes características.

O primeiro grupo (*Características-Var/Todos*) é composto por 16 parâmetros escalares calculados a partir do próprio sinal e de seu envelope:

- RMS do sinal;
- Kurtosis do sinal;
- Skewness do sinal;
- Valor de Pico do sinal;
- ER do sinal;
- Amplitude da Máxima Frequência do sinal entre 0 e 500 Hz;
- Amplitude da Máxima Frequência do sinal entre 501 e 1000 Hz;
- Amplitude da Máxima Frequência do sinal entre 1001 e 1500 Hz;
- RMS do Envelope do sinal;
- Kurtosis do Envelope do sinal;
- Skewness do Envelope do sinal;
- Valor de Pico do Envelope do sinal;
- ER do Envelope do sinal;
- Amplitude da Máxima Frequência do Envelope do sinal entre 0 e 500 Hz;
- Amplitude da Max. Frequência do Envelope do sinal entre 501 e 1000 Hz;
- Amplitude da Max. Frequência do Envelope do sinal entre 1001 e 1500 Hz.

O RMS, o Valor de Pico e a Kurtosis do sinal são parâmetros já amplamente utilizados na indústria. O RMS é o momento estatístico de segunda ordem, o Skewness é o momento estatístico de terceira ordem, e a Kurtosis é o momento estatístico de quarta ordem. O ER é a energia residual do sinal [item 4.9]. O envelope também é amplamente utilizado para detectar defeitos em mancais de rolamento, pois ele fornece informação sobre a modulação dos mesmos [item 4.8].

O segundo, terceiro, quarto e quinto grupos de parâmetros são as amplitudes do espectro de frequência do sinal de 0 a 1250 Hz obtidas pelo esquema mostrado na Figura 7.1.




Figura 7.1 – Esquema para obtenção os espectros de frequência

Cada um dos quatro grupos de espectros obtidos segundo o esquema mostrado na Figura 7.1 tem as propriedades descritas na Tabela 7.1.

Como visto, utilizou-se uma resolução de aproximadamente 9,76 Hz (65 pontos) (*Características-PSD_64*) e na outra uma resolução de aproximadamente 4,88 Hz (129 pontos) (*Características-PSD_128*).

O quarto e quinto grupos de características são as amplitudes do espectro de frequência do envelope do sinal de vibração amostrado, possuindo uma banda de 0 a 1250 Hz, com as mesmas resoluções propostas no segundo (*Características-ENVPSD_64*) e terceiro grupos (*Características-ENVPSD_128*), respectivamente.

Como se espera utilizar este sistema fuzzy de modo cego, ou seja, sem o uso de conhecimento prévio sobre o comportamento mecânico a ser observado, estes quatro grupos obtidos pelo espectro de frequência são colocados integralmente como

características de entrada, sendo que cada componente do vetor representará um valor característico.

Será feita uma análise comparativa sobre estes diferentes grupos de características.

Tabela 7.1 – Dados dos cálculos para obtenção dos espectros de frequência

<i>Características/Grupo -</i>	<i>PSD_64</i> <i>2º Grupo</i>	<i>ENVPSD_64</i> <i>3º Grupo</i>	<i>PSD_128</i> <i>4º Grupo</i>	<i>ENVPSD_128</i> <i>5º Grupo</i>
<i>Frequência de amostragem na aquisição do sinal (Hz)</i>	5000		5000	
<i>Frequência de amostragem após operação de decimate (Hz)</i>	1250		1250	
<i>Banda máxima em frequência (Hz)</i>	625		625	
<i>Número de pontos da janela de ponderação (Hanning)</i>	256		128	
<i>Número de pontos de sobreposição para cálculo de espectro</i>	64		32	
<i>Duração temporal da janela de ponderação (s)</i>	0,204		0,102	
<i>Resolução frequencial – Janela de Hanning (Hz)</i>	14,3		7,3	
<i>Resolução frequencial gráfica (Hz)</i>	9,76		4,88	
<i>Tamanho do vetor de característica (pontos)</i>	65		129	

8. TESTES DO SISTEMA FUZZY

O programa desenvolvido neste trabalho (para criação automática e teste de sistemas fuzzy) permite o desenvolvimento de diversos tipos de sistemas fuzzy. Utilizando este programa, serão desenvolvidos alguns sistemas de detecção e classificação de defeitos em rolamentos. Serão testadas algumas combinações de estratégias de diagnóstico apresentadas no Capítulo 7, podendo estas serem resumidas em:

- 4 casos de conjuntos de criação (*Amostra - 1 a 10, 1 a 15, 1 a 20, Variado*);
- 7 casos de rotação (*Rotação - ##, 400, 600, 800, 1000, 1200, 1400*);
- 5 tipos de características dos sinais (*Características - Var/Todos, PSD_64, ENVPSD_64, PSD_128, ENVPSD_128*);
- 2 tipos de estratégias de diagnósticos (*Detecção/Classificação, Detecção*);
- 5 tipos de perfis de funções de pertinência (*Trapezoidal, Triangular, Gaussiana, Pi, Beta*);
- 2 tipos de cálculo de médias e desvios padrões das funções de pertinência (*Média/Amostra-Todas, Cada*).

As diferentes combinações das possibilidades apresentadas acima permitem gerar 1400 sistemas fuzzy diferentes. Destes, foram testados 980 sistemas fuzzy, sendo que para cada tipo de perfil de função de pertinência e tipo de estratégia de diagnóstico, possui as variações de sistemas fuzzy apresentadas no Anexo B.

Esta grande variedade de sistemas fuzzy permitiu observar os comportamentos mais genéricos que são influenciados pelos perfis das funções de pertinência e pelos grupos de características.

8.1. Parâmetros de Criação do Sistema Fuzzy

Os seguintes parâmetros do sistema fuzzy serão utilizados nos sistemas de inferência fuzzy sem variação:

- Operador AND - Zadeh

- Operador OR – Zadeh
- Operador NOT – Zadeh
- Operador THEN - Mínimo
- Operador de Agregação – Máximo
- Operador de Desfuzzificação – Centróide
- Valor Alfa – 0.1
- Número de Pontos para Discretização – 1000
- Operador Geral das Regras de Inferência – AND (Peso: 1)

Além destes, deve-se definir as funções de pertinência de saída que irão ser utilizados para a etapa de desfuzzificação. No caso de diagnóstico com detecção e classificação, serão utilizadas nos sistemas fuzzy as funções apresentadas na Figura 8.1. Conforme observada na figura, as variáveis lingüísticas utilizadas para estas funções de pertinência de saída são apresentadas na Tabela 8.1, sendo que cada uma delas está relacionada com uma condição do mancal de rolamento.

Esta configuração de funções de pertinência de saída foi adotada uma vez que estes defeitos possuem naturezas diferentes, e, portanto, propõem-se como saída da desfuzzificação uma escala adimensional de gravidade de falha, estando o valor 10 relacionado com os defeitos utilizados para montar o banco de dados.

No caso de diagnóstico com apenas detecção, não foi necessário o processo de desfuzzificação, uma vez que o resultado é obtido a partir de um *Valor limiar de índice fuzzy* (ou de defeito) que vai de 0 a 1. Assim, quando o valor máximo da função de pertinência de saída do sistema fuzzy da condição normal (ou seja, antes da etapa de desfuzzificação), for menor que este nível, o sistema fuzzy indica que o mancal possui um defeito. Quando esta saída for maior que este nível, o sistema fuzzy indica um mancal normal.

Portanto, neste caso, não é necessário definir um perfil de função de pertinência de saída. Sendo utilizado como *valor limiar de índice fuzzy*, escolhido após alguns testes, um nível de 0,1.

Tabela 8.1 – Nomes das variáveis lingüísticas das funções de pertinência de saída.

<i>Nome da Variável Lingüística de Saída</i>	<i>Condição do Rolamento</i>
Normal	Normal
RiscadoExt	Defeituoso – riscado na pista externa
Corrosao1Ext	Defeituoso – corrosão 1 na pista externa
Corrosao2Ext	Defeituoso – corrosão 2 na pista externa
FuradoExt	Defeituoso – furado na pista externa
RiscadoInt	Defeituoso – riscado na pista interna
Corrosao1Int	Defeituoso – corrosão 1 na pista interna
Corrosao2Int	Defeituoso – corrosão 2 na pista interna
FuradoInt	Defeituoso – furado na pista interna

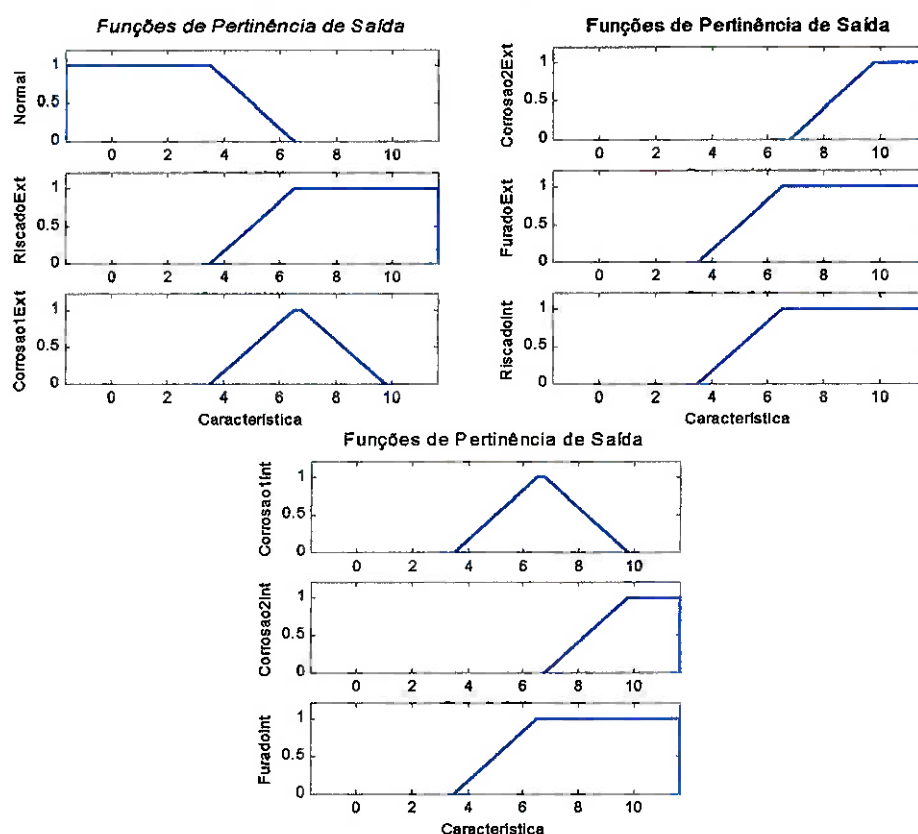


Figura 8.1 – As possíveis saídas do sistema fuzzy (Detecção/Classificação)

Um dos parâmetros dos sistemas fuzzy que será variado para a análise de sensibilidade é o tipo de perfil da função de pertinência (Figura 8.2), utilizando os fatores de proporção de dispersão, que são apresentadas na Tabela 8.2.

Tabela 8.2 – Fatores de Proporção de Dispersão

<i>Perfil</i>	<i>Fatores</i>	
Trapezoidal	f_1	0,5
	f_2	1,5
Triangular	f_1	2,0
Gaussiana	f_1	1,0
Pi	f_1	2,0
Beta	f_1	1,0




Figura 8.2 – Tipos de funções de pertinências com os parâmetros de entrada para um valor médio 0 e um desvio padrão de 1.

Além dos testes com estes fatores de proporção de dispersão de funções de pertinências, utilizaram-se, apenas com fins de validação de resultados, outros fatores que igualam as aberturas das funções de pertinência àquela obtida com o perfil beta, conforme pode ser observado na Figura 8.3. Estes parâmetros são apresentados na Tabela 8.3.

Tabela 8.3 – Fatores de Proporção de Dispersão

<i>Perfil</i>	<i>Fatores</i>	
Trapezoidal	f_1	0,5
	f_2	3,28
Triangular	f_1	3,33
Gaussiana	f_1	1,98
Pi	f_1	3,86
Beta	f_1	1,0

Estes últimos fatores só foram utilizados para verificar a influência do perfil da função de pertinência. Nos outros testes utilizou-se os fatores da Tabela 8.2.




Figura 8.3 – Tipos de funções de pertinências com os parâmetros de entrada para um valor médio 0 e um desvio padrão de 1.

8.2. Parâmetros de Análise

Como parâmetros de análise das performances dos sistemas fuzzy, foram utilizados os seguintes para o caso de diagnóstico com detecção e classificação:

- ✓ *Acertos Defeitos S/N (%)* - verifica-se a existência ou não do defeito, observando se a saída desfuzzificada do sistema fuzzy é maior que 5 (para a condição com defeito) e menor que 5 (para a condição normal). Esta transição ocorre devido à função de pertinência de saída escolhida, sendo que o valor desfuzzificado 5 representa o ponto onde a função de pertinência **normal** possui um grau de veracidade menor que as funções de pertinência de defeito (*corrosão1*, *corrosão2*, *riscado* e *defeito*).
- ✓ *Acertos de Normais (%)* verifica se o banco de testes normais foi classificado corretamente como do tipo normal, ou seja, a função de pertinência de saída normal possui o maior grau de veracidade de saída antes da desfuzzificação.

- ✓ *Acertos de Tipo (%)* verifica se todo o banco de dados de teste, tanto com a condição normal, quanto com os defeitos, foram classificados corretamente, observando qual é a função de pertinência de saída que possui maior grau de veracidade.
- ✓ *Indecisão* indica se existem duas ou mais saídas acionadas simultaneamente com mesma amplitude, por exemplo, normal e algum defeito, o que implica que o sistema fuzzy, não sabe qual das duas condições realmente representa o sistema estudado.
- ✓ *Inexistente* indica que nenhuma função de pertinência de saída foi acionada, ou seja, todas possuem grau de pertinência nulo.
- ✓ *Tempo de Criação* é o tempo necessário para criar o sistema fuzzy.
- ✓ *Tempo de Teste/Amostra* é o tempo necessário para testar cada amostra do banco de dados de teste.

Para o caso de diagnóstico com apenas detecção, os seguintes parâmetros foram utilizados:

- ✓ *Acertos de Normais (%)* verifica se o banco de testes normais foi diagnosticado corretamente como do tipo normal, ou seja, a função de pertinência de saída normal possui um grau de veracidade de saída antes da desfuzzificação maior que o **valor limiar de índice fuzzy** 0,1.
- ✓ *Acertos de Defeitos (%)* verifica se o banco de testes com defeitos foi diagnosticado corretamente como do tipo defeito, ou seja, a função de pertinência de saída normal possui um grau de veracidade de saída antes da desfuzzificação menor que o **valor limiar de índice fuzzy** 0,1.
- ✓ *Tempo de Criação* é o tempo necessário para criar o sistema fuzzy.
- ✓ *Tempo de Teste/Amostra* é o tempo necessário para testar cada amostra do banco de dados de teste.

9. RESULTADOS E DISCUSSÃO

No que se segue serão discutidos principalmente as influências da variação das características dos sinais e o tipo de perfil da função de pertinência.

9.1. Perfil da Função de Pertinência

Através de análise global dos resultados, observou-se em todos os casos, a seguinte ordem de melhor performance em relação ao perfil adotado:

1. *Beta*;
2. *Triangular*;
3. *Pi*;
4. *Gaussiana*;
5. *Trapezoidal*.

Como conceito de performance utiliza-se o menor índice de *Indecisão* e *Inexistência*, e ainda o maior número de acertos entre normal e defeitos.

Um exemplo desta ordem de melhor performance pode ser observada comparando os índice de *Acertos de Tipo* e de *Inexistência* para um sistema fuzzy para diagnóstico de *Deteção/Classificação* utilizando característica PSD_128 (*Características- PSD_128*), média e desvio padrão obtidos de um misto de seqüências do banco de dados (*Amostra- Variado e Média/Amostra-Todas*), considerando uma única rotação de 600 rpm (*Rotação- 600*), que são, respectivamente:

- **Beta** – 89.95% (*Acertos de Tipo*) e 5.82% (*Inexistência*).
- **Triangular** – 17,46% (*Acertos de Tipo*) e 82.54% (*Inexistência*).
- **Pi** – 3,70% (*Acertos de Tipo*) e 96.30% (*Inexistência*).
- **Gaussiana** – 2.65% (*Acertos de Tipo*) e 97.35% (*Inexistência*).
- **Trapezoidal** – 1.06% (*Acertos de Tipo*) e 98.94% (*Inexistência*).

A performance global relacionada ao índice de *Indecisão* de cada perfil é devida principalmente à dispersão da função de pertinência. No caso da função *Beta*, a dispersão é muito maior que nas outras funções, sendo este de aproximadamente o dobro em relação ao *Trapezoidal*, o *Pi*, e o *Gaussiano*. A dispersão no caso da função triangular é também maior em relação a outras funções, conforme ilustrado na Figura 8.2. Com isto, o universo descrito por uma única função de pertinência do tipo *Beta* é muito maior em relação aos outros tipos de perfis de funções, resultando em um menor índice de *Inexistência*. Pela mesma razão, a função de pertinência *Trapezoidal* possui o maior índice de *Inexistência*.

Esta constatação foi confirmada após a utilização dos fatores de proporção da Tabela 8.3, que igualam as aberturas ou dispersões das funções de pertinência. Nestes testes, obtida na condição de melhor performance (diagnóstico com detecção e classificação (*Detecção/Classificação*)) utilizando características PSD_64 (*Características- PSD_64*), média e desvio padrão obtidos de um misto de seqüências do banco de dados (*Amostra-Variado e Média/Amostra-Todas*), considerando uma única rotação (*Rotação- 400, 600, 800, 1000, 1200 e 1400*)), as performances dos cinco perfis foram equivalente, com 91% de acertos de detecção (*Acertos Defeitos S/N*), e 82% de acertos de classificação (*Acertos de Tipo*).

Outra característica importante do perfil *Beta* é o seu topo mais estreito, o que implica em um sistema que dá maior importância a condições obtidas bem próximas da média.

No caso da função de pertinência *Trapezoidal*, além de possuir um alto índice de *Inexistência*, ele é o único que possui índice de *Indecisão*, isto ocorre devido ao seu formato particular, que permite um maior desvio para obter um grau máximo de pertinência 1 da função, e permitindo que, com o mesmo valor de entrada, várias funções de pertinências sejam acionadas neste nível, obtendo assim uma indecisão.

Um aspecto muito importante observado é o menor *Tempo de Criação* para a função *Beta*, isto ocorre porque nesta função é necessário salvar apenas dois parâmetros, igual ao *Gaussiano*, enquanto que para a função *Pi* e a *Triangular* têm-se três parâmetros e para a função *Trapezoidal* têm-se quatro parâmetros.

Além disso, o *Tempo de Teste/Amostra* também é muito inferior em relação aos outros, pois a função *Beta* é descrita apenas por uma fórmula polinomial,

enquanto a *Pi* e a *Trapezoidal* são descritas por quatro funções, sendo necessário, quatro procedimentos de comparação, a *Triangular* é descrita por três funções, sendo necessário, três procedimentos de comparação, e a *Gaussiana* é descrita apenas por uma função, porém, esta é exponencial.

Com isso, percebeu-se também para a estratégia de detecção e classificação, que a função *Beta* necessita um tempo médio 28% menor em relação ao *Trapezoidal* na fase de teste, e 19% menor na fase de criação do sistema fuzzy.

Esta relação de tempo diminui para o caso da estratégia de apenas detecção. Isto ocorre, devido aos menores tempos de criação e teste. Nestes casos, os tempos de, por exemplo, carregar as características, influenciam mais que o tempo de cálculo.

9.2. Valores Característicos

Da análise dos resultados obtidos, nota-se que a principal propriedade que influencia a performance do sistema fuzzy é a escolha das características implantadas.

Através de análise global dos resultados, observou-se na maioria dos casos, a seguinte ordem de melhor performance em relação ao grupo de características:

1. *PSD_128*;
2. *PSD_64*;
3. *ENVPSD_128*;
4. *ENVPSD_64*;
5. *Var/Todos*.

Um exemplo desta ordem de melhor performance pode ser observada comparando um balanço entre os índices de *Acertos de Normais* e *Acertos de Defeitos* para um sistema fuzzy para diagnóstico de *Deteção* utilizando perfil da função de pertinência *Beta*, média e desvio padrão obtidos de um misto de seqüências do banco de dados (*Amostra- Variado e Média/Amostra-Todas*), considerando todas as rotações (*Rotação- ##*), que são, respectivamente:

- **PSD_128** – 97.62% (*Acertos de Normais*) e 76.49% (*Acertos de Defeitos*).
- **PSD_64** – 97.62% (*Acertos de Normais*) e 70.63% (*Acertos de Defeitos*).
- **ENVPSD_128** – 99.21% (*Acertos de Normais*) e 59.82% (*Acertos de Defeitos*).
- **ENVPSD_64** – 99.21% (*Acertos de Normais*) e 57.54% (*Acertos de Defeitos*).
- **Var/Todos** – 47.62% (*Acertos de Normais*) e 79.27% (*Acertos de Defeitos*).

Apesar dos dados apresentados acima, não se pode generalizar esta classificação de performance, um exemplo disto, é o fato de em alguns casos, como quando se utiliza um sistema fuzzy para diagnóstico de *Detecção/Classificação* utilizando perfil da função de pertinência *Triangular*, média e desvio padrão obtidos de um misto de seqüências do banco de dados (*Amostra- Variado e Média/Amostra-Todas*), considerando todas as rotações (*Rotação- ##*), onde o aumento da resolução de 64 (*Características- PSD_64*) para 128 (*Características- PSD_128*) proporciona uma pequena queda de performance (respectivamente de 59.35% para 57.94% do índice de *Acertos de Tipo* e de 3.09% para 14.64% do índice de *Inexistência*).

Isto ocorre, porque ambos possuem a mesma informação, porém um está mais compacto que o outro. De certo modo, em alguns casos, uma maior compactação permite ao sistema fuzzy ser mais robusto, pois permite maior flexibilidade quanto a variações das frequências que compõe o espectro. Neste mesmo caso, com o grupo de características composto de parâmetros estatísticos (*Características- Var/Todos*), que possuem menor quantidade de informação, 16, a performance é muito menor. Isto se deve ao fato da natureza destas informações ser diferente dos espectros, tendo provavelmente uma menor qualidade na descrição das informações contidas nos sinais (com o mesmo sistema fuzzy obteve 35.80% no índice de *Acertos de Tipo* e 0.18% no índice de *Inexistência*).

Deve-se enfatizar que conforme se aumenta a quantidade de características de entrada do sistema fuzzy, mais lento será a resposta dele, uma vez que a quantidade de funções de pertinência a serem verificadas irá aumentar consideravelmente. Este fato pode ser exemplificado em um sistema fuzzy para diagnóstico de *Detecção/Classificação* utilizando perfil da função de pertinência *Beta*, média e

desvio padrão obtidos de um misto de seqüências do banco de dados (*Amostra-Variado e Média/Amostra-Todas*), considerando todas as rotações (*Rotação- ##*), onde os grupos de características necessitaram dos seguintes *Tempo de Teste/Amostra*:

- *PSD_128* e *ENVPSD_128* – 45 seg.
- *PSD_64* e *ENVPSD_64* – 15.5 seg.
- *Var/Todos* – 2.76 seg.

Vale ressaltar que existe redundância nos cinco grupos de características estudados, o que implica em um maior *Tempo de Criação* e *Tempo de Teste/Amostra* do que o necessário, além disso, nestes dados podem existir também informações que não são relevantes à descrição da condição do rolamento, que podem distorcer uma detecção ou classificação correta.

9.3. Outras análises

Os resultados obtidos permitem vários outros tipos de análise de performance e sensibilidade. Resumem-se a seguir quatro delas.

9.3.1. Variação do Banco de Dados de Criação

No caso da utilização do grupo de características estatísticas (*Características-Var/Todos*) com estratégia de detecção e classificação (*Detecção/Classificação*), não se verificou nenhuma variação significativa devido à variação do conjunto de criação. No caso dos outros grupos de características obtidos pelos espectros de frequências (*Características- PSD_64, ENVPSD_64, PSD_128 e ENVPSD_128*), a influência da utilização de um banco de dados de criação com mistura de seqüências é crítica, pois quando se utiliza um banco misturado (*Amostra- Variado*) obtém-se 90% de *Acertos Defeitos S/N*, enquanto que nos casos em que não se mistura (*Amostra- 1 a 10, 1 a 15 e 1 a 20*), o número de *Acertos Defeitos S/N* é nulo.

Para a estratégia de detecção (*Detecção*), percebe-se que a utilização do grupo de características estatísticas (*Características- Var/Todos*) implica em uma

melhor performance conforme se aumenta o banco de dados de criação. Porém, ao se misturar as seqüências de banco de dados (*Amostra- Variado*), a performance cai a praticamente nulo, de modo que o sistema sempre indicará defeito. Este comportamento não é observado para as características obtidas pelos espectros de frequência (*Características- PSD_64, ENVPSD_64, PSD_128 e ENVPSD_128*), cuja performance aumenta ao se misturar as seqüências do banco de dados (*Amostra- Variado*), saindo de quase nulo, para um acerto de detecção de mais 85% para *Acertos de Normais* e 85% para *Acertos de Defeitos*, para os casos com função de pertinência de perfil *Triangular e Beta*.

Pelos resultados obtidos, percebe-se que as características estudadas possuem uma baixa robustez, pois se espera que, se um sistema de inferência for robusto, uma mistura dos conjuntos de banco de dados, ou seja, as possibilidades de casos que compõe o banco de dados de criação, não pode provocar uma grande variação da performance dos sistemas.

9.3.2. Variação de Rotação

Considerando todas as rotações (*Rotação- ##*) (Figura 9.1.a), existe uma maior quantidade possível de condições armazenadas no sistema fuzzy, permitindo representar a maior quantidade possível de variações das características de um padrão do mancal, implicando também em maior índice de *Indecisão* e menor índice de *Inexistência*, conforme observado na Figura 9.1.

Outro aspecto importante que deve ser enfatizado é o aumento do *Tempo de Criação* e o do *Tempo de Teste/Amostra* do sistema fuzzy. Isto ocorre não apenas pelo fato de, no caso de todas as rotações (*Rotação- ##*), é necessário tratar mais amostras (são seis em vez de uma), mas também porque a quantidade de funções de pertinências de entrada armazenadas dentro do sistema fuzzy é 6 vezes maior que no outro caso, sendo necessário analisar todas elas.

Embora as funções de pertinência sejam 6 vezes mais numerosas, o *Tempo de Teste/Amostra* não aumentará nessa mesma proporção.




Figura 9.1 – Funções de pertinência referente à característica Pico para saída Normal para conjunto de banco de dados formado considerando (a) rotação variável (Sistema 1) e (b) rotação constante de 800 rpm (Sistema 4).

9.3.3. Forma de Cálculo das Médias e Desvios Padrões das Funções de Pertinência

A influência da fórmula de cálculo das médias e desvios padrões que serão utilizadas para criação das funções de pertinência, é analisada apenas para sistemas que utilizam as características estatísticas (*Características- Var/Todos*). Neste caso, observou-se que a utilização da média da característica de cada sinal (*Média/Amostra- Cada*) em vez da média da característica de todo um grupo (*Média/Amostra- Todas*) proporciona um melhor desempenho do sistema fuzzy, sendo de aproximadamente 10% maior para *Acertos Defeitos S/N* e 15% maior para *Acertos de Tipo*. Isto ocorre, pois ao se fazer a média de um grupo inteiro de características se desconsidera uma parcela de informação que estão mais distante do valor médio [Figura 9.2.b]. Ao se considerar que cada amostra é independente, obtendo sua própria média e desvio padrão [Figura 9.2.a], o conjunto que representa a condição do rolamento será muito mais abrangente, tornando o sistema mais robusto, conforme mostrado na Figura 9.2.

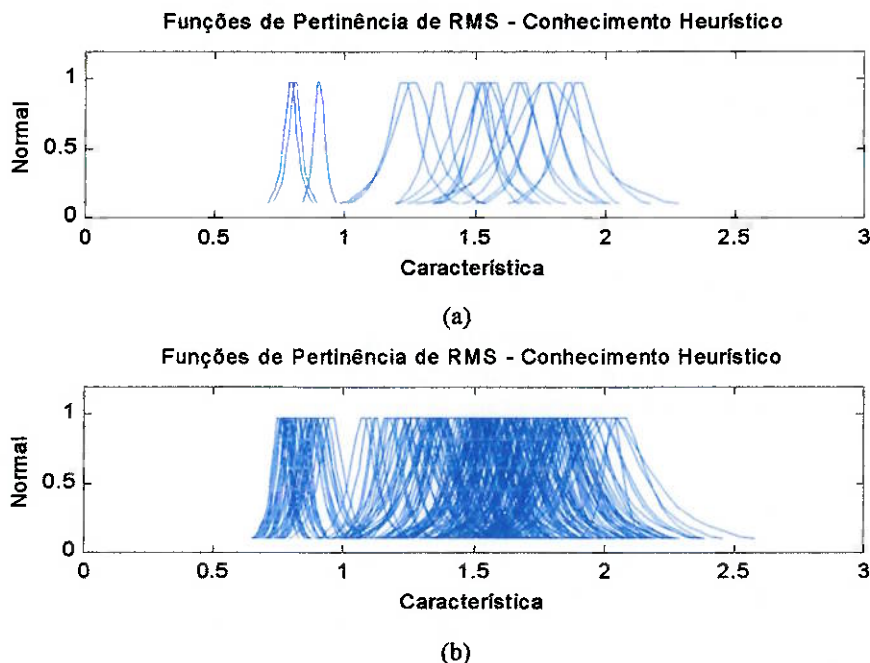


Figura 9.2 - Funções de pertinência referente à característica RMS para saída Normal com média e desvio padrão obtida por (a) todas as amostras (Sistema 99) e (b) para cada amostra (Sistema 106).

Porém, apesar de melhorar a performance do sistema fuzzy, ao se considerar a média e o desvio padrão de cada amostra de sinal (*Média/Amostra- Cada*), se aumenta a quantidade de funções de pertinência armazenadas no sistema fuzzy, e, portanto o esforço computacional tanto para criação quanto para teste é muito maior, uma vez que é necessário analisar todas as funções. Verificou-se um aumento de quase 5 a 10 vezes do *Tempo de Teste/Amostra*.

9.3.4. Detecção x Detecção/Classificação

Em ambas as estratégias propostas foram percebidas que o principal problema não é identificar o mancal defeituoso, mas sim, identificar o mancal em sua condição normal. Percebe-se que, enquanto os sistemas alcançam um alto índice de acertos de detecção para as amostras de mancais de rolamentos com defeitos, para mancais com rolamentos normais, obtêm-se baixos índices de acertos.

Um sistema fuzzy que sempre indica defeito, mesmo para os casos normais, é totalmente ineficaz, pois não reduz o trabalho de análise do operador. Já, um que

sempre indica normal, mesmo para mancais com defeitos, não transmite confiabilidade ao usuário.

No caso da estratégia com detecção e classificação (*Detecção/Classificação*), observa-se na maioria dos casos, um índice de *Acertos de Normais* abaixo de 50%. Portanto, neste caso, uma parte dos casos normais e a totalidade dos casos defeituosos são diagnosticadas como defeituosas. Uma exceção obtida é utilizando o perfil *Beta*, que em alguns casos obteve uma performance de *Acertos de Normais* superior a 80%.

Porém, com a estratégia utilizando apenas a estratégia de detecção (*Detecção*), pode-se alcançar um alto índice de acertos, tanto de mancais normais (*Acertos de Normais*) quanto com defeitos (*Acertos de Defeitos*). Isto ocorre, pois a complexidade do sistema fuzzy neste caso é muito menor, de modo que a tarefa de diagnóstico não sofra influência das outras condições de defeito. Além disso, a tarefa simplifica-se em apenas identificar qual é a condição normal. Um outro aspecto muito importante é o *Tempo de Criação* e o *Tempo de Teste/Amostra* que é muito menor, pois o sistema fuzzy armazena apenas um nono de quantidade de funções de pertinência.

Apesar de todas estas vantagens, esta estratégia de *Detecção* não permite classificar os defeitos, apenas diagnosticar se há um defeito ou não. Um modo de obter um bom desempenho de detecção e também de classificação é colocar dois sistemas em série, sendo que o primeiro apenas diagnostica o defeito, e o segundo classifica as amostras diagnosticadas como defeituosas. Este sistema proposto não foi implementado neste trabalho.

Uma outra desvantagem desta estratégia é o fato de se acrescentar uma outra variável ao problema, que é o *Valor limiar de índice fuzzy* entre a condição normal e o defeito.

Outra análise interessante a ser feita é a comparação entre estas duas estratégias e um alarme tradicional de nível de RMS. Por questão de comparação, para o cálculo deste alarme, utilizou-se a média e o desvio padrão de um banco de dados com *Amostra- Variado*, e composto apenas da condição *Normal*, em todas as *condições experimentais*. Utilizou-se como nível de alarme, o valor médio mais duas vezes o desvio padrão, calculados a partir de um banco de dados composto de misto

de seqüências de banco de dados (*Amostras-Variado*), e composto apenas da condição *Normal*, em todas as *condições experimentais*. Portanto, se o nível de RMS de uma amostra é maior que este nível, a amostra é considerada com defeito, caso contrário, é considerada normal.

Os sistemas fuzzy a serem comparados, são aqueles obtidos com o perfil *Beta* e características PSD_128 (*Características- PSD_128*), média e desvio padrão obtidos de um misto de seqüências do banco de dados (*Amostra- Variado e Média/Amostra-Todas*), considerando todas as rotações (*Rotação- ##*).

- *Alarme* – 100% (*Acertos de Normais*) e 38.69% (*Acertos de Defeitos*).
- *Deteção* – 97.62% (*Acertos de Normais*) e 76.49% (*Acertos de Defeitos*).
- *Deteção/Classificação* – 31.75% (*Acertos de Normais*), 89.59% (*Acertos de Defeitos (S/N)*) e 68.08% (*Acertos de Tipo*).

Pela comparação apresentada acima, fica clara a vantagem de se utilizar o sistema de inferência fuzzy, na detecção de defeito com o diagnóstico de *Deteção* e na classificação de defeito com a estratégia *Deteção/Classificação*.

9.4. Melhor Performance de Teste dos Sistemas de Inferência Fuzzy

Finalmente, o melhor sistema fuzzy para diagnóstico de condição normal/com defeito é aquele obtido com o perfil *Beta* e características PSD_64 e PSD_128 (*Características- PSD_64 e PSD_128*), com estratégia de apenas detecção (*Deteção*), média e desvio padrão obtidos de um misto de seqüências do banco de dados (*Amostra- Variado e Média/Amostra-Todas*), considerando todas as rotações (*Rotação- ##*), tendo performance superior a 85% tanto para *Acertos de Normais* e *Acertos de Defeitos*.

Para o caso de rotação constante (*Rotação- 400, 600, 800, 1000, 1200 e 1400*), nas mesmas condições apresentadas acima, a performance sempre foi superior a 90% tanto para *Acertos de Normais* quanto para *Acertos de Defeitos*, chegando a 95% para *Acertos de Normais* e 99% para *Acertos de Defeitos*.

No caso de estratégia de detecção e classificação (*Detecção/Classificação*), a detecção de defeitos (*Acertos Defeitos S/N*) teve melhor performance, o mesmo tipo de sistema apresentado acima, com 89.6% de acertos. Porém, este sistema fuzzy teve um baixo índice de *Acertos de Normais*, com 32%. Quanto à classificação de tipo de defeito ou condição normal (*Acertos de Tipo*), ele obteve um nível de acerto de 68.08%.

Considerando rotação constante (*Rotação- 400, 600, 800, 1000, 1200 e 1400*), a performance de detecção (*Acertos Defeitos S/N*), utilizando as mesmas condições, oscila próximo a 90%, com *Acertos de Normais* na faixa de 75%. Os *Acertos de Tipo* é de aproximadamente 85%.

10. CONCLUSÃO

Este trabalho procurou desenvolver uma metodologia para criação automática de um sistema de diagnóstico, baseado em inferência fuzzy. Por esta metodologia, as fases de desenvolvimento do sistema fuzzy: criação das funções de pertinência e implantação das regras de inferência; são realizadas automaticamente a partir de um banco de dados.

Um programa de criação de sistema fuzzy foi criado utilizando esta metodologia, com grande preocupação com a interface gráfica com o usuário e sua flexibilidade. Através deste programa e de um banco de dados de defeitos em rolamentos criaram-se diversos sistemas de inferência fuzzy para diagnóstico destes defeitos. A partir destes sistemas fuzzy, analisou-se a influência no diagnóstico tanto das características dos sinais que serão utilizadas como entrada quanto dos parâmetros do sistema fuzzy.

Os resultados obtidos mostram que, referente à função de pertinência, existe uma maior influência da abertura da função de pertinência do que propriamente dito o perfil escolhido.

Os resultados também mostraram que a principal propriedade que influencia a performance do sistema fuzzy é a escolha das características que descrevem as assinaturas dos sinais de vibração. É importante definir primordialmente quais características realmente descrevem o fenômeno a ser identificado. No caso dos mancais de rolamentos, os melhores resultados foram obtidos para os espectros de frequência do sinal de maior resolução, que realmente na prática possui um comportamento mais confiável, em relação a parâmetros estatísticos e escalar.

Outro aspecto a ser enfatizado é a ponderação do esforço computacional necessário para implantar o sistema fuzzy. Muitas vezes, uma melhora de performance de 10% acarreta um aumento de tempo de teste de 10 vezes, o que pode tornar inviável a sua utilização.

Observa-se que é muito importante uma variação de descrições do padrão a ser diagnosticado para que se obtenha um sistema com bom nível de generalização e confiabilidade. Desta maneira, flutuações nas características dos sinais em teste, não levam a diagnósticos errados. Por isso, deve-se ter muito cuidado para escolher as

amostras que irão compor o sistema fuzzy, que tanto pode resultar em um baixo índice de descrição dos padrões a serem diagnosticados, quanto a distorções das descrições dos defeitos, que pode induzir a um diagnóstico falso.

Percebeu-se que o fato de se preocupar em apenas encontrar um mancal normal, ignorando os outros padrões que compõe o banco de dados de defeitos, permite um aumento de performance de acertos e queda no tempo de criação e de teste. Portanto, foi proposto para trabalhos futuros um outro layout de sistema fuzzy, que separam as etapas de detecção e classificação em dois sistemas fuzzy distintos.

11.REFERÊNCIA BIBLIOGRÁFICA

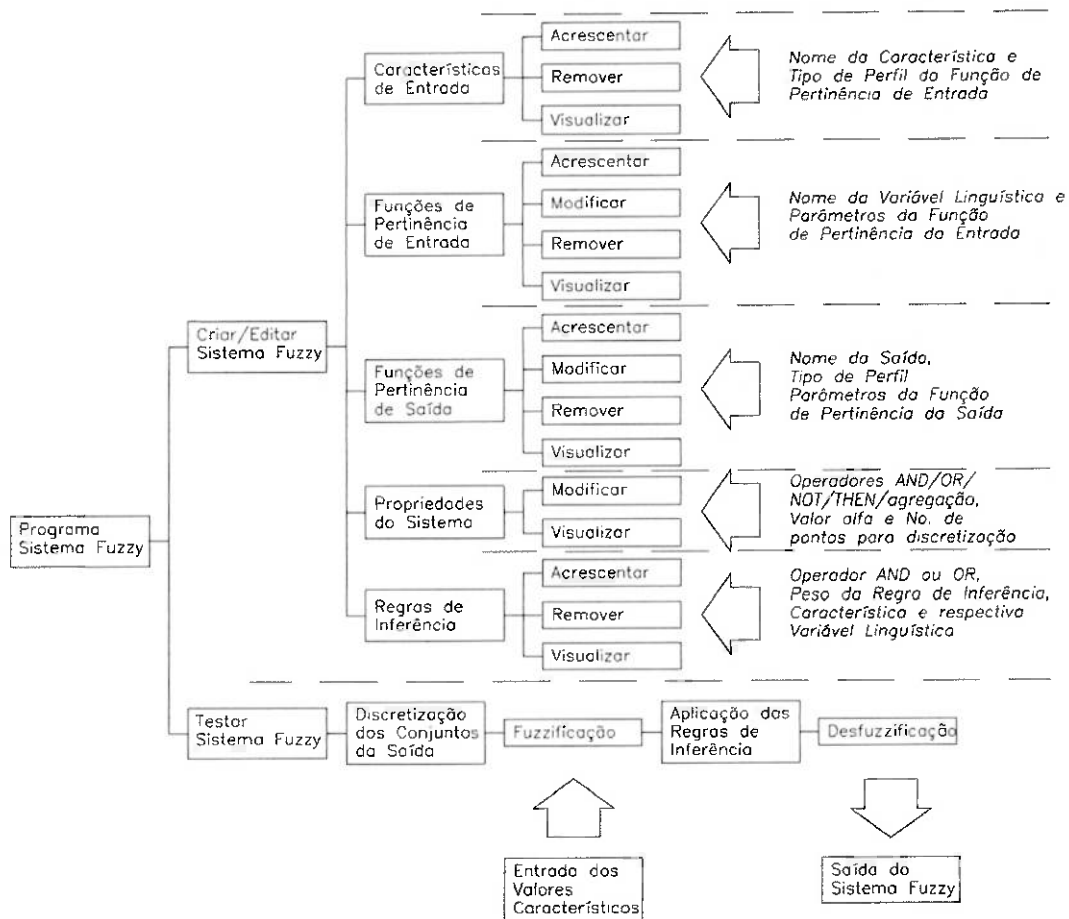
1. ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *Vibração mecânica de máquinas com velocidades de operação de (600 a 12000) rpm – bases para especificação e padrões de avaliação*. NBR 10.082, ABNT, 1987.
2. ALMEIDA, R.G.; VICENTE, S. A. S; PADOVESE, L. R.. *New Technique for Evaluation of Global Vibration Levels in Rolling Bearings. Anais do COBEM 2001*, 2001.
3. AYOUBI, M.; ISERMANN, R.. *Neuro-fuzzy systems for diagnosis. Fuzzy Sets and Systems*, v. 89, p. 289-307, 1997.
4. BARKOV, A.; BARKOVA, N.. *Condition Assessment and Life Prediction of Rolling Element Bearings – Part 2. Sound and Vibration*, p. 27-31, Setembro de 1995.
5. BERRY, J. B.. *How to track rolling bearing health with vibration signature analysis. Sound and Vibration*, p. 24-35, Novembro 1991.
6. COX, E.. *The Fuzzy Systems Handbook*. Ed. AP Professional, 615 p., 1994.
7. DRON, J. P.; RASOLOFONDRAIBE, L.; BOLAERS, F.; PAVAN, A.. *High-resolution Methods in Vibratory Analysis: Application to Ball Bearing Monitoring and Production Machine. International Journal of Solids and Structures*, v. 38, p. 4293-4313, 2001.
8. FAG. *Catálogo*, 1985.
9. FLANAGAN, M.. *Innovative tools for automatic vibration analysis and diagnosis – 1a. part. Machine, Plant & Systems Monitor*. p. 17-20, February 1998.
10. FLANAGAN, M.. *Innovative tools for automatic vibration analysis and diagnosis – 2a. part. Machine, Plant & Systems Monitor*. p. 15-18, October 1998.
11. FRANK, P. M.; KÖPPEN-SELIGER, B.. *Fuzzy Logic and Neural Network Applications to Fault Diagnosis. International Journal of Approximate Reasoning*, v.16, p. 67-88, 1997.
12. GOLDMAN, S.. *Vibration Spectrum Analysis: A practical approach*. Industrial Press Inc., 1a. ed, 1991.
13. HENG, R. B. W.; NOR, M. J. M.. *Statistical Analysis of Sound and Vibration Signals for Monitoring Rolling Bearing Condition. Applied Acoustics*, v. 53, p. 211-226, 1998.
14. INTERNATIONAL STANDARDS ORGANIZATION. *Mechanical vibration- evaluation of machine vibration by measurements on non-rotating parts: ISO 10816-1: General guidelines*, ISO, 1995.

15. JACK, L. B.; NANDI, K.. *Support Vector Machines for Detection and Characterization of Rolling Element Bearing Faults. Proc. Instn. Mech. Engrs.*, v. 215, Part C, p. 1065-1074, 2001.
16. JEFFRIES, M.; LAI, E.; PLANTENBERG, D. H.; HULL, J. B.. *A fuzzy approach to the condition monitoring of a packaging plant. Journal of Materials Processing Technology*, v. 109, p. 83-89, 2001.
17. JOENTGEN, A.; MIKENINA, L.; WEBER, R.; ZEUGNER, A.; ZIMMERMANN, H.-J.; *Automatic fault detection in gearboxes by dynamic fuzzy data analysis. Fuzzy Sets and Systems*, v. 105, p. 123-132, 1999.
18. JOENTGEN, A.; MIKENINA, L.; WEBER, R.; ZIMMERMANN, H. J.. *Dynamic Fuzzy Data Analysis Based on Similarity Between Functions. Fuzzy Sets and Systems*, v. 105, p. 81-90, 1999.
19. JONES, R. M.. *Enveloping for Bearing Analysis. Sound and Vibration*, p. 10-15, Fevereiro de 1996.
20. KARNIK, N. N.; MENDEL, J. M.. *Operations on Type-2 Fuzzy Sets. Fuzzy Sets and Systems*, v. 122, p. 327-348, 2001.
21. KARTALOPOULOS, S. V.. *Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications*. IEEE Press, 1996.
22. KIMURA, Y.. *Maintenance Tribology: Its Significance and Activity in Japan. Wear*, v. 207, p. 63-66, 1997.
23. LEONHARDT, S.; AYOUBI, M.. *Methods of Fault Diagnosis. Control Eng. Practice*, v. 5, n. 5, p. 683-692, 1997.
24. LI, B.; CHOW, M.; TIPSUWAN, Y.; HUNG, J. C.. *Neural-Network-Based Motor Rolling Bearing Fault Diagnosis. IEEE Transactions on Industrial Electronics*, v. 47, n. 5, p. 1060-1069, Outubro 2000.
25. LIU, T. I.; SINGONAHALLI, J. H.; IYER, N. R.. *Detection of Roller Bearing Defects using Experts System and Fuzzy Logic. Mechanical Systems and Signal Processing*, v. 10 n. 5, p. 595-614, 1996.
26. LOPES, T. A. P.; TROYMAN, A. C. R.. *Manutenção Preditiva por Vibrações: o Sistema AD4. ALCOOLbrás*, p. 44-46, Março/Abril 2001.
27. LUCE, S.. *Choice Criteria in Conditional Preventive Maintenance. Mechanical Systems and Signal Processing*, v. 13, n. 1, p. 163-168, 1999.
28. MATHWORKS, THE. *Fuzzy Logic Toolbox: For Use With MATLAB, User's Guide. Version 2.*, MathWorks Inc., Janeiro de 1995, 227 p.

29. MECHEFSKE, C. K.. *Objective Machinery Fault Diagnosis Using Fuzzy Logic. Mechanical Systems and Signal Processing*, v. 12 n. 6, p. 855-862, 1998.
30. MENON, A. K.; BOUTAGHOU, Z.-E.. *Time-Frequency Analysis of Tribological Systems – Part I: Implementation and Interpretation. Tribology International*, v. 31, n. 9, p. 501-510, 1998.
31. MISHKOFF, H. C.. *Understanding Artificial Intelligence*. Radio Shack, 1986.
32. MORI, K.; KASASHIMA, N.; YOSHIOKA, T.; UENO, Y.. *Prediction of spalling on a ball bearing by applying the discrete wavelet transform to vibration signals. Wear*, v. 195, p. 162-168, 1996.
33. NSK. *NSK Bearing Doctor: Diagnóstico Rápido de Ocorrência em Rolamentos*. 2002.
34. PADOVESE, L. R. *Comparison of neural networks performance for fault classification in rolling bearings. Proceedings of IASTED International Conference, Applied Modeling and Simulation*, p. 6-11, 1999.
35. PADOVESE, L. R. *Automatização de Diagnóstico de Falhas em Plantas Industriais*, 2002, 142 p., Tese de Livre Docência, EP-USP.
36. PINTO, C.. *Mastering electrical motor failures. Experts on Maintenance*, Disponível em: <http://www.maintenance-tv.com/world/mtv/articles/articles.htm>. Acesso em: 24 Junho 2002.
37. PROAKIS, J.G.; MANOLAKIS, D.G.. *Digital Signal Processing*, 3rd Ed., Prentice Hall, 1996.
38. SHAW, I. S.; SIMÕES, M. G.. *Controle e Modelagem Fuzzy*. Ed. Edgard Blücher, 1999.
39. SHIROISHI, J.; LI, Y.; LIANG, S.; KURTESS, T.; DANYLUK, S.. *Bearing Condition Diagnostics via Vibration and Acoustic Emission Measurements. Mechanical Systems and Signal Processing*, v. 11, n. 5, p. 693-705, 1997.
40. SKF CONDITION MONITORING. *Prism4 for Windows: User Manual*, 1997.
41. TANDON, N.. *A Comparison of Some Vibration Parameters for the Condition Monitoring of Rolling Element Bearings. Measurements*, v. 12, p. 285-289, 1994.
42. TANDON, N.; CHOUDHURY, A.. *A Review of Vibration and Acoustics Measurement Methods for the Detetion in Rolling Element Bearings. Tribology International*, v. 32, p. 469-480, 1999.
43. TARIFA, Enrique E.; SCENNA, Nicolás J.. *Fault Diagnosis, Direct Graphs, and Fuzzy Logic. Computers Chem. Engng.*, v. 21, p. S649-S654, 1997.
44. TSOUKALAS, L. H.; UHRIG, R. E.. *Fuzzy and Neural Approaches in Engineering*. John Wiley & Sons Inc., 1997.

45. UPADHYAYA, B. R.; YAN, W.; BEHRAVESH, M. M.; HENRY, G.. *Development of a diagnosis expert system for eddy current data analysis using applied artificial intelligence methods*. **Nuclear Engineering and Design**, n. 193, p. 1-11, 1999.
46. VICENTE, S. A. da S.; MASOTTI, P. H. F.; ALMEIDA, R. G. T. de; TING, D. K. S.; PADOVESE, L. R.. *Automatic Diagnosis of Defects in Bearings Using Fuzzy Logic*. **Anais do COBEM 2001**, 2001.
47. VICENTE, S. A. V.; FUJIMOTO, R. Y.; PADOVESE, L. R.. *Rolling Bearing Fault Diagnostic System Using Fuzzy Logic*. **The 10th IEEE International Conference on Fuzzy Systems**, v. 2, 2001.
48. YANG, B.-S.; JO, Y.-C.; LIM, D.-S.. *Defect Diagnostics of Rolling Element Bearing Using Fuzzy Dichotomy Technique*. **JSME International Journal**, series C, v. 43, n. 2, p. 439-444, 2000.
49. ZENG, W. Z.. *Discussion on Maintenance Strategy, Policy and Corresponding Maintenance Systems in Manufacturing*. **Robotics Engineering and Systems Safety**, n. 55, p. 151-162, 1997.

Anexo A - LayOut do programa



Anexo B - Combinações de Estratégias de Diagnósticos

Sistema	Media/ Amostra	Rotação	Amostra	Características	Amostra/ Tipo
1	Todas	##	1 a 10	Var/Todos (1)	15 a 20
2	Todas	400	1 a 10	Var/Todos (1)	15 a 20
3	Todas	600	1 a 10	Var/Todos (1)	15 a 20
4	Todas	800	1 a 10	Var/Todos (1)	15 a 20
5	Todas	1000	1 a 10	Var/Todos (1)	15 a 20
6	Todas	1200	1 a 10	Var/Todos (1)	15 a 20
7	Todas	1400	1 a 10	Var/Todos (1)	15 a 20
8	Todas	##	1 a 15	Var/Todos (3)	15 a 20
9	Todas	400	1 a 15	Var/Todos (3)	15 a 20
10	Todas	600	1 a 15	Var/Todos (3)	15 a 20
11	Todas	800	1 a 15	Var/Todos (3)	15 a 20
12	Todas	1000	1 a 15	Var/Todos (3)	15 a 20
13	Todas	1200	1 a 15	Var/Todos (3)	15 a 20
14	Todas	1400	1 a 15	Var/Todos (3)	15 a 20
15	Todas	##	1 a 20	Var/Todos (4)	15 a 20
16	Todas	400	1 a 20	Var/Todos (4)	15 a 20
17	Todas	600	1 a 20	Var/Todos (4)	15 a 20
18	Todas	800	1 a 20	Var/Todos (4)	15 a 20
19	Todas	1000	1 a 20	Var/Todos (4)	15 a 20
20	Todas	1200	1 a 20	Var/Todos (4)	15 a 20
21	Todas	1400	1 a 20	Var/Todos (4)	15 a 20
22	Cada	##	1 a 10	Var/Todos (2)	15 a 20
23	Cada	400	1 a 10	Var/Todos (2)	15 a 20
24	Cada	600	1 a 10	Var/Todos (2)	15 a 20
25	Cada	800	1 a 10	Var/Todos (2)	15 a 20
26	Cada	1000	1 a 10	Var/Todos (2)	15 a 20
27	Cada	1200	1 a 10	Var/Todos (2)	15 a 20
28	Cada	1400	1 a 10	Var/Todos (2)	15 a 20
29	Cada	##	1 a 15	Var/Todos (2)	15 a 20
30	Cada	400	1 a 15	Var/Todos (2)	15 a 20
31	Cada	600	1 a 15	Var/Todos (2)	15 a 20
32	Cada	800	1 a 15	Var/Todos (2)	15 a 20
33	Cada	1000	1 a 15	Var/Todos (2)	15 a 20
34	Cada	1200	1 a 15	Var/Todos (2)	15 a 20
35	Cada	1400	1 a 15	Var/Todos (2)	15 a 20
36	Cada	##	1 a 20	Var/Todos (2)	15 a 20
37	Cada	400	1 a 20	Var/Todos (2)	15 a 20
38	Cada	600	1 a 20	Var/Todos (2)	15 a 20
39	Cada	800	1 a 20	Var/Todos (2)	15 a 20
40	Cada	1000	1 a 20	Var/Todos (2)	15 a 20
41	Cada	1200	1 a 20	Var/Todos (2)	15 a 20
42	Cada	1400	1 a 20	Var/Todos (2)	15 a 20

Sistema	Media/ Amostra	Rotação	Amostra	Características	Amostra/ Tipo
71	Cada	##	1 a 10	PSD_64 (6)	15 a 20
72	Cada	400	1 a 10	PSD_64 (6)	15 a 20
73	Cada	600	1 a 10	PSD_64 (6)	15 a 20
74	Cada	800	1 a 10	PSD_64 (6)	15 a 20
75	Cada	1000	1 a 10	PSD_64 (6)	15 a 20
76	Cada	1200	1 a 10	PSD_64 (6)	15 a 20
77	Cada	1400	1 a 10	PSD_64 (6)	15 a 20
78	Cada	##	1 a 10	ENVPSD_64 (10)	15 a 20
79	Cada	400	1 a 10	ENVPSD_64 (10)	15 a 20
80	Cada	600	1 a 10	ENVPSD_64 (10)	15 a 20
81	Cada	800	1 a 10	ENVPSD_64 (10)	15 a 20
82	Cada	1000	1 a 10	ENVPSD_64 (10)	15 a 20
83	Cada	1200	1 a 10	ENVPSD_64 (10)	15 a 20
84	Cada	1400	1 a 10	ENVPSD_64 (10)	15 a 20
85	Cada	##	1 a 10	PSD_128 (8)	15 a 20
86	Cada	400	1 a 10	PSD_128 (8)	15 a 20
87	Cada	600	1 a 10	PSD_128 (8)	15 a 20
88	Cada	800	1 a 10	PSD_128 (8)	15 a 20
89	Cada	1000	1 a 10	PSD_128 (8)	15 a 20
90	Cada	1200	1 a 10	PSD_128 (8)	15 a 20
91	Cada	1400	1 a 10	PSD_128 (8)	15 a 20
92	Cada	##	1 a 10	ENVPSD_128 (12)	15 a 20
93	Cada	400	1 a 10	ENVPSD_128 (12)	15 a 20
94	Cada	600	1 a 10	ENVPSD_128 (12)	15 a 20
95	Cada	800	1 a 10	ENVPSD_128 (12)	15 a 20
96	Cada	1000	1 a 10	ENVPSD_128 (12)	15 a 20
97	Cada	1200	1 a 10	ENVPSD_128 (12)	15 a 20
98	Cada	1400	1 a 10	ENVPSD_128 (12)	15 a 20
99	Todas	##	Variado	Var/Todos (13)	Variado
100	Todas	400	Variado	Var/Todos (13)	Variado
101	Todas	600	Variado	Var/Todos (13)	Variado
102	Todas	800	Variado	Var/Todos (13)	Variado
103	Todas	1000	Variado	Var/Todos (13)	Variado
104	Todas	1200	Variado	Var/Todos (13)	Variado
105	Todas	1400	Variado	Var/Todos (13)	Variado
106	Cada	##	Variado	Var/Todos (14)	Variado
107	Cada	400	Variado	Var/Todos (14)	Variado
108	Cada	600	Variado	Var/Todos (14)	Variado
109	Cada	800	Variado	Var/Todos (14)	Variado
110	Cada	1000	Variado	Var/Todos (14)	Variado
111	Cada	1200	Variado	Var/Todos (14)	Variado
112	Cada	1400	Variado	Var/Todos (14)	Variado

Anexo B - Combinações de Estratégias de Diagnósticos

43	Todas	##	1 a 10	PSD_64 (5)	15 a 20
44	Todas	400	1 a 10	PSD_64 (5)	15 a 20
45	Todas	600	1 a 10	PSD_64 (5)	15 a 20
46	Todas	800	1 a 10	PSD_64 (5)	15 a 20
47	Todas	1000	1 a 10	PSD_64 (5)	15 a 20
48	Todas	1200	1 a 10	PSD_64 (5)	15 a 20
49	Todas	1400	1 a 10	PSD_64 (5)	15 a 20
50	Todas	##	1 a 10	ENVPSD_64 (9)	15 a 20
51	Todas	400	1 a 10	ENVPSD_64 (9)	15 a 20
52	Todas	600	1 a 10	ENVPSD_64 (9)	15 a 20
53	Todas	800	1 a 10	ENVPSD_64 (9)	15 a 20
54	Todas	1000	1 a 10	ENVPSD_64 (9)	15 a 20
55	Todas	1200	1 a 10	ENVPSD_64 (9)	15 a 20
56	Todas	1400	1 a 10	ENVPSD_64 (9)	15 a 20
57	Todas	##	1 a 10	PSD_128 (7)	15 a 20
58	Todas	400	1 a 10	PSD_128 (7)	15 a 20
59	Todas	600	1 a 10	PSD_128 (7)	15 a 20
60	Todas	800	1 a 10	PSD_128 (7)	15 a 20
61	Todas	1000	1 a 10	PSD_128 (7)	15 a 20
62	Todas	1200	1 a 10	PSD_128 (7)	15 a 20
63	Todas	1400	1 a 10	PSD_128 (7)	15 a 20
64	Todas	##	1 a 10	ENVPSD_128 (11)	15 a 20
65	Todas	400	1 a 10	ENVPSD_128 (11)	15 a 20
66	Todas	600	1 a 10	ENVPSD_128 (11)	15 a 20
67	Todas	800	1 a 10	ENVPSD_128 (11)	15 a 20
68	Todas	1000	1 a 10	ENVPSD_128 (11)	15 a 20
69	Todas	1200	1 a 10	ENVPSD_128 (11)	15 a 20
70	Todas	1400	1 a 10	ENVPSD_128 (11)	15 a 20

113	Todas	##	Variado	PSD_64 (15)	Variado
114	Todas	400	Variado	PSD_64 (15)	Variado
115	Todas	600	Variado	PSD_64 (15)	Variado
116	Todas	800	Variado	PSD_64 (15)	Variado
117	Todas	1000	Variado	PSD_64 (15)	Variado
118	Todas	1200	Variado	PSD_64 (15)	Variado
119	Todas	1400	Variado	PSD_64 (15)	Variado
120	Todas	##	Variado	ENVPSD_64 (17)	Variado
121	Todas	400	Variado	ENVPSD_64 (17)	Variado
122	Todas	600	Variado	ENVPSD_64 (17)	Variado
123	Todas	800	Variado	ENVPSD_64 (17)	Variado
124	Todas	1000	Variado	ENVPSD_64 (17)	Variado
125	Todas	1200	Variado	ENVPSD_64 (17)	Variado
126	Todas	1400	Variado	ENVPSD_64 (17)	Variado
127	Todas	##	Variado	PSD_128 (16)	Variado
128	Todas	400	Variado	PSD_128 (16)	Variado
129	Todas	600	Variado	PSD_128 (16)	Variado
130	Todas	800	Variado	PSD_128 (16)	Variado
131	Todas	1000	Variado	PSD_128 (16)	Variado
132	Todas	1200	Variado	PSD_128 (16)	Variado
133	Todas	1400	Variado	PSD_128 (16)	Variado
134	Todas	##	Variado	ENVPSD_128 (18)	Variado
135	Todas	400	Variado	ENVPSD_128 (18)	Variado
136	Todas	600	Variado	ENVPSD_128 (18)	Variado
137	Todas	800	Variado	ENVPSD_128 (18)	Variado
138	Todas	1000	Variado	ENVPSD_128 (18)	Variado
139	Todas	1200	Variado	ENVPSD_128 (18)	Variado
140	Todas	1400	Variado	ENVPSD_128 (18)	Variado