UNIVERSIDADE DE SÃO PAULO ESCOLA POLITÉCNICA
DEPARTAMENTO DE ENGENHARIA MECÂNICA

RODRIGO YOSHIAKI FUJIMOTO

Diagnóstico Automático de Defeitos em Rolamentos
Baseado em Lógica Fuzzy

São Paulo

2005

RODRIGO YOSHIAKI FUJIMOTO

**Diagnóstico Automático de Defeitos em Rolamentos
Baseado em Lógica Fuzzy**

Dissertação apresentada à Escola Politécnica da
Universidade de São Paulo para obtenção do título de
Mestre em Engenharia

Área de Concentração: Engenharia Mecânica
Orientador: Prof. Dr. Linilson R. Padovese

São Paulo

2005

FICHA CATALOGRÁFICA

Fujimoto, Rodrigo Yoshiaki

**Diagnóstico automático de defeitos em rolamentos baseado em lógica *fuzzy* / R.Y. Fujimoto. -- São Paulo, 2005.
158 p.**

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Mecânica.

1.Rolamentos (Defeito; Diagnóstico) 2.Fuzzy I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia Mecânica II.t.

FUJIMOTO, R. Y. **Diagnóstico Automático de Defeitos em Rolamentos Baseado em Lógica Fuzzy**. 2005. 158F. Dissertação (Mestrado em Engenharia Mecânica) – Escola Politécnica da Universidade de São Paulo, São Paulo.

ERRATA

Folha	Linha	Onde se lê	Leia-se
ABSTRACT	5	describes	presents
3	1	propostas	a analisar
4	2	são apresentadas	apresentam-se
6	14	algoritmos	conceitos
8	16	é utilizada	utiliza-se
10	8	levando	levando-se
10	10	eles utilizam	utilizam-se
11	1	não é transparente	nem sempre é transparente
11	14	descrição matemática	descrição algébrica
11	14	descrições empíricas	descrições heurísticas
12	11	sistemas inferência fuzzy	sistemas de inferência fuzzy
12	12	modelo matemático	modelo algébrico
16	5	através de gráficos	através da análise visual dos gráficos
18	12	uma melhor desempenho	um melhor desempenho
22	9	Nesta definição	Nesta teoria
22	10	um certo valor	um valor
23	4	$A = \{x, \mu_A(x) \mid x \in X\}$	$A = (x, \mu(x))$
31	4	fornecidos por pessoas	fornecidas por especialistas

33	1	implantação	implementação
34	7	definida	definidas
37	17	estreito ... fuzzy	“estreito” ... “fuzzy”
41	2	apresentadas	propostas
44	8	foi utilizada	utiliza-se
44	10	foi tomada	toma-se
48	3	está	localiza-se
53	10	é apresentado	apresenta-se
53	17	são realizados	realizou-se
58	Fig. 4.5	(n)	(Δ)
61	7	criar	implementar
61	11	criação	obtenção
61	14	CRIAÇÃO	OBTENÇÃO
61	15	criação	obtenção
64	5	Sendo que, neste caso	Neste caso
64	5	Equação 5.3	Equação 5.2
65	6	na Figura 5.2	nas equações 5.1 e 5.2
67	7	comparando todos	comparando-se todas
68	2	bi-dimensional	bi-dimensionais
88	10	influencia a	influencia o

Agradecimentos

Ao Prof. Dr. Linilson Padovese, pela atenção e apoio durante o processo de definição, orientação e finalização.

A Escola Politécnica da USP, pela oportunidade de realização do curso de mestrado e por colocar a disposição à área experimental e o laboratório.

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

Aos meus colegas de laboratório e meu orientador que me inspiraram e auxiliaram para alcançar os resultados obtidos.

RESUMO

FUJIMOTO, R. Y. **Diagnóstico Automático de Defeitos em Rolamentos Baseado em Lógica Fuzzy**, 2005, 182 f. Dissertação (Mestrado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2005.

Este trabalho apresenta duas metodologias baseadas em lógica fuzzy para automatizar o diagnóstico de defeito em equipamentos mecânicos, além de fazer uma comparação de seu desempenho utilizando um caso experimental. As duas metodologias estudadas são: o sistema de inferência fuzzy e o algoritmo baseado em Fuzzy C-Means. O alarme estatístico é uma metodologia existente atualmente na indústria com este objetivo e que será utilizado neste trabalho para comparação de desempenho. Para realizar os testes, foram desenvolvidos programas que permitiram criar alarmes e sistemas fuzzy utilizando um banco de dados experimental. De modo diferente ao que são feitos normalmente, os sistemas fuzzy de diagnóstico testados neste trabalho foram construídos automaticamente utilizando informações do banco de dados experimentais composto por sinais de vibração, que representam a condição normal e diversos tipos de defeitos em mancais de rolamentos. Os parâmetros escalares característicos necessários para a entrada nos sistemas fuzzy foram obtidos através do processamento dos sinais de vibração de mancais de rolamentos. Nas análises realizadas neste trabalho, foi estudada a influência de diversas características de criação do sistema fuzzy. Como exemplo, pode-se citar como principal influência, a complexidade do banco de dados a ser analisado pelo sistema fuzzy. Por fim, além de apresentar uma comparação de performance entre as metodologias fuzzy apresentadas no trabalho, com o alarme estatístico, são discutidas as características de cada uma destas metodologias. Destacam-se como principais contribuições deste trabalho, a obtenção de uma metodologia utilizada para criar de maneira automática o sistema de inferência fuzzy e as modificações realizadas no algoritmo Fuzzy C-Means para aperfeiçoar o desempenho em classificação de defeitos.

Palavras-chave: lógica fuzzy, rolamento, Fuzzy C-Means, sistema de inferência fuzzy, alarme estatístico.

ABSTRACT

FUJIMOTO, R. Y. **Automatic Diagnoses of Rolling Bearing Failures Based in Fuzzy Logic**, 2005, 182 f. Dissertação (Mestrado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2005.

This work describes two proposed methodologies for the automatic diagnoses in mechanical equipment: the fuzzy system inference and a Fuzzy C-Means based algorithm. Their performances are evaluated in an experimental case and, afterwards, also compared by the statistical alarm, a diagnostic methodology very used in industries at present. In order to do the tests, a developed computer algorithm allowed creating alarms and fuzzy systems by the use of an experimental database. These tested diagnostic systems were automatically built using information from the mentioned database that was composed by samples of vibration signals, representing several types of rolling bearing defects and the bearing normal condition. The fuzzy systems input scalar parameters were obtained by signal processing. The influence of some of the building fuzzy systems parameters in the system performance was also studied, which allow establishing, for example, that the database complexity is an important factor in the fuzzy system performance. Finally, this work discusses the main characteristics of each one of the described methodologies. The most important contribution of this work is the proposition of a methodology for creating fuzzy system automatically as well as the analysis of the fuzzy C-Means as a tool for system diagnoses.

Keywords: fuzzy logic, rolling bearing, Fuzzy C-Means, fuzzy inference system, statistical alarm.

Lista de Ilustrações

<i>Figura 1.1 – Razões de falhas de rolamentos</i> ⁴³ .	5
<i>Figura 1.2 – Estrutura de um sistema especialista</i>	6
<i>Figura 2.1 – Comparação entre lógica clássica e lógica fuzzy</i> ³⁴ .	22
<i>Figura 2.2 – Padrão de regra de inferência</i>	28
<i>Figura 2.3 – Diagrama do processo de inferência fuzzy</i> ³⁴	30
<i>Figura 2.4 – Estrutura de um Sistema Fuzzy</i>	32
<i>Figura 2.5 – Exemplo de Similaridades</i>	35
<i>Figura 2.6 – Exemplo de funções de pertinência de uma única característica obtida por FCM, com expoente fuzzy m igual a: (a) 1.1 e (b) 2.0</i>	38
<i>Figura 3.1– Rolamento B015TVP da FAG (a) montado e (b) desmontado</i>	41
<i>Figura 3.2 – Esquema da ordem de aquisição dos sinais de vibração dos rolamentos.</i>	43
<i>Figura 3.3 – Esquema da bancada de ensaios</i>	44
<i>Figura 3.4 – Layout geral da bancada de ensaio de defeitos de rolamento</i>	45
<i>Figura 3.5 – Detalhe da bancada de ensaio (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 (abaixo do mancal).</i>	45
<i>Figura 3.6 – Equipamento de filtro, amplificação e conversão A/D.</i>	46
<i>Figura 3.7 – Sistema de aquisição de dados</i>	46
<i>Figura 3.8 – (a) Sistema de monitoramento da carga aplicada e (b) variador de frequência para regular a rotação do motor</i>	47
<i>Figura 3.9 – Esquema para obtenção os espectros de frequência</i>	50

<i>Figura 4.1 – Esquema da separação do banco de dados de cada parâmetro para a realização do teste do alarme estatístico.</i>	55
<i>Figura 4.2 – Gráficos para análise de desempenho do alarme estatístico do parâmetro RMS considerando o banco de dados apenas de NORMAL, apenas de DEFEITO e considerando ambos os banco de dados.</i>	56
<i>Figura 4.3 - Gráficos para análise de desempenho do alarme estatístico do parâmetro Valor de Pico de Envelope considerando o banco de dados apenas de NORMAL, apenas de DEFEITO e considerando ambos os banco de dados.</i>	57
<i>Figura 4.4 – Máximo desempenho de acertos para todos os parâmetros de análise de vibração utilizados.</i>	57
<i>Figura 4.5 – Índice de nível de alarme Δ otimizada (onde cada parâmetro de análise de vibração utilizado obteve máximo desempenho apresentado na Figura 4.4).</i>	58
<i>Figura 5.1 – Mapeamento do banco de dados hipotético de exemplo para demonstrar a metodologia.</i>	63
<i>Figura 5.2 – Parâmetros da função (a) gaussiana.</i>	64
<i>Figura 5.3 – Funções de pertinência obtidas do exemplo da Figura 5.1, para o grupo G1 (utilizando característica 1 (a) e 2 (b)).</i>	65
<i>Figura 5.4 – Funções de pertinência obtidas do exemplo da Figura 5.1, para o grupo G2 (utilizando característica 1 (a) e 2 (b) para os dois grupos).</i>	65
<i>Figura 5.5 – Regras de inferências padrões</i>	67
<i>Figura 5.6 – Regra de Inferência Padrão para o exemplo da Figura 5.1.</i>	68
<i>Figura 5.7 – Representação do conjunto (funções de pertinência e regras de inferência) para o (a) grupo G1 e o (b) grupo G2 representados no exemplo da Figura 5.1.</i>	69
<i>Figura 5.8 – Esquema do sistema fuzzy obtido por esta metodologia na forma de rede.</i>	70
<i>Figura 5.9 – As possíveis saídas do sistema fuzzy (Classificação)</i>	75

<i>Figura 5.10 – 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 abscissa.</i>	77
<i>Figura 5.11 – Tipos de funções de pertinências com os parâmetros de entrada para um valor médio 0 e um desvio padrão de 1.</i>	78
<i>Figura 5.12 – Tipos de funções de pertinências com os parâmetros de entrada para um valor médio 0 e um desvio padrão de 1.</i>	79
<i>Figura 5.13 - Influência da dispersão f_1 sobre a desempenho tanto dos sistemas fuzzy de detecção quanto de classificação.</i>	87
<i>Figura 5.14 - Funções de pertinência referente à característica RMS para saída Normal com média e desvio padrão obtida por (a) todas as amostras e (b) para cada amostra.</i>	92
<i>Figura 5.15 – Exemplo da influência do valor limiar α sobre a desempenho de detecção de diferentes banco de dados (de NORMAIS, de DEFEITO e GLOBAL) para a estratégia de Detecção.</i>	97
<i>Figura 5.16– Desempenho de detecção para o SISTEMA FUZZY NORMAL influenciada pelo o valor limiar α.</i>	98
<i>Figura 5.17 – Desempenho dos sistemas fuzzy testados</i>	99
<i>Figura 6.1 – Mapeamento dos dados de exemplo para treinamento</i>	104
<i>Figura 6.2 – Funções de Pertinência para o banco de dados de exemplo utilizando $c = 2$, (a) Grupo 1 e (b) Grupo 2.</i>	105
<i>Figura 6.3 - – Funções de Pertinência para o banco de dados de exemplo utilizando $c = 4$, (a) Cluster 1 e (b) Cluster 2.</i>	106
<i>Figura 6.4 - – Funções de Pertinência para o banco de dados de exemplo utilizando $c = 4$, (c) Cluster 3 e (d) Cluster 4.</i>	107

<i>Figura 6.5 – Graus de pertinência de cada uma das 80 amostras do banco de dados de exemplo relacionadas a um determinado cluster.</i>	108
<i>Figura 6.6 – Graus de pertinência ideais para o banco de dados de exemplo.</i>	109
<i>Figura 6.7 – Graus de pertinência de cada uma das 80 amostras do banco de dados de exemplo relacionadas a um determinado grupo.</i>	110
<i>Figura 6.8 – Funções de Pertinência para o banco de dados de exemplo utilizando $c = 4$, e posterior processo de adaptação, (a) Grupo 1 e (b) Grupo 2.</i>	111
<i>Figura 6.9 – Regra de inferência padrão utilizado pelo algoritmo FCM</i>	113
<i>Figura 6.10 – Desempenho de acerto de classificação dos sistemas FCM influenciados pelos diversos expoentes fuzzy.</i>	118
<i>Figura 6.11 - Desempenho de acerto de detecção dos sistemas FCM influenciados pelos diversos expoentes fuzzy.</i>	118
<i>Figura 6.12 – Influência do expoente fuzzy sobre o número de iterações no treinamento.</i>	119
<i>Figura 6.13 – Desempenho de acerto de classificação dos sistemas FCM influenciados pelo número de centros (ou clusters).</i>	120
<i>Figura 6.14 – Desempenho de acerto de detecção dos sistemas FCM influenciados pelo número de centros (ou clusters).</i>	120
<i>Figura 6.15 – Influência do número de centros sobre o número de iterações no treinamento.</i>	121
<i>Figura 6.16 – Desempenho de acerto de classificação dos sistemas FCM influenciados pelo número de centros (ou clusters) e pela complexidade do banco de dados, considerando uma única carga ou todas (diferenciando apenas a condição normal do defeito furo e variando todas as outras condições de rotação e parâmetros de análise de vibração apresentados na Tabela 6.1 e na Tabela 6.2).</i>	122

<i>Figura 6.17 – Desempenho de acerto de detecção dos sistemas FCM influenciados pelo número de centros (ou clusters) e pela complexidade do banco de dados, considerando uma única carga ou todas (nas condições apresentadas na Figura 6.16).</i>	123
<i>Figura 6.18 – Influência do número de centros (ou clusters) e da complexidade do banco de dados, considerando uma única carga ou todas sobre o número de iterações no treinamento (nas condições apresentadas na Figura 6.16).</i>	123
<i>Figura 6.19 – Desempenho de acerto de classificação dos sistemas FCM influenciados pela complexidade do banco de dados, considerando os defeitos que compõe o banco de dados.</i>	124
<i>Figura 6.20 – Desempenho de acerto de detecção dos sistemas FCM influenciados pela complexidade do banco de dados, considerando os defeitos que compõe o banco de dados.</i>	125
<i>Figura 6.21 – Número de iterações no treinamento dos sistemas FCM influenciado pela complexidade do banco de dados, considerando os defeitos que compõe o banco de dados.</i>	125
<i>Figura 6.22 - Desempenho de acerto de classificação dos sistemas FCM influenciados pelos parâmetros de entrada utilizados (considerando todos os defeitos).</i>	127
<i>Figura 6.23 - Desempenho de acerto de detecção dos sistemas FCM influenciados pelos parâmetros de entrada utilizados (considerando todos os defeitos).</i>	127
<i>Figura 6.24 - Número de iterações no treinamento dos sistemas FCM influenciado pelos parâmetros de entrada utilizados (considerando todos os defeitos).</i>	128

Lista de Tabelas

<i>Tabela 1.1 – Tabela resumo da norma ISO 2372 – 1974²⁰.</i>	9
<i>Tabela 1.2 – Tabela com máxima desempenho obtida para rede MLP e PNN⁴¹.</i>	11
<i>Tabela 1.3 – Principais características de sistemas de inferência fuzzy e redes neurais⁵³</i>	12
<i>Tabela 2.1 – Propriedades dos operadores lógicos fuzzy (T_T – operador T_{norm}; e T_S – operador S-norm), sendo a, b e c graus de pertinência quaisquer de $[0, 1]$.</i>	24
<i>Tabela 2.2 – Opções de operadores AND e OR</i>	26
<i>Tabela 2.3 – Opção de operador NOT</i>	27
<i>Tabela 2.4 – Opção de operador THEN</i>	28
<i>Tabela 2.5 – Opção de operador Agregação, sendo μ_{CFF} as funções de pertinência resultante do sistema fuzzy.</i>	29
<i>Tabela 3.1 – Características Geométricas do Rolamento B015TVP</i>	41
<i>Tabela 3.2 – Condições amostradas</i>	42
<i>Tabela 3.3 – Equipamento e parâmetros de aquisição dos sinais de vibração</i>	48
<i>Tabela 3.4 – Parâmetros dos sinais de vibração que compõe o grupo Var/Todos.</i>	49
<i>Tabela 3.5 – Dados dos cálculos para obtenção dos espectros de frequência</i>	51
<i>Tabela 3.6 – Tabela de resumo dos grupos de parâmetros de análise de vibração utilizados no sistema de diagnóstico automático.</i>	52
<i>Tabela 4.1 – Parâmetros dos sinais de vibração utilizados no teste do alarme estatístico.</i>	54
<i>Tabela 4.2 – Tabela com máxima desempenho obtida pelo Alarme Estatístico.</i>	60
<i>Tabela 5.1 – Médias e desvios padrões do exemplo da Figura 5.1.</i>	64
<i>Tabela 5.2 – Tabela de variações utilizadas na criação dos sistemas de inferência fuzzy.</i>	72
<i>Tabela 5.3 – Nomes das variáveis lingüísticas das funções de pertinência de saída.</i>	74

<i>Tabela 5.4 – Fatores de Proporção de Dispersão</i>	78
<i>Tabela 5.5 – Fatores de Proporção de Dispersão</i>	79
<i>Tabela 5.6 – Tabela de resumo dos grupos de parâmetros de análise de vibração utilizados no sistema de inferência fuzzy.</i>	83
<i>Tabela 5.7 – Características dos sistemas de inferência fuzzy utilizadas para a análise da influência da Dispersão f_1</i>	87
<i>Tabela 5.8 – Tabela com máxima desempenho obtida no teste com respectivas dispersões (f_1).</i>	88
<i>Tabela 6.1 – Tabela com o resumo das variações de complexidades utilizadas nos testes deste algoritmo de criação de sistemas fuzzy.</i>	115
<i>Tabela 6.2 – Resumo dos grupos de parâmetros de análise de vibração utilizados para testar o algoritmo de FCM.</i>	116
<i>Tabela 6.3 – Tabela com as estratégias que obtiveram a melhor desempenho de acerto de detecção e classificação utilizando o algoritmo FCM.</i>	129
<i>Tabela 7.1 – Resumo das máximas desempenho obtidas com cada metodologia</i>	132

Lista de Siglas

RMS	- (Root mean square) Raiz da Média Quadrática
FFCM	- Functional fuzzy c-means
CEP	- Controle Estatístico de Processo
MLP	- Multilayer Perceptron
PNN	- Probabilistic Neural Network
FCM	- 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
DEP	- 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
ISO	- International Standards Organization
LMSS	- Lockheed Martin Michoud Space Systems
VDI	- Verein Deutscher Ingenieure

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
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_{espectro}	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
t	tempo
B	largura do rolamento
Δ_{ALARME}	índice de nível de alarme

Sumário

1.	<i>INTRODUÇÃO</i>	1
1.1.	Objetivos e Contribuições _____	3
1.2.	Resumo Bibliográfico _____	4
1.2.1.	Defeitos em Mancais de Rolamentos _____	4
1.2.2.	Sistemas Especialistas _____	6
1.2.3.	Sistemas Automáticos de Diagnósticos de Falhas _____	7
1.2.4.	Alarme Estatístico _____	8
1.2.5.	Redes Neurais para Sistema Automático de Diagnóstico _____	10
1.2.6.	Sistema de Inferência Fuzzy _____	11
1.2.7.	Fuzzy C-Means _____	15
1.2.8.	Outros _____	19
2.	<i>CONCEITOS TEÓRICOS</i>	20
2.1.	Conceito de Alarme Estatístico _____	20
2.2.	Conceito de Lógica Fuzzy _____	22
2.2.1.	Função de Pertinência _____	23
2.2.2.	Operadores Lógicos _____	24
2.2.3.	Operador AND _____	25
2.2.4.	Operador OR _____	25
2.2.5.	Operador NOT _____	26
2.2.6.	Valor Limiar α _____	27
2.2.7.	Regras de Inferência _____	27
2.2.8.	Operador THEN _____	28
2.2.9.	Operador de Agregação _____	29
2.2.10.	Operador de Desfuzzificação _____	29
2.2.11.	Inferência Fuzzy _____	30
2.3.	Conceito de Sistema de Inferência Fuzzy _____	32
2.4.	Conceito de Fuzzy C-Means _____	33
2.4.1.	Similaridade _____	34

2.4.2.	Medida de Similaridade	36
2.4.3.	Algoritmo do FCM	37
3.	MATERIAIS E MÉTODOS	41
3.1.	Rolamentos	41
3.2.	Aparato Experimental	44
3.3.	Parâmetros de Análise da Vibração	48
4.	ALARMES ESTATÍSTICOS	53
4.1.	Testes	53
4.2.	Resultados e Discussões	56
5.	SISTEMA DE INFERÊNCIA FUZZY	61
5.1.	Metodologia para Automatizar a Criação do Sistema Fuzzy	61
5.1.1.	Obtenção das Funções de Pertinência	62
5.1.2.	Obtenção das Regras de Inferência	66
5.1.3.	Representação Gráfica do Sistema de Diagnóstico Fuzzy	69
5.2.	Testes	71
5.2.1.	Parâmetros de Criação do Sistema Fuzzy	73
5.2.2.	Estratégias de Diagnóstico para Teste do Sistema Fuzzy	80
5.3.	Resultados	83
5.3.1.	Tipo de Perfil da Função de Pertinência	84
5.3.2.	Influência da Dispersão f_I no desempenho do sistema fuzzy	86
5.3.3.	Valores Característicos	88
5.3.4.	Outras análises	90
5.3.5.	Melhor Desempenho	99
5.4.	Discussões dos Resultados	100
6.	FUZZY C-MEANS	102
6.1.	Obtenção das Regras de Inferência Automaticamente	102
6.2.	Discussões da Teoria	112
6.3.	Testes	114
6.3.1.	Complexidade do Banco de Dados de Criação	114
6.3.2.	Expoente Fuzzy (m)	116

6.3.3.	Número de Centros (ou <i>clusters</i>)	117
6.3.4.	Critério de Parada	117
6.4.	Resultados	117
6.4.1.	Influência do Expoente Fuzzy (m)	117
6.4.2.	Influência do Número de Centros (ou <i>clusters</i>)	119
6.4.3.	Complexidade do Banco de Dados	122
6.4.4.	Parâmetros de Análise de Vibração	126
6.4.5.	Melhor Desempenho	129
6.5.	Discussões dos Resultados	129
7.	CONCLUSÃO	131
8.	BIBLIOGRAFIA	134
	APÊNDICE	139
Apêndice A	Análise de Vibração	140
Apêndice B	Característica do Programa “Sistema_Fuzzy”	147
Apêndice C	Equações que descrevem as Funções de Pertinência	155

1. INTRODUÇÃO

Em todos os setores de atividades industriais, a importância da otimização da produtividade dos equipamentos 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. Para isto, novos conceitos estão sendo utilizados na manutenção e produção industrial. Entre estes conceitos, pode-se destacar a manutenção preditiva, que visa reduzir os custos associados à manutenção e o aumento da disponibilidade dos equipamentos, baseado na análise da condição atual do equipamento.

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 detectar e observar o desenvolvimento de um determinado defeito. A manutenção preditiva utiliza diversas ferramentas para alcançar este objetivo final, tais como, a análise de óleo, de vibração mecânica, de corrente, de emissão acústica, termografia, entre outros. Dentre estes, uma importante ferramenta é a análise de vibração mecânica do equipamento, onde os sinais obtidos através do monitoramento da vibração de mancais, redutores, motores, etc., são analisados, objetivando a detecção de uma alteração no estado do equipamento. O diagnóstico de um eventual defeito é realizado através da detecção de alguma alteração da assinatura mecânica normal do equipamento.

O diagnóstico de defeito em um componente do equipamento pode ser a simples constatação de defeito, ou, até mesmo, levar a 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 diagnóstico está ligada diretamente com a capacitação do analista.

Um empecilho para a obtenção de um diagnóstico preciso é o volume de informações que precisam ser analisadas. Uma planta industrial pode ter centenas ou milhares de pontos a serem analisados. E, diante da impossibilidade de se analisar detalhadamente cada ponto, utilizam-se programas de diagnósticos automáticos que adotam uma 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. Apesar disto, este tem sido a metodologia mais amplamente utilizada na indústria tendo resultados positivos em alguns casos.

Este trabalho propõe duas metodologias baseadas em fuzzy para automatizar um diagnóstico de falhas e obter um desempenho superior aos tradicionalmente utilizados, que são o sistema de inferência fuzzy e o algoritmo Fuzzy C-Means (FCM). Uma terceira metodologia, denominado alarme estatístico, já utilizada atualmente na indústria, é também estudada de modo que sejam possíveis a comparação de sua performance com as das outras

duas metodologias. Para as três metodologias propostas, são apresentados algoritmos para a obtenção de um sistema de diagnóstico de maneira automática.

Como estudo de caso dos sistemas de diagnóstico automático propostos, foi utilizado o caso de defeitos de mancais de rolamentos. Os mancais de rolamentos são um dos pontos mais críticos em máquinas rotativas, devido principalmente pela quantidade encontrada numa planta industrial e sua diversidade de aplicações.

Para o diagnóstico de mancais de rolamentos, foi utilizado uma bancada experimental, onde o monitoramento dos mancais de rolamento foi feito através da medida de vibração por acelerômetros. Os métodos de processamento de sinais tradicionalmente usados, como o RMS, espectro de frequência e envelope ^{19, 46,50,51}, foram utilizados no processo de diagnóstico de defeito. Neste trabalho pretende-se utilizar um grupo destes parâmetros clássicos para formar o banco de informações a ser utilizado pelo sistema de diagnóstico.

1.1. OBJETIVOS E CONTRIBUIÇÕES

Como objetivo principal deste trabalho, pretende-se estudar duas metodologias para automatizar o diagnóstico de defeitos baseada em lógica fuzzy (o sistema de inferência fuzzy e o algoritmo Fuzzy C-Means). Além disso, pretende-se apresentar duas metodologias para automatizar o processo de criação destes sistemas de diagnósticos: um algoritmo automatizado de sistema de inferência fuzzy e; um algoritmo modificado baseado em Fuzzy C-Means (FCM).

Os desempenhos destas duas metodologias serão comparados com uma terceira metodologia já utilizada na indústria: o alarme estatístico.

Serão estudadas as influências de algumas variáveis sobre o desempenho do diagnóstico das três metodologias em um caso experimental. Dentre estas variáveis pode-se destacar a complexidade do banco de dados a ser analisado.

1.2. RESUMO BIBLIOGRÁFICO

Neste item são apresentadas algumas referências bibliográficas relacionadas à importância da análise de vibração para a detecção de defeitos em mancais de rolamentos, bem como um resumo bibliográfico das metodologias estudadas neste trabalho, que são, o sistema de inferência fuzzy, o fuzzy c-means e o alarme estatístico. Outro importante aspecto apresentado a seguir é o conceito de sistemas especialistas, principalmente relacionado ao seu emprego em diagnósticos de falhas.

1.2.1. Defeitos em Mancais de Rolamentos

Em manutenção, considera-se como falha de um equipamento a situação onde o equipamento ou não pode ser utilizado, ou não permite uma qualidade adequada de produção. Neste caso, a falha é considerada a situação onde o equipamento deixa de cumprir a sua função.

Defeito refere-se a uma condição do equipamento, diferente da condição na qual ela foi projetada (uma trinca, por exemplo), que pode ou não estar provocando uma falha no equipamento. Neste caso, o defeito é considerado uma deficiência do equipamento, porém, ele não necessariamente deixa de cumprir a função a qual foi projetado.

O surgimento de um defeito num mancal de rolamento pode ter um alto impacto nos custos relacionados a uma possível falha do equipamento ^{5,30,31,38,40,51}, que são muito superiores ao custo da troca do rolamento em si.

Um exemplo é o caso de motores elétricos ⁴³, onde cerca de 37% das falhas identificadas são devidos a mancais de rolamentos, conforme pode ser observado na Figura 1.1.

Figura 1.1 – Razões de falhas em motores elétricos ⁴³.

A SKF e a NSK ^{39,48} descrevem 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 na instalação, má ou falta de lubrificação, penetração de partículas estranhas entre as pistas, sobrecargas, influência de calor externo não previsto em projeto, etc. Estas falhas podem ser mais bem identificadas após a desmontagem do rolamento e com uma profunda análise da falha do rolamento.

Existem diversos trabalhos referentes à análise da evolução da falha em mancais de rolamentos, como um exemplo está o trabalho de Barkov ⁴.

Uma das principais ferramentas utilizada para a observação do defeito antes que ocorra a falha do equipamento é a análise de vibração ^{38, 50, 51}. Esta ferramenta é mais bem discutida no Apêndice A. Outra ferramenta também utilizada é o sinal de emissão acústica ⁵¹.

1.2.2. Sistemas Especialistas

Pode-se definir sistema especialista como sendo um programa projetado especificamente para representar um conhecimento humano em um domínio particular de conhecimento (área de especialização) ³⁷.

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 1.2.

Figura 1.2 – Estrutura de um sistema especialista

A aquisição de informação para um sistema especialista pode ser feita através da análise da literatura, entrevista com 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.

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.

Entre as 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 de desempenho dos resultados e generalização do modelo pelas seguintes razões ¹⁴:

- incapacidade de imitar os processos de análise executados por especialistas;
- números finitos 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.

Da análise da revisão bibliográfica, observou-se que além de atender as limitações da lógica convencional apresentadas acima, os 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 ao fato do comportamento físico da planta a ser diagnosticado variar durante a operação. Portanto, existe 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 do sistema ⁵⁴.

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 ³⁷.

1.2.3. Sistemas Automáticos de Diagnósticos de Falhas

A necessidade de um sistema automático para diagnóstico fica clara em uma planta industrial onde existe a geração diária de uma enorme quantidade de dados que devem ser

analisados. Neste caso, o diagnóstico de falhas, implicaria em um custo muito alto 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. Assim, eles podem ter sua atenção voltada para os casos mais complexos.

Uma técnica muito usada atualmente para esta tarefa de pré-análise, para diagnóstico em mancais de rolamento, é a utilização do valor de um parâmetro (RMS, Valor de Pico, ...) obtido através de sinais de aceleração do mancal (ou de outros sinais: velocidade, deslocamento, envelope de aceleração, ...) para acionar um alarme de falha ⁴⁷, e a partir de então um especialista analisa a necessidade da troca. Esta mesma técnica pode ser utilizada para sistemas de diagnósticos de plantas industriais inteiras ²⁴.

A confiabilidade deste tipo de sistema é baixa em alguns casos ^{56,57}. Para aperfeiçoá-lo foi proposta a utilização de diversas outras técnicas. Dentre elas, pode-se citar o alarme estatístico, a rede neural ^{30,40} e sistemas fuzzy ^{31, 35,56,57}.

1.2.4. Alarme Estatístico

Como um padrão em muitas indústrias em sua manutenção preditiva, é utilizada uma pré-análise para determinar se um dado equipamento necessita de uma análise mais aprofundada. Esta pré-análise é normalmente definida por valores globais (por exemplo, de RMS de vibração) superiores a um valor limite.

Estes valores limites são divididos em duas categorias:

- alerta (quando o equipamento está em uma condição anormal);
- alarme (quando o equipamento inicia processo de falha terminal).

Para a definição destes limites, podem ser utilizadas diversas normas, por exemplo a ISO-2372²⁰ e a VDI-2056⁵⁵. Ambas as normas definem pela categoria (tamanho e suporte) da máquina qual é a faixa de vibração admissível.

As duas normas trabalham com recomendações de valores em unidades de velocidade (ex: V_{rms} (mm/s) ou V_{pico} (in/s)) ou de deslocamento (V_{pico} (μm)). Como exemplo, um gráfico resumo da norma ISO-2372²⁰ é apresentado na Tabela 1.1.

Outras recomendações de faixas admissíveis de vibração é apresentada pela ISO-10816-1²¹ e pela LMMSS³².

Existem outras recomendações de alarme utilizando o envelope de aceleração, tais como proposto por Wei⁶⁰. Ele propõe o valor do alarme baseado na rotação e diâmetro do eixo, para uma faixa de frequência definida.

Tabela 1.1 – Tabela resumo da norma ISO 2372 – 1974²⁰.

***Limites de Faixas de Velocidade e Classes de Máquinas
Padrão ISO 2372-1974***

Severidade de Vibração		Máquinas Pequenas	Máquinas Médias	Máquinas Grandes	
mm/s RMS	in/s RMS			Base Rígida	Base Flexível
		Classe I	Classe II	Classe III	Classe IV
0,28	0,011	bom	bom	bom	bom
0,46	0,018	bom	bom	bom	bom
0,71	0,028	satisfatório	bom	bom	bom
1,12	0,044	satisfatório	bom	bom	bom
1,80	0,071	satisfatório	satisfatório	bom	bom
2,79	0,110	insatisfatório	satisfatório	satisfatório	bom
4,50	0,177	insatisfatório	insatisfatório	satisfatório	satisfatório
7,11	0,280	insatisfatório	insatisfatório	insatisfatório	satisfatório
11,18	0,440	inaceitável	insatisfatório	insatisfatório	insatisfatório
18,03	0,710	inaceitável	inaceitável	insatisfatório	insatisfatório
27,94	1,100	inaceitável	inaceitável	inaceitável	insatisfatório
44,96	1,770	inaceitável	inaceitável	inaceitável	inaceitável
70,87	2,790	inaceitável	inaceitável	inaceitável	inaceitável

Vale ressaltar que os limites admissíveis apresentados nestas normas e artigos são apenas recomendações iniciais de níveis de alarmes, que não definem o modo normal de

vibrar de um equipamento específico. As limitações de vibrações variam de equipamento para equipamento, devendo ser definido a partir de uma condição de vibração tomada como referência (“*baseline*”) do equipamento, não apenas em cada início de operação da máquina, mas também, a comparação deste último com o histórico total do equipamento.

Portanto, em equipamentos onde não existe um histórico de vibração para realizar uma análise de tendência de vibração (ou obtenção da *baseline*), os valores de alarme apresentados nestas normas devem ser utilizados.

Levando em consideração as particularidades de cada equipamento, existem programas comerciais que tentam considerar o histórico de um equipamento específico ⁶¹. Para tanto, eles utilizam o alarme estatístico. Este conceito foi utilizado neste presente estudo.

1.2.5. Redes Neurais para Sistema Automático de Diagnóstico

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) ^{30, 40, 41}, e PNN (Probabilistic Neural Network) ^{40, 41}.

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 ⁵³.

Um exemplo muito claro da utilização da rede neural com o propósito de diagnóstico de falhas é o programa ADVISOR fornecido pela Bruel & Kjaer ^{13,14} 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%) ⁴¹, 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.

Os resultados obtidos por Padovese ⁴¹, que utilizou o mesmo banco de dados deste trabalho, são apresentados na Tabela 1.2. Estes resultados serão utilizados para fazer uma comparação de desempenho com as outras metodologias apresentadas neste trabalho.

Tabela 1.2 – Tabela com máxima desempenho obtida para rede MLP e PNN⁴¹.

	<i>Máximo Desempenho para Rede MLP</i>	<i>Máximo Desempenho para Rede PNN</i>
Detecção	100 %	100 %
Classificação	100 %	100 %

1.2.6. Sistema de Inferência Fuzzy

Uma das grandes desvantagens da metodologia do alarme estatístico é sua extrema simplicidade, o que o impede de modelar um sistema complexo ou de obter um modelo mais preciso. Um modo de superar essa limitação 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.

Uma vantagem do sistema de inferência fuzzy é que ele não necessita de uma descrição matemática detalhada do sistema a ser modelado, podendo ser utilizadas descrições empíricas para obter o modelo fuzzy final.

Além disso, ele permite superar a limitação do modelamento tipo caixa-preta utilizada pela rede neural.

A Tabela 1.3 apresenta uma resumida comparação entre os sistemas fuzzy e neural.

Tabela 1.3 – Principais características de sistemas de inferência fuzzy e redes neurais ⁵³

<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 desempenho
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

Além de permitir que o usuário utilize seus conhecimentos heurísticos, obtidos previamente, 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.

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 ²³, que aponta a facilidade de implementá-lo sem um profundo conhecimento do funcionamento do sistema fuzzy. Isto pode resultar em sistemas de inferência que só alcançam o resultado esperado em condições extremamente particulares.

Os sistemas inferência fuzzy são utilizados onde existem incertezas na medição, ou quando ainda não se possui um modelo matemático bem definido para estimar o comportamento de um sistema. Através de um sistema fuzzy é possível modelar um sistema extremamente complexo de uma forma mais simples e compreensiva.

Entre as vantagens da lógica fuzzy, pode-se citar ³⁴:

- 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 presentes, por exemplo, nas redes neurais.

Os sistemas de inferência fuzzy são baseados no conceito da lógica fuzzy. Este conceito e alguns parâmetros que influenciam no comportamento do sistema de inferência fuzzy são apresentados por Fujimoto ¹⁶. Dentro da lógica fuzzy, trabalha-se diretamente com as palavras, que, apesar de ser menos preciso que valores numéricos, elas são mais próximas à intuição humana, expressando a tolerância à imprecisão existente no cotidiano.

Os sistemas de inferência fuzzy não tem sido muito utilizados em diagnósticos de falhas em mancais de rolamento. Na pesquisa bibliográfica realizada foram encontrados apenas quatro artigos utilizando esta idéia ^{31,35,56,57} que utilizam sinais de vibração (ou parâmetros escalares ou vetoriais calculados a partir destes sinais de vibração) com esse fim.

A utilização de sinais de vibração também é empregada amplamente em sistemas baseados em rede neural ^{30,40,41}.

Alguns parâmetros escalares utilizados na etapa de pré-processamento (ou seja, que são utilizados como entradas) para sistemas fuzzy, e que foram encontrados na literatura, podem ser listadas como se seguem: amplitude 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 ^{56,57}, 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 ³¹ só utiliza um único parâmetro de vibração como entrada, que não descreve adequadamente o defeito no mancal de rolamento. No apresentado por Mechefske ³⁵, o sistema fuzzy detecta 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 ^{56,57} o sistema é criado utilizando apenas de conhecimentos heurísticos (um trabalho extremamente fatigante, dependendo da quantidade de dados a serem tratados).

Nos artigos ^{31,56,57}, utiliza-se como entrada do sistema, parâmetros obtidos do sinal de vibração. A utilização destes parâmetros permite comprimir uma grande quantidade de informações existentes no sinal, fornecendo apenas características relevantes para descrever o defeito. Liu ³¹ faz uma discussão sobre qual parâmetro é mais relevante para este fim, considerando o caso de defeito em rolamento.

Mechefske ³⁵ 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 ⁴¹. Uma característica deste tipo de entrada, é que este vetor possui muita informação redundante e/ou irrelevante para o desempenho do sistema de

diagnóstico, aumentando o esforço computacional e, em alguns casos, prejudicando o diagnóstico.

Além de ser utilizado no diagnóstico de falhas em mancais de rolamento, os sistemas fuzzy também são utilizados em diagnóstico de falhas em caixas de redução ²⁴ e de plantas industriais ^{23,52}, além de controles industriais, modelagem de sistemas dinâmicos, reconhecimento de padrão, entre outros ^{7,28,34,45}.

Existem diversas variações e combinações de lógica fuzzy e redes neurais com o objetivo de alcançar uma mistura das características apresentadas por ambos (Tabela 1.3). 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 utilizada para detecção de falhas em tubos de trocadores de calor em plantas nucleares ⁵⁴. 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.

1.2.7. Fuzzy C-Means

Existem diversos métodos de classificação baseado em lógica fuzzy. Billaudel ⁶ apresenta uma comparação entre quatro deles: *Fuzzy C-Means*, *Fuzzy K Nearest Neighbours*, método baseado em Regras Fuzzy e *Fuzzy Pattern Matching method*. Ele utilizou alguns bancos de dados de origens distintas para obter uma comparação destes algoritmos em diversos problemas.

Grauel ¹⁷ também apresenta uma comparação entre três métodos de classificação de padrões aplicados em um problema de controle de qualidade de usinagem: redes-neurais, sistemas fuzzy baseados em regras e FCM.

No trabalho de Grauel ¹⁷, as regras fuzzy utilizadas pelo Fuzzy C-Means são obtidas heurísticamente através de gráficos. Apesar desta idéia ser interessante, pois resulta em menores quantidades de regras de inferência e funções de pertinência que as obtidas pelo método proposto neste presente trabalho, ele possui uma grande desvantagem, pois necessita de uma análise bem profunda (maior tempo de processamento) para se alcançar às regras e funções ótimas.

O algoritmo do FCM pode ser utilizado como um compactador do banco de dados, sendo que os centros obtidos através dele são utilizados para descrever as funções de pertinência, como por exemplo, valores médios de função de pertinência do tipo gaussiana. É esta a idéia utilizada por Chen ⁷ em seu trabalho.

Definindo, *Fuzzy c-means* (FCM) é uma técnica ou algoritmo para se obter *clusters* ou grupos de similaridades em um conjunto de dados. Neste caso, cada elemento do banco de dados pertence a um *cluster* por um determinado grau de pertinência. Esta técnica foi originalmente proposto por Dunn e generalizado por Jim Bezdek em 1973 como um aperfeiçoamento de métodos de obtenção de *clusters* anteriormente proposto ³⁴.

O propósito de se obter grupos de similaridade ou *clusters* é identificar grupos naturais de dados a partir de um grande conjunto de dados para produzir uma representação concisa do comportamento de um sistema.

Este algoritmo utiliza a noção de distância para definir o grau de pertinência de um dado elemento a um *cluster*. A medida de distância normalmente utilizada é a euclidiana. Os centros obtidos por este algoritmo tentam minimizar a distância intraclasses (entre

componentes relacionados a um determinado centro) e maximizar a distância interclasses (entre centros).

Na literatura são apresentadas diversas modificações do algoritmo do FCM. Entre elas pode-se citar o proposto por Joentgen ^{24,25}, para tratamento de dados na forma de funções, por Flores-Sintas ¹⁵, utilizando a medida de distância de Mahalanobis em vez da euclidiana, e por Cheng ⁹, que forneceu um aperfeiçoamento na velocidade de convergência do algoritmo.

Joentgen ^{24,25} apresenta em seus dois artigos um modo de se trabalhar com funções dinâmicas (ou tendências temporais). Enquanto na maioria das vezes se trabalha com características que descrevem o perfil de uma função (ou vetor de entrada), ele apresenta um modo de se trabalhar com comparações diretamente da própria função, ou seja, sem a necessidade de um pré-processamento. Esta visão é utilizada para modificar o algoritmo do FCM (*fuzzy c-means*) formar o chamado FFCM (*functional fuzzy c-means*).

A principal contribuição dada por Joentgen ^{24,25}, não é tanto o FFCM, que não possui, estruturalmente, diferença muito grande com o FCM, mas sim, a visão de se trabalhar diretamente com a função (ou vetor de entrada) utilizando uma variação do FCM.

Nos seus trabalhos, Joentgen ^{24,25} exemplifica a utilização deste algoritmo para identificar falhas em caixa de redução. A função (vetor de entrada) que ele utiliza na comparação é o espectro de frequência. É enfatizado o fato de não necessitar de qualquer conhecimento de especialista, uma vez que o sistema de diagnóstico verifica se houve variação do espectro, mas ignora qual seja a natureza desta mudança.

Ao se utilizar a distância euclidiana no algoritmo FCM, existe a hipótese de uma distribuição homogênea e isotrópica dos grupos dentro do banco de dados, o que não ocorre em muitos casos. Apesar de não se determinar perfeitamente estas duas características (homogeneidade e isotropia) dentro de um banco de dados, no caso onde se conhecem estas falhas, podem-se utilizar diferentes medidas de distâncias para suplantar este problema. Neste

contexto, Flores-Sintas ¹⁵, propôs uma modificação do algoritmo de FCM de modo a utilizar a distância Mahalanobis (para obter grupos elípticos) sem a necessidade de acrescentar novas restrições que complicariam o problema.

Uma desvantagem deste algoritmo FCM é o seu alto tempo de processamento devido à sua natureza iterativa e o grande número de vetores de características normalmente envolvidos no cálculo. Para resolver este problema, Cheng ⁹ propôs o mrFCM (*Multistage Random Sampling Fuzzy C-Means*), que utiliza diversas amostras aleatórias do banco de dados de tamanho muito inferior (não utiliza todo o banco de dados de entrada) para obter os centros de *cluster* iniciais. Posteriormente, estes são utilizados para inicializar o algoritmo FCM. Este algoritmo foi aplicado em um banco de dados para reconhecimento de imagem de ressonância de cérebros e imagens de satélite.

No FCM existem dois parâmetros principais para obter uma melhor desempenho do algoritmo, o expoente fuzzy m e o número de *cluster* c (discutido em maior detalhes ver Item 2.4.3). Dependendo da escolha destes fatores, podem-se alcançar resultados muito diversos. Em muitos artigos ^{6,7,17} são apresentados modos para otimizar estes dois parâmetros através de critérios de validades, tais como: critério de separabilidade e compactabilidade, grau de partição, hipervolume fuzzy, entre outros.

Estes critérios não são analisados no presente trabalho uma vez que aqui se pretende analisar principalmente a aplicabilidade do FCM em diagnóstico de defeitos em rolamentos.

Uma das características do algoritmo do FCM é o fato dele usar uma limitação para os graus de pertinência que produz apenas pertinências relativas, ou seja, que depende de todos os *clusters*. Isto não ocorre na formulação da teoria de conjunto fuzzy feita por Zadeh. Nela, o grau de pertinência de um ponto no domínio de discurso para um conjunto fuzzy é independente dos graus de pertinências em outros conjuntos fuzzy definidos no mesmo domínio de discurso ¹⁵.

Outra característica do algoritmo, é a sua ampla dependência dos centros de *cluster* iniciais, não apenas na velocidade de convergência, mas também na precisão nos centros de *cluster* obtidos no final ⁹. Por isso, no presente trabalho, decidiu-se não utilizar uma escolha aleatória para estes centros de *cluster* iniciais, mas sim, centros obtidos de conhecimento prévio do banco de dados.

O método do FCM é muito útil se existe um conhecimento superficial das propriedades do sistema a ser modelado, uma vez que ele não precisa de conhecimento de especialista explícito. Além disso, ele possui um tempo de adaptação menor se comparado com redes neurais artificiais ¹⁷.

Pode-se trabalhar com o algoritmo FCM utilizando-o em conjunto com outros métodos. Chen ⁷ utiliza o FCM em conjunto com o *Fuzzy K-Nearest Neighbours* para diagnosticar a produtividade de algumas empresas fictícias. Por exemplo, enquanto o FCM é utilizado para obter os *clusters*, o *Fuzzy K-Nearest Neighbours* é utilizado para classificar uma nova amostra em algum dos *clusters* obtidos previamente.

Normalmente, para se aplicar o FCM ⁷, o banco de dados é normalizado pelo valor médio e o desvio padrão referentes a cada característica que descreve o hiper-espço. Isto evita a dominância de uma característica sobre as outras, devido a uma discrepância de magnitudes.

1.2.8. Outros

Outros métodos utilizados, ou que podem ser utilizados, para o diagnóstico de falhas são a grafos de causas-efeito ⁵², a técnica de dicotomia fuzzy ⁵⁸, *support vector machines* (SVMs) ²², entre outros.

2. CONCEITOS TEÓRICOS

2.1. CONCEITO DE ALARME ESTATÍSTICO

Sob condições de operação normais, o nível de vibração medido em um equipamento deveria permanecer em uma faixa de alarme relacionada com a incerteza estatística da medição ⁶¹. Esta incerteza estatística de medida é descrita por uma distribuição gaussiana ou normal. Portanto, ele poderá ser representado por um valor médio (ou linha central, $\bar{x}$) e seu desvio padrão (σ).

O conceito do alarme estatístico utiliza algumas regras para determinar se existem anormalidades (não relacionadas à incerteza estatística de medição) que possam estar relacionadas a uma falha ou condição adversa de operação. Deste modo, o alarme estatístico só pode ser utilizado na tarefa de diagnosticar, ou seja, identificar a ocorrência de uma anormalidade, mas ele não permite classificar o tipo de anormalidade ocorrida.

Existem algumas regras estatísticas (utilizados por exemplo no Controle Estatístico de Processo ⁴⁹) que determinam em quais condições pode-se definir se existiu alguma variação no sistema. Ampliando os conceitos presentes em análise de gráfico de controle utilizado no Controle Estatístico de Processo (CEP)⁴⁹, (utilizado para determinar a ocorrência de anormalidades em um processo qualquer) pode-se diagnosticar anormalidades no comportamento normal da vibração de um equipamento. As regras utilizadas na análise de gráfico de controle no CEP ⁴⁹ são.

- 01 ponto além de $(3 \times \sigma)$ da linha central;
- 09 pontos consecutivos de um lado da linha central;
- 06 pontos consecutivos, crescente ou decrescente;

- 14 pontos consecutivos, alternando para cima e para baixo;
- 02 de 3 pontos além de $(2 \times \sigma)$ da linha central (mesmo lado);
- 04 de 5 pontos além de $(1 \times \sigma)$ da linha central (mesmo lado);
- 15 pontos consecutivos até $(1 \times \sigma)$ da linha central (em ambos os lados);
- 08 pontos consecutivos além de $(1 \times \sigma)$ da linha central (em ambos os lados);

Apesar da existência destas regras estatísticas para determinar anormalidades, o alarme estatístico ⁶⁰ utiliza apenas de uma única destas regras.

- Se o *Valor Global* (ou ponto de controle) é maior que *Alarme* (ou *Alerta*) existe o defeito.

Sendo o valor de *Alarme* (ou *Alerta*) definindo por:

$$Alarme = \bar{x} + \Delta_{ALARME} \sigma$$

Equação 2.1

Sendo $\bar{x}$ e σ , respectivamente, o valor médio e desvio padrão da distribuição gaussiana do parâmetro considerado, e Δ_{ALARME} (ou *índice do nível de alarme*) um valor a ser definido pelo analista de vibração.

Não existe um valor de Δ_{ALARME} (ou *índice do nível de alarme*) definido para estes limites de vibrações. Apenas como um exemplo, Wier ⁶¹ utiliza como valor para este índice Δ_{ALARME} , entre 2 (para Alerta) e 3 (para Alarme).

Porém, este parâmetro Δ_{ALARME} (ou *índice do nível de alarme*) deve ser escolhido pelo analista de acordo com a confiabilidade dele no banco de dados histórico de vibração.

2.2. CONCEITO DE LÓGICA FUZZY

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

Sobre este assunto, Lotfi Zadeh, o “pai” da lógica fuzzy, cita ³⁴: “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 conceito 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 2.1, onde se ilustra a classificação de altura de pessoas.

Figura 2.1 – Comparação entre lógica clássica e lógica fuzzy ³⁴.

Os conjuntos fuzzy 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 ⁵³:

$$A = \{x, \mu_A(x) \mid x \in X\} \quad \textbf{Equação 2.2}$$

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 2.1.b, a função de **pertinência** é o perfil que relaciona o valor numérico da altura (x) e o grau de pertinência (μ).

2.2.1. Função de Pertinência

A função de pertinência μ_A associa a um dado componente x do universo de discurso X , o seu respectivo grau de pertinência em um determinado conjunto fuzzy.

Dentre os diversos perfis ou funções que são utilizados para este propósito, estão ¹⁶:

- Trapezoidal;
- Triangular;
- Gaussiano;
- Pi;
- Beta;

Conforme apresentado no Apêndice C, as funções de pertinência podem ser descritas através de equações, sendo que, em casos de perfis simétricos, utilizam-se nestas equações, o

valor médio (m) e a dispersão (Δ), e até dois fatores de proporção de dispersão indicando a abertura do perfil (f_1 e f_2).

2.2.2. Operadores Lógicos

De modo análogo à lógica clássica, na lógica fuzzy existem os operadores de conjunto⁷, 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:

$$\mu_{A \cap B}(x) = T_T(\mu_A(x), \mu_B(x)) \quad \text{Equação 2.3}$$

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

$$\mu_{A \cup B}(x) = T_S(\mu_A(x), \mu_B(x)) \quad \text{Equação 2.4}$$

Existem diversas definições para estes operadores. Normalmente, para obter uma relação com a lógica clássica, procura-se satisfazer as propriedades da Tabela 2.1. Karnik²⁷ apresenta outras leis ou propriedades que os operadores lógicos devem possuir.

Tabela 2.1 – 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 2.1, elas são usadas na prática.

2.2.3. 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 ⁷ na Tabela 2.2.

2.2.4. Operador OR

Este operador define a união entre dois conjuntos fuzzy. Análogo ao operador AND, para esta operação já foram apresentadas na literatura ⁷ 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 2.2.

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 foi utilizada para os dois operadores nos testes realizados neste trabalho.

Tabela 2.2 – Opções de operadores AND e OR

	<i>AND/Intersecção ($\cap$)</i>	<i>OR/União ($\cup$)</i>
<i>Zadeh</i>	$\min(\mu_A[x], \mu_B[y])$	$\max(\mu_A[x], \mu_B[y])$
<i>Mean</i>	$\frac{\mu_A[x] + \mu_B[y]}{2}$	$\frac{\left(2 \min(\mu_A[x], \mu_B[y]) + \right.}{6}$ $\left. + 4 \cdot \max(\mu_A[x], \mu_B[y]) \right)$
<i>Mean²</i>	$Mean(\cap)^2$	$Mean(\cup)^2$
<i>Mean^{1/2}</i>	$\sqrt{Mean(\cap)}$	$\sqrt{Mean(\cup)}$
<i>Produto</i>	$\mu_A[x] \times \mu_B[y]$	$(\mu_A[x] \times \mu_B[y]) - \mu_A[x] + \mu_B[y]$
<i>Bounded Sum</i>	$\max(0, \mu_A[x] + \mu_B[y])$	$\min(1, \mu_A[x] + \mu_B[y])$
<i>Yager</i>	$1 - \min\left(1, \left((1 - \mu_A[x])^k + (1 - \mu_B[y])^k\right)^{1/k}\right)$	$\min\left(1, \left(\mu_A[x]^k + \mu_B[y]^k\right)^{1/k}\right)$
<i>Zysno</i>	$\left(\prod_{i=1}^n \mu_i[x]\right)^{(1-\gamma)} \left(1 - \prod_{i=1}^n (1 - \mu_i[x])\right)^\gamma$	
<i>Dubois</i>	$\frac{\mu_A[x] \times \mu_B[y]}{\max(\mu_A[x], \mu_B[y], k)}$	$\frac{\left((\mu_A[x] + \mu_B[y]) - (\mu_A[x] + \mu_B[y]) - \right.}{\max(1 - \mu_A[x], 1 - \mu_B[y], k)}$ $\left. - \min(\mu_A[x], \mu_B[y], 1 - k) \right)$

2.2.5. 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 ⁷ diversas variações, dentre elas, são apresentadas na Tabela 2.3 algumas destas opções.

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

Tabela 2.3 – 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>	$\frac{1}{2}(1 + \cos(\pi \times \mu_A[x]))$

2.2.6. Valor Limiar 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 limiar α é considerado como sendo nulo. Este valor é escolhido baseado em conhecimentos empíricos do criador do sistema fuzzy.

2.2.7. 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.

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*

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 2.2 – Padrão de regra de inferência

2.2.8. Operador THEN

Além dos operadores lógicos de intersecção (AND), união (OR) e complemento (NOT), como pode ser observado na Figura 2.2, 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 conseqüente. Esta influência pode ser definida pelas operações apresentadas na Tabela 2.4. Nesta tabela, 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 2.4 – Opção de operador THEN

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

2.2.9. 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 consequência do sistema como um todo devido às entradas do sistema fuzzy. Esta consequência pode ser definida pelas funções apresentadas na Tabela 2.5.

Tabela 2.5 – Opção de operador Agregação, sendo μ_{CFF} as funções de pertinência resultante do sistema fuzzy.

	<i>Agregação($\leftarrow$)</i>
<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*.

2.2.10. 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 ³⁴:

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

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

2.2.11. 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 ³⁴.

Pode-se definir dois tipos de sistemas de inferência, o proposto por Mandani e o proposto por Sugeno ³⁴. 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 2.2.2);
3. Aplicação do operador THEN (Implicação – Item 2.2.8);
4. Agregar as saídas de todas as regras (Oper. de Agregação – Item 2.2.9);
5. Desfuzzificação (Item 2.2.10).

Este processo pode ser resumido na Figura 2.3.

Figura 2.3 – Diagrama do processo de inferência fuzzy ³⁴

O modelo de Mandani possui as seguintes vantagens:

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

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:

$$\text{IF } x \text{ é } A \text{ E/OU } y \text{ NÃO é } B \text{ E/OU } \dots w \text{ é } F \text{ ENTÃO } u = k$$

Onde k é um valor constante dentro do universo de discurso da saída. As saídas deste processo podem ser denominadas *singletons*.

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

$$\text{IF } x \text{ é } A \text{ E/OU } y \text{ NÃO é } B \text{ E/OU } \dots w \text{ é } F \text{ ENTÃO } u = p.x + q.y + r$$

Sendo p , q e r constantes. Neste modelo, 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;

2.3. CONCEITO DE SISTEMA DE INFERÊNCIA FUZZY

Um sistema de inferência fuzzy é um método que permite modelar um sistema através de regras simples, utilizando os conceitos de lógica fuzzy^{28,34}. A estrutura de um sistema de inferência fuzzy pode ser esquematizado como é mostrado na Figura 2.4.

Figura 2.4 – 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:
 - a. tipo de operador AND, OR e NOT da regra de inferência;
 - b. tipo de operador THEN (ou conclusão);
 - c. tipo de operador de agregação;
 - d. tipo de operador de desfuzzificação;
 - e. 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 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 projetista do sistema fuzzy, são as regras de inferência deste problema. Ou seja, a relação entre causa e consequência.

Finalmente, o especialista do sistema fuzzy define os parâmetros operacionais do sistema fuzzy, e cria o sistema de inferência.

Após um projeto inicial, devem-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.

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

2.4. CONCEITO DE FUZZY C-MEANS

Fuzzy C-means ou FCM é um algoritmo para separar em grupos de similaridades, ou *clusters*, um conjunto de pontos ou dados, minimizando uma função objetiva fuzzy escolhida previamente. Estes *clusters* obtidos por este algoritmo são representados por vetores

protótipos. A similaridade entre estes vetores protótipos e os vetores de dados é representado por um grau de pertinência entre 0 e 1. Deste modo, um modo mais simples de se definir o FCM, é como sendo um algoritmo para obtenção de funções de pertinência.

2.4.1. Similaridade

Um conceito muito importante na lógica fuzzy e utilizada no conceito do Fuzzy C-Means é a similaridade, por ser uma das medidas amplamente utilizadas e discutidas para obter as funções de pertinência.

A similaridade entre dois elementos podem ser definida de duas formas:

- *similaridade estrutural*: semelhança de forma, evolução e característica de uma determinada função que descreve o elemento;
- *similaridade pontual*: pela medida de distância no espaço de característica que descreve o elemento.

A diferença entre estas duas definições é mais bem observada quando se faz uma comparação entre duas funções no tempo ou em qualquer outro domínio (por exemplo, sinais de vibrações e espectros de frequência). Uma função pode ser tratada de duas formas, através dos pontos de sua trajetória (uma vez que na prática normalmente se trabalha com funções discretas), ou por características numéricas que descreve o perfil desta função.

No primeiro, ao se comparar duas funções pelos pontos de sua trajetória, pode-se considerar cada um destes pontos como sendo uma característica distinta. Com isso, alcança-se um espaço de característica de N dimensões, sendo N o número de pontos da função. A similaridade pontual considera este espaço de característica para definir o grau de similaridade. Este grau de similaridade é obtido através de uma medida de distância.

Já a similaridade estrutural está mais ligada às características numéricas que descrevem o perfil de uma função. Entre estas características pode-se citar o RMS, mínimo e máximo global, características estatísticas (Skewness e Kurtosis), entre outros. O grau de similaridade é obtido comparando um conjunto destas características, e, portanto, pode-se dizer que esta similaridade está relacionada à escolha destas características. Esta similaridade pode ser obtida também através da medida de distância.

Figura 2.5 – Exemplo de Similaridades

Através da Figura 2.5 pode-se exemplificar esta diferença de similaridade. Considerando a similaridade pontual, as funções A e B são mais similares entre si, do que em relação a C e D. Porém, ao se considerar a similaridade estrutural (neste exemplo, apenas a ondulação da função) as funções A e B perdem esta similaridade. Na Figura 2.5, a função estruturalmente mais similar a A é a função C, e a função mais similar à B é a função D.

Por esta discussão apresentada acima, fica claro que existe um ponto de sobreposição entre estas duas definições de similaridade. Esta sobreposição se refere ao fato de se considerar os pontos da trajetória da função como características que a descrevem o seu perfil,

e posteriormente tratá-los de modo semelhante à similaridade pontual (através de medida de distância).

Outra diferença entre similaridades é que a pontual trabalha com características de mesma natureza (por exemplo, neste trabalho utilizou-se apenas valores de aceleração em m/s^2), e a estrutural trabalha com características de diferentes naturezas (por exemplo, valor de pico, RMS, Kurtosis,...).

Neste trabalho, foram utilizados grupos de características que usam ambos os conceitos. Estes grupos de características são apresentados posteriormente.

2.4.2. Medida de Similaridade

Um modo para se obter uma medida de similaridade entre dois vetores é utilizando a distância entre os dois. Considerando dois vetores g e h , e a medida de distância entre eles como sendo $d(g,h)$, o grau de similaridade pode ser definido por²⁵:

$$s(g,h) = \frac{1}{1 + d(g,h)} \quad \text{Equação 2.5}$$

A medida de distância entre dois vetores pode assumir diversas formas, entre elas pode-se citar principalmente a distância euclidiana:

$$d(g,h) = \sqrt{\sum_{i=1,\dots,n} (g(i) - h(i))^2} \quad \text{Equação 2.6}$$

Neste trabalho foi utilizada esta definição euclidiana para se calcular os graus de pertinência.

2.4.3. Algoritmo do FCM

Este algoritmo tem como objetivo calcular um conjunto B de vetores protótipos b_i , a partir de um conjunto X de objetos de treinamento x_j . Estes dois conjuntos são relacionados por outro conjunto U de graus de pertinência $\mu_{i,j}$. O objeto de treinamento x_j é um vetor de S valores característicos que representam um determinado dado. Analogamente, o vetor protótipo b_i é o centro do grupo de similaridade i e deve possuir também S valores característicos.

Neste algoritmo é utilizada a seguinte função de pertinência ¹⁵:

$$\mu_{i,j} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{i,j}}{d_{k,j}} \right)^{\frac{2}{m-1}}} \quad \forall i = 1, \dots, c \quad e \quad \forall j = 1, \dots, N \quad \text{Equação 2.7}$$

O problema de encontrar *clusters*, ou seja, aplicar o FCM, pode ser formulado como sendo a minimização de uma função objetiva. Esta função é definida por FLORES-SINTAS ¹⁵ como sendo:

$$J(B, U; X) = \sum_{i=1}^c \sum_{j=1}^N (\mu_{i,j})^m \cdot d^2(x_j, b_i) \quad \text{Equação 2.8}$$

sendo que se deseja obter c *clusters*, utilizando N objetos de treinamento.

O parâmetro m é o expoente fuzzy (definido em valores acima de 1). O expoente fuzzy controla as sobreposições das funções de pertinência. Quanto maior o valor de m , mais estreito é a função de pertinência, ou seja, mais fuzzy. Isto pode ser visto claramente na Figura 2.6.

Figura 2.6 – Exemplo de funções de pertinência de uma única característica obtida por FCM, com expoente fuzzy m igual a: (a) 1.1 e (b) 2.0

Para garantir a convergência do algoritmo são impostas duas restrições:

$$\sum_{i=1}^c \mu_{i,j} = 1 \quad \forall j = 1, \dots, N$$

Equação 2.9

$$\mu_{i,j} \in [0,1] \quad \forall i = 1, \dots, c \quad e \quad \forall j = 1, \dots, N$$

Equação 2.10

A primeira restrição indica que os conjuntos fuzzy são excludentes, ou seja, não existe nenhum dado que pertença completamente (grau de pertinência igual a 1) a dois conjuntos distintos. Já a segunda restrição é a própria definição de grau de pertinência. Quando este é nulo, o dado não está contido no respectivo conjunto fuzzy, e quando grau de pertinência é 1, o dado está contido completamente ao conjunto fuzzy. Estas duas restrições podem ser vistas claramente na Figura 2.6. Como pode ser visto nesta figura, nos centros dos *clusters* ou das funções de pertinência (neste exemplo, 3.0, 7.5 e 15.0) os graus de pertinência são 1 para uma única função de pertinência e 0 para as outras. Esta é um perfil de função de pertinência diferente das utilizadas para o sistema de inferência fuzzy (apresentado no item 5.3.1).

Deve-se enfatizar novamente que no algoritmo FCM, o grau de pertinência está amplamente relacionado ao grau de similaridade entre dois vetores, o vetor protótipo e o vetor objeto.

O algoritmo do FCM utilizado e apresentado neste trabalho trabalha com *clusters* hiper-esféricos, devido à escolha da medida euclidiana de distância, apesar de ser o mais utilizado existem variações deste algoritmo que utilizam *clusters* elípticos que não são discutidos nesta monografia.

A seguir são apresentados os passos do algoritmo FCM:

1. Inicialização:

Escolhe-se o número de *clusters* c , o expoente fuzzy m , e o critério de parada. Inicialmente, deve-se gerar a matriz de pertinência U composta por u_{ij} . Normalmente, esta matriz é obtida aleatoriamente respeitando as restrições apresentadas na Equação 2.9 e Equação 2.10.

2. Determinação dos centros dos clusters b_i .

$$b_i = \frac{\sum_{j=1}^N (\mu_{i,j})^m \cdot x_j}{\sum_{j=1}^N (\mu_{i,j})^m} \quad \forall i = 1, \dots, c \quad \text{Equação 2.11}$$

3. Recálculo dos graus de pertinências μ_{ij} .

$$\mu_{i,j} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{i,j}}{d_{k,j}} \right)^{\frac{2}{m-1}}} \quad \forall i = 1, \dots, c \quad e \quad \forall j = 1, \dots, N \quad \text{Equação 2.12}$$

4. Verificação do critério de parada.

Existem diversos critérios de paradas possíveis. Neste trabalho foi utilizada a comparação das variações dos graus de pertinência. Caso o valor máximo de variação

ocorrido em uma iteração for maior que uma meta pré-estabelecida, o critério de parada não é atendido.

5. Se o critério de parada não é atendido, os passos 2 a 4 são repetidos.

A partir do algoritmo apresentado acima foram feitos alguns procedimentos para melhor adaptá-lo ao problema de reconhecimento de padrão utilizando banco de dados com alvos conhecidos. Esta adaptação é feita de modo a obter automaticamente as regras de inferência de sistema fuzzy.

3. MATERIAIS E MÉTODOS

Para realizar os testes das metodologias apresentadas neste trabalho, foi necessária a obtenção de alguns dados experimentais de sinais de vibração. A seguir é apresentado um resumo da metodologia utilizada para obter estes dados.

3.1. ROLAMENTOS

O banco de dados foi obtido utilizando rolamentos rígidos de esferas desmontáveis B015TVP da FAG (Figura 3.1) ¹², cujas características geométricas são apresentadas na Tabela 3.1.

Figura 3.1– Rolamento B015TVP da FAG (a) montado e (b) desmontado

Tabela 3.1 – Características Geométricas do Rolamento B015TVP

Característica Geométrica		(mm)
<i>Diâmetro do Elemento Rolante (mm)</i>	d	7,2
<i>Diâmetro da Trajetória do Elemento (mm)</i>	D	27,6
<i>Largura do Rolamento (mm)</i>	B	10,0
<i>Ângulo de Contato (°)</i>	α_c	0
<i>Número de Esferas</i>	Z	10

O banco de dados é composto de sinais de aceleração medidos em mancais de rolamentos normais e com defeitos em classes de condições conforme mostradas na Tabela 3.2. Os defeitos, localizados tanto na pista externa quanto na pista interna, são um pequeno furo, corrosão 1 (faixa transversal exposta à água do mar sintética por 8 horas), corrosão 2 (idem ao anterior, com tempo de exposição de 24 horas) e pista integralmente riscada. A vibração foi medida em seis diferentes rotações (de 400 rpm a 1400 rpm), e para cada rotação foram aplicadas três diferentes cargas radiais (200 N, 400 N e 600 N).

Tabela 3.2 – Condições amostradas

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

Quanto à ordem de aquisição de sinais de vibração, foram obtidas inicialmente, para cada rolamento, com um determinado defeito, 5 amostras em cada velocidade de rotação e carga aplicada. Posteriormente, o rolamento foi desmontado e montado novamente, e foi medido um novo conjunto de 5 amostras de sinais. Após realizar a aquisição com todos os rolamentos com defeito e com o normal, este mesmo procedimento é realizado novamente. Cada conjunto de 5 amostras de sinais é denominado neste trabalho como sequência. Um esquema desta ordem descrita, é apresentado na Figura 3.2.

primeira seqüência de aquisições

última seqüência de aquisições

XXX

condição a ser modificada para a próxima seqüência de aquisições

seqüência de aquisições realizada a seguir

conjunto de seqüência de aquisições realizadas (exemplo, todas as condições de rotação, ou todas as condições de carga ou todas as condições de carga e rotação).

Figura 3.2 – Esquema da ordem de aquisição dos sinais de vibração dos rolamentos.

Portanto, obteve-se um banco de dados composto de 20 amostras (4 seqüências de 5 amostras) de cada condição de sistema mostrado na Tabela 3.2. Com esta ordem de aquisição de dados, incluiu-se no banco de dados diversas condições que não consideradas na Tabela 3.2, e portanto, não são estudadas neste trabalho, mas que existem na prática, como, por exemplo o método de montagem do rolamento. Deste modo, criou um sistema de diagnóstico robusto, que não é influenciado por estas outras condições não estudadas no presente trabalho.

3.2. *APARATO EXPERIMENTAL*

Para a aquisição dos sinais que compõem o banco de dados, foi utilizada a bancada de ensaios apresentada no esquema da Figura 3.3, e na foto da Figura 3.4. 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 vertical 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 3.3 – Esquema da bancada de ensaios

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-amplicador utilizado foi ajustado em uma frequência de corte de 1,5 kHz. A amplificação do sinal foi ajustada em função da amplitude do sinal resultante, de modo a obter a maior resolução possível, sem ocorrer a saturação do sistema de conversão analógico-digital.

Figura 3.4 – Layout geral da bancada de ensaio de defeitos de rolamento

Figura 3.5 – Detalhe da bancada de ensaio (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 (abaixo do mancal).

Figura 3.6 – 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 3.7 – Sistema de aquisição de dados

Para o controle de rotação do motor utilizou-se o variador de frequência TOSHIBA® TOSVERT VF-S72004P(2) (Figura 3.8.b).

Figura 3.8 – (a) Sistema de monitoramento da carga aplicada e (b) 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 3.8.a).

Como parâmetro de aquisição, foi utilizadas uma taxa de amostragem de 5 kHz com 10 segundos de amostragem. A Tabela 3.3 resume o equipamento e os parâmetros de aquisição utilizados.

Posteriormente, o sinal foi convertido de Volts para a unidade de aceleração (m/s^2), que é utilizada para se realizar a análise do sinal, e obtenção dos parâmetros escalares que

foram a entrada do sistema fuzzy. Nesta mesma etapa, todos os sinais foram centrados em zero.

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

Tabela 3.3 – Equipamento e parâmetros de aquisição dos sinais de vibração

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

3.3. PARÂMETROS DE ANÁLISE DA VIBRAÇÃO

Nas plantas industriais, normalmente a análise da vibração é feita utilizando sinal de um acelerômetro convertido em unidade de velocidade. Porém, pretendeu-se realizar os testes apresentados neste trabalho com a menor quantidade possível de pré-processamento. Portanto, foi escolhido utilizar o sinal puro em aceleração ao invés de transformá-lo em velocidade.

Para a análise das metodologias de diagnóstico apresentadas neste trabalho utilizaram-se alguns parâmetros dos sinais de vibração apresentados no Apêndice A. Eles são mostrados na Tabela 3.4.

Tabela 3.4 – Parâmetros dos sinais de vibração que compõe o grupo *Var/Todos*.

<i>Sinal de Origem</i>	<i>Parâmetro</i>	<i>Símbolo</i>
<i>Sinal de Vibração</i>	(1) RMS, (2) Kurtosis, (3) Skewness, (4) Valor de Pico, (5) ER	RMS (Normal) Kurtosis (Normal) Skewness (Normal) Pico (Normal) ER (Normal)
<i>Amplitude Máxima do Espectro de Freqüência do Sinal de Vibração entre:</i>	(6) 0 e 500 Hz, (7) 501 e 1000 Hz, (8) 1001 e 1500 Hz	Pico B1 (Normal) Pico B2 (Normal) Pico B3 (Normal)
<i>Envelope do Sinal</i>	(9) RMS, (10) Kurtosis, (11) Skewness, (12) Valor de Pico, (13) ER	RMS (Envelope) Kurtosis (Envelope) Skewness (Envelope) Pico (Envelope) ER (Envelope)
<i>Amplitude Máxima do Espectro de Freqüência do Envelope do sinal entre:</i>	(14) 0 e 500 Hz, (15) 501 e 1000 Hz, (16) 1001 e 1500 Hz	Pico B1 (Envelope) Pico B2 (Envelope) Pico B3 (Envelope)

Estes parâmetros foram utilizados para formar um primeiro grupo de parâmetros de análise (denominado como *Var/Todos*) que foi utilizado nos testes dos sistemas de

diagnóstico. Estes parâmetros foram escolhidos, pois são os mais comumente utilizados na indústria e em artigos técnicos.

Outros grupos de parâmetros utilizados, foram as amplitudes do espectro de frequência do sinal de 0 a 1250 Hz obtidas pelo esquema mostrado na Figura 3.9. Com estas amplitudes foram obtidos quatro grupos de espectros, denominados *PSD_64*, *PSD_128*, *ENVPSD_64* e *ENVPSD_128*. Obteve-se cada um dos quatro grupos de espectros através do esquema mostrado na Figura 3.9 utilizando os dados de cálculos descritos na Tabela 3.5. Maiores detalhes com relação à obtenção do espectro de vibração são apresentados por Proakis ⁴⁴.

No 2º grupo (denominado *PSD_64*) utilizaram-se as amplitudes em cada frequência do espectro de vibração que possuía uma resolução de aproximadamente 9,76 Hz (65 pontos). No 3º grupo (denominado *PSD_128*) este espectro de vibração possuía uma resolução de aproximadamente 4,88 Hz (129 pontos). Estas resoluções foram usadas tanto para o espectro do sinal de vibração, quanto para o espectro do sinal de envelope (neste caso, denominados *ENVPSD_64* e *ENVPSD_128*, respectivamente).

Figura 3.9 – Esquema para obtenção os espectros de frequência

Estes grupos de parâmetros foram escolhidos, pois o espectro de vibração, tanto do sinal de vibração quanto de seu envelope, possuem as informações necessárias para o

diagnóstico do mancal de rolamento analisado. Estas informações normalmente são decifradas pelo analista de vibração, que neste caso, está sendo simulado pelo sistema de diagnóstico automático.

Tabela 3.5 – Dados dos cálculos para obtenção dos espectros de frequência

<i>Características/Grupo</i>	<i>PSD_64</i>	<i>ENVPSD_64</i>	<i>PSD_128</i>	<i>ENVPSD_128</i>
	<i>2º Grupo</i>	<i>3º Grupo</i>	<i>4º Grupo</i>	<i>5º Grupo</i>
<i>Frequência de amostragem na aquisição do sinal (Hz)</i>	5000		5000	
<i>Frequência de amostragem após reamostragem (Hz)</i>	1250		1250	
<i>Frequência máxima do espectro (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	

É feita uma análise global dos sistemas de diagnósticos utilizando estes diferentes grupos de parâmetros.

Resumindo os parâmetros utilizados como entrada para os sistemas de diagnóstico automático, tem-se a Tabela 3.6.

Tabela 3.6 – Tabela de resumo dos grupos de parâmetros de análise de vibração utilizados no sistema de diagnóstico automático.

<i>Grupo</i>	<i>Características</i>	
1º	Var/Todos (16 parâmetros)	<ul style="list-style-type: none"> ✓ (1) RMS, (2) Kurtosis, (3) Skewness, (4) Valor de Pico, (5) ER do sinal; ✓ Amplitude da Máxima Frequência do sinal entre (6) 0 e 500 Hz, entre (7) 501 e 1000 Hz e entre (8) 1001 e 1500 Hz; ✓ (9) RMS, (10) Kurtosis, (11) Skewness, (12) Valor de Pico, (13) ER do Envelope do sinal; ✓ Amplitude da Máxima Frequência do Envelope do sinal entre (14) 0 e 500 Hz, entre (15) 501 e 1000 Hz e entre (16) 1001 e 1500 Hz.
2º	PSD_64 (64 parâmetros)	Espectro de Vibração de Aceleração com 64 pontos e frequência máxima de 625 Hz.
3º	PSD_128 (128 parâmetros)	Espectro de Vibração de Aceleração com 128 pontos e frequência máxima de 625 Hz.
4º	ENVPSD_64 (64 parâmetros)	Envelope do Espectro de Vibração de Aceleração com 64 pontos e frequência máxima de 625 Hz.
5º	ENVPSD_128 (128 parâmetros)	Envelope do Espectro de Vibração de Aceleração com 128 pontos e frequência máxima de 625 Hz.

4. ALARMES ESTATÍSTICOS

Na análise de vibração em plantas industriais, normalmente se utilizam valores globais de vibração limiares para determinar a condição de trabalho de um equipamento. Estes valores limiares são definidos como alarmes (ou alertas).

Normalmente, estes valores são obtidos via recomendações ou normas que são baseados em condições padrões de uma família de equipamento.

Entretanto, existe uma grande quantidade de equipamentos que não seguem a tendência padrão de sua família, de modo que os valores de alarme se tornam ineficientes para representar a condição do equipamento.

Neste capítulo, é apresentado um conceito existente, mas não muito utilizado na análise de vibração, que são os alarmes estatísticos. Estes alarmes são obtidos considerando o histórico de vibração de um determinado equipamento, e seu sistema de decisão é baseado em lógica clássica.

4.1. TESTES

Com o objetivo de analisar o comportamento de alguns parâmetros de entrada sobre o alarme estatístico, bem como para comparar a desempenho desta metodologia com as outras apresentadas neste trabalho, são realizados alguns testes para verificar a eficiência do método do alarme estatístico.

Para a realização destes testes, foram utilizados os seguintes parâmetros de vibração apresentados na Tabela 4.1 (ver Capítulo 3) aplicados ao banco de dados de teste, obtendo um conjunto de valores característicos.

Tabela 4.1 – Parâmetros dos sinais de vibração utilizados no teste do alarme estatístico.

<i>Sinal de Origem</i>	<i>Parâmetro</i>	<i>Símbolo</i>
<i>Sinal de Vibração</i>	(1) RMS, (2) Kurtosis, (3) Skewness, (4) Valor de Pico, (5) ER	RMS (Normal) Kurtosis (Normal) Skewness (Normal) Pico (Normal) ER (Normal)
<i>Amplitude Máxima do Espectro de Frequência do Sinal de Vibração entre:</i>	(6) 0 e 500 Hz, (7) 501 e 1000 Hz, (8) 1001 e 1500 Hz	Pico B1 (Normal) Pico B2 (Normal) Pico B3 (Normal)
<i>Envelope do Sinal</i>	(9) RMS, (10) Kurtosis, (11) Skewness, (12) Valor de Pico, (13) ER	RMS (Envelope) Kurtosis (Envelope) Skewness (Envelope) Pico (Envelope) ER (Envelope)
<i>Amplitude Máxima do Espectro de Frequência do Envelope do sinal entre:</i>	(14) 0 e 500 Hz, (15) 501 e 1000 Hz, (16) 1001 e 1500 Hz	Pico B1 (Envelope) Pico B2 (Envelope) Pico B3 (Envelope)

Extraiu-se deste conjunto de valores característicos todos os aqueles obtidos com um determinado parâmetro dos sinais de vibração (por exemplo, RMS). Dentre esses, separou-se os valores obtidos com o grupo de rolamentos considerados NORMAIS. A partir deste grupo, foram escolhidos aleatoriamente cerca de 25% deles para calcular o seu valor médio e desvio padrão que foram utilizados para obter o nível de alarme.

Com o restante do banco de dados, escolheu-se aleatoriamente mais 50% dos dados para testar a desempenho do alarme obtido. Neste último banco de dados de teste podem ser distinguidas duas categorias, uma considerada como sendo NORMAL e outra considerada como possuindo DEFEITO.

Um resumo esquemático desta separação do banco de dados para criação e teste do alarme estatístico é apresentado na Tabela 4.2.

<i>BANCO DE DADOS</i>		25 %	25 %	25 %	25 %
NORMAL					
DEFEITO	RISCADO INT				
	RISCADO EXT				
	CORROSÃO 1 INT				
	CORROSÃO 2 INT				
	CORROSÃO 1 EXT				
	CORROSÃO 2 EXT				
	FURADO INT				
	FURADO EXT				

	Banco de dados para treinamento
	Banco de dados para teste

Figura 4.1 – Esquema da separação do banco de dados de cada parâmetro para a realização do teste do alarme estatístico.

Para obtenção do nível de alarme, utilizou-se a Equação 2.1. Neste teste variou-se o valor de Δ_{ALARME} (ou *índice do nível de alarme*) para determinar a melhor desempenho para cada parâmetro considerado. Esta variação ocorreu entre 0,1 a 4,0.

Uma vez que o alarme estatístico só permite a **Detecção** de um defeito, não é possível realizar a **Classificação** (ou tipo) deste defeito (por exemplo, furo, corrosão, riscado,...).

4.2. RESULTADOS E DISCUSSÕES

Como resultados das análises realizadas, apresenta-se os seguintes gráficos das Figura 4.2, Figura 4.3, Figura 4.4 e Figura 4.5. Estes resultados são discutidos em seguida. Nestes gráficos, foram utilizadas as seguintes definições:

$$\text{Acertos de Defeitos} = \frac{\text{Número de Acertos de Defeitos}}{\text{Número Total de Testes de Defeitos}} [\%] \quad \text{Equação 4.1}$$

$$\text{Acertos de Normais} = \frac{\text{Número de Acertos de Normais}}{\text{Número Total de Testes de Normais}} [\%] \quad \text{Equação 4.2}$$

$$\text{Acertos Totais} = \frac{1}{2} \left(\text{Acertos de Defeitos} + \text{Acertos de Normais} \right) [\%] \quad \text{Equação 4.3}$$

Figura 4.2 – Gráficos para análise de desempenho do alarme estatístico do parâmetro RMS considerando o banco de dados apenas de NORMAL, apenas de DEFEITO e considerando ambos os banco de dados.

Figura 4.3 - Gráficos para análise de desempenho do alarme estatístico do parâmetro Valor de Pico de Envelope considerando o banco de dados apenas de NORMAL, apenas de DEFEITO e considerando ambos os banco de dados.

Figura 4.4 – Máximo desempenho de acertos para todos os parâmetros de análise de vibração utilizados.

Alarmes Estatísticos (Máximos Desempenhos)

Figura 4.5 – Índice de nível de alarme Δ otimizada (onde cada parâmetro de análise de vibração utilizado obteve máximo desempenho apresentado na Figura 4.4).

Nos gráficos da Figura 4.2 e da Figura 4.3 é exemplificada a influência do índice de nível de alarme Δ_{ALARME} sobre a desempenho (ou número de acerto). Todos os parâmetros de análise de vibração utilizados nesta metodologia (RMS, Kurtosis, Skewness,...) apresentaram o mesmo comportamento destes dois gráficos.

Percebe-se que o **Acertos de Normais** tende a aumentar conforme o aumento de Δ_{ALARME} (ou *índice do nível de alarme*) enquanto o **Acertos de Defeitos** possui uma tendência inversa, ou seja, possui uma queda conforme aumenta o valor de Δ_{ALARME} . Este fato ocorre, pois de acordo com o aumento do nível de alarme Δ_{ALARME} , o diagnóstico fica menos sensível para identificar as diferenças entre o NORMAL e o DEFEITO, de modo a identificar todos os NORMAIS corretamente, porém, diagnosticando erroneamente o DEFEITO também como NORMAL.

Balanceando a desempenho de **Acertos de Normais** e a desempenho de **Acertos de Defeitos**, obtendo assim, a desempenho de **Acertos Totais**, percebe-se a existência de um ponto ótimo de melhor desempenho ou acerto.

O ponto ótimo de melhor desempenho para cada parâmetro de análise de vibração pode ser observado na Figura 4.5, sendo que sua respectiva desempenho é apresentada na Figura 4.4.

Pela Figura 4.5, percebe-se que a melhor desempenho está em grande maioria dos casos dos parâmetros de análise de vibração localizado na faixa de Δ_{ALARME} (ou *índice do nível de alarme*) entre 1,0 e 2,5, com exceção de dois parâmetros (Pico B1 Normal e Pico B3 Envelope).

Pelos resultados apresentados na análise dos testes da metodologia de alarme estatístico, observa-se que não se pode definir um valor de Δ_{ALARME} (ou *índice do nível de alarme*) ótimo aplicável a todos os parâmetros de análise de vibração apresentados, uma vez que foram obtidos diferentes índices ótimos para cada parâmetro (variando na faixa de 1,0 a 2,5).

O valor ótimo vai depender tanto da capacidade do parâmetro escolhido de diferenciar o caso NORMAL dos casos com DEFEITO (grande diferença entre as médias) quanto da capacidade de repetibilidade do parâmetro (pequeno desvio padrão). Porém, o mesmo procedimento utilizado neste trabalho, separando um banco de dados de treinamento e de teste pode ser utilizado em qualquer caso, para determinar o índice do nível de alarme ótimo para um dado equipamento qualquer e parâmetro escolhido para ser utilizado.

Finalmente, verificou-se que o melhor desempenho obtido através da metodologia do alarme estatística foi do parâmetro ER em Envelope, com um valor de 76,0% de acertos.

Este desempenho ótimo obtido com o sistema de diagnóstico de Alarme Estatístico (76,0% de acertos) é utilizada para comparação com os sistemas de diagnósticos obtidos através de outras metodologias apresentadas a seguir neste trabalho.

Tabela 4.2 – Tabela com máxima desempenho obtida pelo Alarme Estatístico.

	<i>Detecção</i>
Desempenho de Acertos	76,0 %
Parâmetro de Entrada	ER em Envelope
Δ_{ALARME}	2,0

Relembramos que o alarme estatístico permite apenas a detecção de uma anormalidade ou falha, não sendo possível classificar qual o tipo da falha. Além disso, ele é baseado apenas do histórico de dados analíticos que o equipamento possui, não sendo possível agregar conhecimentos heurísticos ao modelo.

Nos casos onde não exista um banco de dados completo e amplo de um determinado equipamento, pode-se aplicar o alarme estatístico utilizando um banco de dados composto de equipamentos semelhantes. Caso, estes últimos não existam, o alarme estatístico não pode ser proposto, sendo normalmente usados os valores recomendados em normas. Com o tempo, logo que se obtenha um bando de dados mais amplo, o alarme estatístico pode ser instalado no equipamento ou seu valor atualizado.

5. SISTEMA DE INFERÊNCIA FUZZY

Uma das principais desvantagens ou limitações de um sistema fuzzy é a necessidade de um especialista do problema para obter o conhecimento heurístico para construir as funções de pertinência, regras de inferência e outros componentes necessários no sistema fuzzy (por exemplo, tipo de operadores lógicos, operador de desfuzzificação,...). Este trabalho pode ser extremamente longo, em função da complexidade do sistema a ser implementado.

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. Aqui se podem separar as funções de pertinências em dois tipos: as de entrada (para o processo de fuzzificação), e as de saída (para obter as conseqüências de cada regra).

Na metodologia utilizada neste trabalho para criação de sistema de inferência fuzzy, pretendeu-se focar principalmente na resolução dos problemas de criação da função de pertinência de entrada e da regra de inferência.

5.1. METODOLOGIA PARA AUTOMATIZAR A CRIAÇÃO DO SISTEMA FUZZY

Um modo de se resolver os problemas de criação da função de pertinência de entrada e da regra de inferência é utilizando uma metodologia para criar o sistema de inferência fuzzy automaticamente baseando-se em informações contidas em um banco de dados ¹⁶.

Apesar desta metodologia automatizar estes dois processos de criação do sistema fuzzy (funções de pertinência de entrada e regras de inferência), outros parâmetros, tais como: as funções de pertinência de saída, operadores lógicos, operadores de implicação, entre outros; ainda precisam ser definidos pelo usuário.

Esta metodologia é apresentada detalhadamente a seguir, mostrando as etapas de criação automática das funções de pertinência e das regras de inferência. Para melhor ilustrar cada etapa proposta, será utilizado um exemplo simples, posteriormente o sistema de inferência será aplicado no caso real proposto no Capítulo 3.

Aplicando neste caso real, os desempenhos dos sistemas de inferência obtidos por esta metodologia serão comparados com os desempenhos das outras metodologias (alarme estatístico e Fuzzy C-Means) propostas neste presente trabalho.

5.1.1. Obtenção das Funções de Pertinência

Inicialmente, o usuário deve definir as *condições a serem identificadas* (parâmetro de interesse), obtidas em diversas *condições experimentais* (parâmetros que não se pretende diagnosticar).

Posteriormente, devem-se escolher as *Características* que descrevem as *condições a serem identificadas*.

Apenas para *fins ilustrativos*, vamos considerar um exemplo de banco de dados hipotético. Este exemplo é muito mais simples que um banco de dados real, mas permite uma melhor compreensão dos passos utilizados na metodologia.

Neste exemplo, têm-se duas *condições a ser identificada* (Grupo G1 e Grupo G2). Para cada uma delas, como se pode observar pela figura, existem duas *condições experimentais* (Condição C1 e Condição C2).

Para cada elemento destes grupos são obtidos dois valores de *Características* (1 e 2). Para facilitar a visualização destes grupos foi feito a representação da Figura 5.1. O objetivo neste exemplo é criar um sistema de diagnóstico que determine a *condição a ser identificado* (*G1* ou *G2*) através dos valores das *Características* (1 e 2).

Figura 5.1 – Mapeamento do banco de dados hipotético de exemplo para demonstrar a metodologia.

Para um dado *grupo* e *condição experimental* (G1-C1, G1-C2, G2-C1 e G2-C2) definido, é calculada a média de cada *Característica* (1 e 2) 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*.

No exemplo proposto acima, têm-se os seguintes valores de médias e desvio padrão:

Tabela 5.1 – Médias e desvios padrões do exemplo da Figura 5.1.

		<i>Característica 1</i>		<i>Característica 2</i>	
		<i>Média (m)</i>	<i>Desvio Padrão (σ)</i>	<i>Média</i>	<i>Desvio Padrão (σ)</i>
<i>Grupo G1</i>	<i>G1_C1</i>	0.93	0.25	0.96	0.33
	<i>G1_C2</i>	3.98	0.31	2.99	0.28
<i>Grupo G2</i>	<i>G2_C1</i>	4.05	0.28	1.05	0.21
	<i>G2_C2</i>	2.09	0.29	2.08	0.27

Posteriormente, é definido para cada valor característico um tipo de perfil de função de pertinência, que melhor o represente. No exemplo proposto neste item, foi escolhido arbitrariamente utilizar um perfil do tipo gaussiano, apresentado na Figura 5.2.

Figura 5.2 – Parâmetros da função (a) gaussiana.

Sendo que a função de pertinência pode ser representada através do valor médio (m) e uma dispersão (Δ). Sendo que, neste caso, a dispersão Δ é definida pela Equação 5.3.

$$\mu_{GAUSS}(x; m, \Delta) = e^{-\left(\frac{m-x}{\Delta}\right)^2} \quad \text{Equação 5.1}$$

$$\Delta = \sigma \times f_1 \quad \text{Equação 5.2}$$

Assim, devem-se definir as dispersões (Δ') para o perfil da função de pertinência. No exemplo proposto neste item, foi escolhido utilizar um fator de proporção de dispersão f_I de 2,0.

Tanto o perfil quanto o fator devem ser escolhidos de acordo com conhecimentos prévios do usuário.

Posteriormente, com cada um dos valores médio e respectivos desvios padrão, é criado uma função de pertinência com as equações apresentadas na Figura 5.2. As oito funções de pertinência obtidas através de cada conjunto de média e desvio padrão da Tabela 5.1 são apresentados na Figura 5.3 e Figura 5.4.

Figura 5.3 – Funções de pertinência obtidas do exemplo da Figura 5.1, para o grupo G1 (utilizando característica 1 (a) e 2 (b)).

Figura 5.4 – Funções de pertinência obtidas do exemplo da Figura 5.1, para o grupo G2 (utilizando característica 1 (a) e 2 (b) para os dois grupos).

As funções de pertinência criadas a partir das características são agrupadas e relacionadas a uma *condição a ser identificada* (Grupo G1 e Grupo G2).

5.1.2. Obtenção das Regras de Inferência

Uma vez que as funções de pertinência foram criadas utilizando o procedimento descrito acima, devem-se definir as regras de inferência que regem o sistema fuzzy, e que relaciona a entrada com a saída.

Nesta metodologia, definiu-se uma regra de inferência 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* ou padrões *a serem identificadas*);

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

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

As regras de inferência fuzzy padrões são:

$$\begin{aligned}
 & \textbf{SE } \{[X(1)] \text{ é } [N(i,1,1)] \textbf{ OU } [X(1)] \text{ é } [N(i,1,2)] \textbf{ OU } \dots \textbf{ OU } [X(1)] \text{ é } [N(i,1,p(i,1))]\} \textbf{ E } \{[X(2)] \text{ é } \\
 & [N(i,2,1)] \textbf{ OU } [X(2)] \text{ é } [N(i,2,2)] \textbf{ OU } \dots \textbf{ OU } [X(2)] \text{ é } [N(i,2,p(i,1))]\} \textbf{ E } \dots \textbf{ E } \{[X(m)] \text{ é } [N(i,m,1)] \textbf{ OU } \\
 & [X(m)] \text{ é } [N(i,m,2)] \textbf{ OU } \dots \textbf{ OU } [X(m)] \text{ é } [N(i,m,p(i,1))]\} \textbf{ ENTÃO } [Y(i)] \text{ é } [Def(i)] \textbf{ SENÃO} \\
 \\
 & \textbf{SE } \{[X(1)] \text{ é } [N(i+1,1,1)] \textbf{ OU } [X(1)] \text{ é } [N(i+1,1,2)] \textbf{ OU } \dots \textbf{ OU } [X(1)] \text{ é } [N(i+1,1,p(i+1,1))]\} \textbf{ E } \\
 & \{[X(2)] \text{ é } [N(i+1,2,1)] \textbf{ OU } [X(2)] \text{ é } [N(i+1,2,2)] \textbf{ OU } \dots \textbf{ OU } [X(2)] \text{ é } [N(i+1,2,p(i+1,1))]\} \textbf{ E } \dots \textbf{ E } \\
 & \{[X(m)] \text{ é } [N(i+1,m,1)] \textbf{ OU } [X(m)] \text{ é } [N(i+1,m,2)] \textbf{ OU } \dots \textbf{ OU } [X(m)] \text{ é } [N(i+1,m,p(i+1,1))]\} \textbf{ ENTÃO} \\
 & [Y(i+1)] \text{ é } [Def(i+1)] \textbf{ SENÃO} \\
 \\
 & \textbf{SE } \dots
 \end{aligned}$$

Figura 5.5 – Regras de inferências padrões

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.

Do exemplo da Figura 5.1, obtêm-se as seguintes regras:

<p>SE $\{[X(1)] \text{ é } [G1_C1_Caract1] \text{ OU } [X(1)] \text{ é } [G1_C2_Caract1]\}$ E $\{[X(2)] \text{ é } [G1_C1_Caract2] \text{ OU } [X(2)] \text{ é } [G1_C2_Caract2]\}$ ENTÃO $[Y(i)] \text{ é } [G1]$ SENÃO</p> <p>SE $\{[X(1)] \text{ é } [G2_C1_Caract1] \text{ OU } [X(1)] \text{ é } [G2_C2_Caract1]\}$ E $\{[X(2)] \text{ é } [G2_C1_Caract2] \text{ OU } [X(2)] \text{ é } [G2_C2_Caract2]\}$ ENTÃO $[Y(i)] \text{ é } [G2]$</p>
--

Figura 5.6 – Regra de Inferência Padrão para o exemplo da Figura 5.1.

Utilizando para os operadores **OU** e **E**, que são as funções de máximo e mínimo, respectivamente, chega-se nas seguintes representações bi-dimensional da Figura 5.7 quando se aplica as regras de inferência da Figura 5.6 nas funções de pertinência da Figura 5.3 e Figura 5.4.

(a)

(b)

Figura 5.7 – Representação do conjunto (funções de pertinência e regras de inferência) para o (a) grupo G1 e o (b) grupo G2 representados no exemplo da Figura 5.1.

5.1.3. Representação Gráfica do Sistema de Diagnóstico Fuzzy

Um outro modo de se representar graficamente o sistema de inferência fuzzy obtido por esta metodologia é na forma de rede, como ilustrado na Figura 5.8. Nesta figura as linhas

finas estão relacionadas às *Características* de entrada e as linhas grossas às *condições a serem identificadas*.

Nesta figura, além da saída normalmente utilizada por um sistema fuzzy, que é a saída desfuzzificada, também é proposto um outro tipo de saída para identificação da *condição a ser identificada* mais “ativada” ou mais semelhante ao sinal a ser identificado.

Figura 5.8 – Esquema do sistema fuzzy obtido por esta metodologia na forma de rede.

5.2. TESTES

A metodologia apresentada no item 5.1, para criação automática de sistemas fuzzy foi utilizada para criar alguns sistemas de detecção e classificação de defeitos em rolamentos.

O banco de dados utilizado neste teste é composto de conjuntos de sinais de vibrações para cada *condição a ser identificada* (parâmetros de interesse, neste teste, o tipo de defeito do rolamento), e obtidas em diversas *condições experimentais* (parâmetros que não se pretende diagnosticar, tais como rotação do eixo ou carga).

Inicialmente, escolheram-se os parâmetros ou valores característicos dos sinais de vibrações a serem utilizados como entrada do sistema de inferência fuzzy. A partir do banco de dados, são calculados os valores característicos escolhidos para cada sinal de vibração, utilizando as equações citadas no **Apêndice A**.

Como se está enfocando a análise de sinais de vibrações, a metodologia apresentada é iniciada com este tipo de informação bruta, sem um tratamento de sinal mais criterioso. Porém, esta metodologia pode ser empregada considerando-se já conhecidas os valores característicos.

Foram testadas algumas combinações de estratégias de diagnóstico apresentadas no item 5.2.2, podendo estas serem resumidas na Tabela 5.2.

Tabela 5.2 – Tabela de variações utilizadas na criação dos sistemas de inferência fuzzy.

<i>Tipo de Variação</i>	<i>Nomenclatura</i>	<i>Quantidade de Variações</i>	<i>Variações</i>
<i>Conjuntos de Criação</i>	Amostra	04	1 a 10 1 a 15 1 a 20 Variado
<i>Rotação</i>	Rotação	07	## 400 600 800 1000 1200 1400
<i>Grupo de Parâmetros para Análise de Vibração</i>	Características	05	Var/Todos PSD_64 ENVPSD_64 PSD_128 ENVPSD_128
<i>Perfil da Função de Pertinência</i>		05	Trapezoidal Triangular Gaussiana Pi Beta
<i>Tipo de Estratégia de Diagnóstico</i>		02	Classificação Detecção
<i>Tipo de Cálculo de Médias e Desvios Padrões utilizados na função de Pertinência</i>	Média/Amostra	02	Todas Cada

As diferentes combinações das possibilidades apresentadas acima permitem gerar 1400 sistemas fuzzy diferentes. Destes, foram testados cerca de 980 sistemas fuzzy. Esta grande variedade de sistemas fuzzy permitiu realizar uma análise de sensibilidade quanto aos perfis das funções de pertinência e aos grupos de características.

5.2.1. Parâmetros de Criação do Sistema Fuzzy

Os seguintes parâmetros do sistema fuzzy foram utilizados nos sistemas de inferência fuzzy apresentadas a seguir:

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

Além destes, foi definido por tentativa e erro as funções de pertinência de saída que irão ser utilizados para a etapa de desfuzzificação. No caso de diagnóstico com detecção e classificação, foram utilizadas nos sistemas fuzzy as funções apresentadas na Figura 5.9. Conforme observada na figura, as variáveis lingüísticas utilizadas para estas funções de pertinência de saída são apresentadas na Tabela 5.3, 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 nível de gravidade **0** relacionado com a condição normal e o nível de gravidade **10** relacionado com os defeitos utilizados para montar o banco de dados.

Tabela 5.3 – 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 5.9 – As possíveis saídas do sistema fuzzy (Classificação)

Para o 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. Neste teste foi utilizado como **valor limiar de índice fuzzy**, escolhido após alguns testes, um nível de 0,1.

Outro parâmetro importante para os sistemas fuzzy é o perfil da função de pertinência de entrada. Neste trabalho, como padrão, é utilizada uma função de pertinência de entrada com perfil Beta e dispersão (f_I) de 1,0.

Um exemplo das funções de pertinências obtidos é apresentado na Figura 5.10, onde é possível ilustrar a aplicação desta metodologia no caso específico determinado para este trabalho. Para o 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 teste, uma dada rotação e carga – ver Capítulo 3).

Figura 5.10 – 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 abscissa.

Um dos parâmetros dos sistemas fuzzy que foi variado para a análise de sensibilidade é o tipo de perfil da função de pertinência (Figura 5.11), utilizando os fatores de proporção de dispersão, que são apresentadas na Tabela 5.4.

Tabela 5.4 – 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 5.11 – 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 5.12. Estes parâmetros são apresentados na Tabela 5.5.

Tabela 5.5 – 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 5.4.

Figura 5.12 – Tipos de funções de pertinências com os parâmetros de entrada para um valor médio 0 e um desvio padrão de 1.

5.2.2. Estratégias de Diagnóstico para Teste do Sistema Fuzzy

São propostas algumas variações ou estratégias de diagnósticos que podem ser utilizadas no sistema de inferência fuzzy com o objetivo de alcançar maior confiabilidade. Algumas combinações destas estratégias foram feitas nos testes realizados neste trabalho.

5.2.2.1. 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.

O primeiro, chamado de (*Amostra-1 a 10*), é composto somente com um quarto do banco de dados total. O segundo, chamado de (*Amostra-1 a 15*), é composto com metade do banco de dados total. O terceiro, chamado de (*Amostra-1 a 20*), é composto por todo o banco de dados. O quarto, chamado de (*Amostra-Variado*), é composto por dez amostras obtidas aleatoriamente do banco de dados inteiro.

Estas combinações visam verificar a robustez do sistema, ou seja, se a dispersão das funções de pertinência (relacionada com a dispersão das amostras) são adequadas para descrever as variáveis lingüísticas e se outros parâmetros não controlados influenciam no desempenho do sistema fuzzy.

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 por um quarto do banco de dados (que não foram utilizados na etapa de criação, quando possível), e foi utilizado para testar os sistemas fuzzy criados a partir dos conjuntos de criação: (*Amostra-1 a 10*), (*Amostra-1 a 15*) e (*Amostra-1 a 20*). O outro, denominado (*Amostra/Tipo-Variado*), é composto por sete amostras obtidas aleatoriamente do banco de

dados inteiro, e foi utilizado para testar os sistemas fuzzy criados a partir do conjunto de criação (*Amostra-Variado*).

5.2.2.2. *Variação de Rotação*

Cada um dos conjuntos de dados do item 5.2.2.1 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***).

5.2.2.3. *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 dos parâmetros característicos (RMS, Kurtosis, etc,...) obtidos para cada condição de carga e rotação de cada conjunto de criação do sistema fuzzy, ou seja, das variações experimentais feitas. Nos testes apresentados aqui, 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***).

5.2.2.4. *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 (***Deteccção***). Com esta última estratégia, não é possível definir qual o defeito que ocorreu, mas apenas detectar o defeito.

O diagnóstico de ***Deteccção*** 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 diversos parâmetros característicos, ao contrário dos alarmes tradicionais que utilizam, sobretudo, 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.

5.2.2.5. *Escolha dos Parâmetros Característicos de Vibração*

Os parâmetros característicos foram divididos em cinco grupos com diferentes parâmetros de análise de vibração que foram utilizados no sistema de inferência fuzzy. Estes parâmetros de análise de vibração são apresentados no Apêndice A. Um resumo destes grupos é apresentado na Tabela 5.6.

Tabela 5.6 – Tabela de resumo dos grupos de parâmetros de análise de vibração utilizados no sistema de inferência fuzzy.

<i>Grupo</i>	<i>Características</i>	
1º	Var/Todos (16 parâmetros)	<ul style="list-style-type: none"> ✓ (1) RMS, (2) Kurtosis, (3) Skewness, (4) Valor de Pico, (5) ER do sinal; ✓ Amplitude da Máxima Frequência do sinal entre (6) 0 e 500 Hz, entre (7) 501 e 1000 Hz e entre (8) 1001 e 1500 Hz; ✓ (9) RMS, (10) Kurtosis, (11) Skewness, (12) Valor de Pico, (13) ER do Envelope do sinal; ✓ Amplitude da Máxima Frequência do Envelope do sinal entre (14) 0 e 500 Hz, entre (15) 501 e 1000 Hz e entre (16) 1001 e 1500 Hz.
2º	PSD_64 (64 parâmetros)	Espectro de Vibração de Aceleração com 64 pontos e frequência máxima de 625 Hz.
3º	PSD_128 (128 parâmetros)	Espectro de Vibração de Aceleração com 128 pontos e frequência máxima de 625 Hz.
4º	ENVPSD_64 (64 parâmetros)	Envelope do Espectro de Vibração de Aceleração com 64 pontos e frequência máxima de 625 Hz.
5º	ENVPSD_128 (128 parâmetros)	Envelope do Espectro de Vibração de Aceleração com 128 pontos e frequência máxima de 625 Hz.

5.3. RESULTADOS

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

5.3.1. Tipo de Perfil da Função de Pertinência

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

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

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

Um exemplo deste desempenho ordenado pode ser observado comparando os índices 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 desempenho 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 5.11. 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 5.5, que igualam as aberturas ou dispersões das funções de pertinência. Nestes testes, obtida na condição de melhor desempenho (diagnóstico com detecção e classificação (*Detecção/Classificação*)) utilizando 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 desempenhos 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, 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 (como no caso da função **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 para a estratégia de 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.

5.3.2. Influência da Dispersão f_I no desempenho do sistema fuzzy

Um outro fator que influencia o perfil da função de pertinência, é o índice de dispersão f_I , que indica a abertura da função de pertinência (apresentado no item 2.2.1 e no Apêndice C).

Para a análise da influência desta característica foi escolhido arbitrariamente um sistema fuzzy com a combinação de variações apresentadas na Tabela 5.7. Com um sistema de inferência fuzzy definido, variou-se a dispersão f_I entre 0,5 a 5,0 e foi observada a desempenho de acerto para *detecção* e *detecção/classificação* do sistema de inferência fuzzy em cada caso.

Tabela 5.7 – Características dos sistemas de inferência fuzzy utilizadas para a análise da influência da Dispersão f_I

<i>Variação do Sistema Fuzzy</i>	
Média/Amostra	Todas
Rotação	400
Amostra	Variado
Características	PSD_64
Tipo do Perfil da Função de Pertinência	Beta
Amostra/Tipo	Variado

Os resultados obtidos nesta análise de influência são apresentados na Figura 5.13. Percebe-se que tanto para **Detecção** quanto para **Classificação** existe um máximo global de desempenho. Especificamente para o exemplo da Figura 5.13, a máxima desempenho foi obtida no sistema fuzzy que utiliza os valores apresentados na Tabela 5.8.

Figura 5.13 - Influência da dispersão f_I sobre a desempenho tanto dos sistemas fuzzy de detecção quanto de classificação.

Tabela 5.8 – Tabela com máxima desempenho obtida no teste com respectivas dispersões (f_I).

	<i>Máximo Desempenho</i>	<i>Dispersão (f_I)</i>
Detecção	89,4 %	1,1
Classificação	61,6 %	1,1 a 5,0

Percebe-se que um valor baixo para a dispersão (f_I) é mais prejudicial para o desempenho de diagnóstico do que um valor alto. Neste exemplo, o ponto ótimo obtido foi de 1,1, mas pode-se afirmar que este valor ótimo vai depender do sistema fuzzy a ser testado.

Para o desempenho da classificação percebe-se que existe um máximo valor de desempenho alcançado (61,6% de acertos a partir de $f_I = 1,1$), onde um aumento de f_I não gera melhora de desempenho.

Em outros sistemas testados, foram observados comportamentos semelhantes ao apresentado na Figura 5.13.

5.3.3. Valores Característicos

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

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

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

Um exemplo deste desempenho ordenado pode ser observado comparando em conjunto os índice de *Acertos de Normais* e *Acertos de Defeitos* para um sistema fuzzy para diagnóstico de *Detecção* 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 desempenhos apresentados acima, não se pode generalizar esta ordem de desempenho (por exemplo, que o **PSD_128** sempre terá um desempenho melhor que o **Var/Todos**).

Um exemplo desta exceção foi observado quando se utilizou 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 (**PSD_64**) para 128 (**PSD_128**)). Neste caso, observou-se uma pequena queda de desempenho (respectivamente de 59.35% para 57.94% do índice de *Acertos de Tipo* e de 3.09% para 14.64% do índice de *Inexistência*).

O comportamento do desempenho utilizando os diversos grupos de características ocorre, porque todos os grupos possuem a mesma informação, porém em um grupo, esta informação está mais compacta que em outro. De certo modo, em alguns casos, uma maior

compactação permite ao sistema fuzzy ser mais robusto, sendo menos influenciado por condições não controladas.

Deve-se enfatizar que conforme se aumenta a quantidade de características de entrada do sistema fuzzy, mais lento é 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** (128 características de entrada) – 45 seg.
- **PSD_64 e ENVPSD_64** (64 características de entrada) – 15.5 seg.
- **Var/Todos** (16 características de entrada) – 2.76 seg.

5.3.4. Outras análises

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

5.3.4.1. Variação do Banco de Dados de Criação

No caso da utilização do grupo de características estatísticas (**Var/Todos**) com estratégia de detecção e classificação (**Detecção/Classificação**), não se verificou nenhuma mudança significativa devido à variação do conjunto de criação.

Porém, no caso dos outros grupos de características obtidos pelos espectros de freqüências (**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, indicando que existe uma grande influência das **condições não controladas** (por exemplo, rotação, o procedimento de montagem da bancada de teste, entre outros).

Para a estratégia de detecção (*Deteção*), percebe-se que a utilização do grupo de características estatísticas (*Var/Todos*) implica em um melhor desempenho conforme se aumenta o banco de dados de criação. Porém, ao se misturar as seqüências de banco de dados (*Amostra- Variado*), o desempenho cai a praticamente zero, de modo que o sistema sempre indicará defeito. Este comportamento não é observado para as características obtidas pelos espectros de frequência (*PSD_64, ENVPSD_64, PSD_128 e ENVPSD_128*), cujo desempenho aumenta ao se misturar as seqüências do banco de dados (*Amostra- Variado*), saindo de quase zero, 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 os grupos de características utilizados produzem um sistema de inferência pouco robusto, sendo o desempenho deste último amplamente influenciado por **condições não controladas** (por exemplo, rotação, o procedimento de montagem da bancada de teste, entre outros).

5.3.4.2. Cálculo das Médias e Desvios Padrões das Funções de Pertinência

A influência da fórmula de cálculo das médias e desvios padrões que são utilizadas para criação das funções de pertinência, é analisada apenas para sistemas que utilizam as características estatísticas (*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*.

Este melhor desempenho do (*Média/Amostra- Cada*) ocorre pois ao se fazer a média de um grupo inteiro de características (*Média/Amostra- Todas*) se desconsidera uma parcela de informação que estão mais distante do valor médio [Figura 5.14.a]. Ao se considerar que cada amostra é independente (*Média/Amostra- Cada*), obtendo sua própria média e desvio padrão [Figura 5.14.b], o conjunto que representa a condição do rolamento é muito mais abrangente, tornando o sistema mais robusto, conforme mostrado na Figura 5.14.

Figura 5.14 - Funções de pertinência referente à característica RMS para saída Normal com média e desvio padrão obtida por (a) todas as amostras e (b) para cada amostra.

O aumento tempo ao se utilizar (*Média/Amostra- Cada*) é uma outra consideração a ser observada, pois os esforços computacionais na etapa de criação e teste são muito maiores uma vez que é necessária analisar uma maior quantidade de funções de pertinências.

Verificou-se que este aumento está entre 5 e 10 vezes quando se considera o *Tempo de Teste/Amostra*.

5.3.4.3. *Detecção x Detecção/Classificação*

Utilizando-se ambas as estratégias propostas, percebeu-se que o principal problema não é identificar o mancal defeituoso, mas sim, identificar o mancal em sua condição normal. Constatou-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*** onde se alcançou um desempenho de *Acertos de Normais* superior a 80%.

Com a estratégia utilizando apenas a estratégia de detecção (***Detecção***), pode-se alcançar um maior índice de acertos em relação à ***Detecção/Classificação***, tanto de mancais normais (*Acertos de Normais*) quanto com defeitos (*Acertos de Defeitos*). Este melhor desempenho, se deve à menor complexidade do sistema fuzzy para a estratégia de ***Detecção***, de modo que a tarefa de diagnóstico não possui grande influência condições não controladas. 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 separa o caso normal de um defeituoso, e o segundo classifica o tipo de defeito. Esta proposta não foi implementada neste trabalho.

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

Outra análise interessante a ser feito 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 (**Amstras-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 PSD₁₂₈ (**PSD₁₂₈**), 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- ##**).

Os melhores resultados obtidos com os sistemas de inferência fuzzy obtidos com a metodologia apresentada neste capítulo são os seguintes:

- **Detecção** – 97.62% (*Acertos de Normais*) e 76.49% (*Acertos de Defeitos*).

- **Detecção/Classificação** – 31.75% (*Acertos de Normais*), 89.59% (*Acertos de Defeitos (S/N)*) e 68.08% (*Acertos de Tipo*).

Para comparação, o melhor resultado obtido com o alarme estatístico obtido no Capítulo 4 foi:

- **Alarme Estatístico** – 100% (*Acertos de Normais*) e 38.69% (*Acertos de Defeitos*).

Comparando o desempenho do alarme estatístico e dos sistemas de inferência fuzzy, fica clara a vantagem de se utilizar o sistema de inferência fuzzy, na detecção de defeito com o diagnóstico de **Detecção**, onde se obtém um melhor desempenho que o alarme estatístico, e na classificação de defeito com a estratégia **Detecção/Classificação**, que é uma função que o alarme estatístico não possui.

5.3.4.4. *Influência do Valor Limiar α em um Sistema para Detecção*

O sistema de inferência fuzzy para a estratégia **Detecção** é composto apenas por funções de pertinência de entrada relacionada a rolamentos normais, sendo que, quando nenhuma função de pertinência é ativada pelos valores de entrada do teste (ou a pertinência obtida é inferior ao valor limiar α), a entrada é considerada como sendo pertencente a um rolamento com defeito.

Foram realizados diversos testes utilizando diversas combinações de variações apresentadas no item 5.2.2 para verificar a influência de um parâmetro do sistema fuzzy que possui grande influência no desempenho, o valor limiar α .

Vale ressaltar que neste tipo de sistema de inferência fuzzy, não existe a classificação do tipo de defeito (furado, riscado, corrosão,...), mas ele apenas diagnostica se o rolamento analisado é normal (ou sem defeito) ou não.

Convém observar que a complexidade deste tipo de sistema de inferência fuzzy é muito inferior aos sistemas de inferência fuzzy utilizados para classificar os tipos de defeitos.

Um exemplo do comportamento da desempenho de acertos de detecção em função o valor limiar α é apresentado na Figura 5.15. Neste gráfico, foram utilizadas as seguintes definições:

$$Normal = \frac{Número\ de\ Acertos\ de\ Normais}{Número\ Total\ de\ Testes\ de\ Normais} [\%] \quad \textbf{Equação 5.3}$$

$$Defeito = \frac{Número\ de\ Acertos\ de\ Defeitos}{Número\ Total\ de\ Testes\ de\ Defeitos} [\%] \quad \textbf{Equação 5.4}$$

$$Global = \frac{1}{2}(Defeito + Normal) [\%] \quad \textbf{Equação 5.5}$$

Figura 5.15 – Exemplo da influência do valor limiar α sobre a desempenho de detecção de diferentes banco de dados (de NORMAIS, de DEFEITO e GLOBAL) para a estratégia de *Deteção*.

A partir deste gráfico, percebe-se que ele possui um valor ótimo entre 0.1 e 0.2. Percebe-se também, que quando se utiliza valor muito alto, o sistema fuzzy tende a diagnosticar todos os dados como sendo relacionados a rolamentos com defeito (independente de ter defeito ou não), inviabilizando o sistema fuzzy e tornando-o muito próximo a um comportamento de sistema de inferência baseada em lógica clássica.

Apesar disto, deve-se lembrar que existem outros sistemas fuzzy que obtiveram pontos ótimos de valor limiar α diferentes a este exemplo, porém o comportamento das curvas é similar para todos os sistemas fuzzy testados.

Um resumo dos resultados obtidos com todas as combinações de variações apresentados no item 5.2.2 é apresentada na Figura 5.16, sendo que a máxima desempenho obtida foi de 97,3 % de acertos de detecção.

Interpretando a Figura 5.16, percebe-se que entre os sistemas fuzzy testados existe maior quantidade de sistema fuzzy próxima à mínima desempenho que de máxima (devido ao fato da desempenho média estar mais próximo ao desempenho mínima). Este comportamento é agravado quanto maior for o valor limiar α . A melhor distribuição de resultados foi obtida para um valor limiar $\alpha = 1,0$.

Figura 5.16– Desempenho de detecção para o SISTEMA FUZZY NORMAL influenciada pelo o valor limiar α .

Resumindo os resultados, percebeu-se que os melhores desempenhos foram obtidos utilizando um valor limiar α entre 0.1 e 0.2.

5.3.5. Melhor Desempenho

Com diversas combinações de sistemas de inferência fuzzy apresentadas no item 5.2.2, obteve-se uma variedade de resultados representados na Figura 5.17. Estes resultados são utilizados para comparar com os outros sistemas de diagnóstico criados neste trabalho.

Percebe-se que, apesar de ser alcançado um desempenho de acerto superior a 94% tanto para detecção quanto para detecção/classificação, a desempenho média de todos os sistemas de inferência fuzzy testadas é baixa, com alguns sistemas tendo desempenho de 0.0%.

Figura 5.17 – Desempenho dos sistemas fuzzy testados

5.4. DISCUSSÕES DOS RESULTADOS

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 o desempenho 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 que deve ser considerada é o esforço computacional necessário para implantar o sistema fuzzy. Muitas vezes, uma melhora de desempenho 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 em condição normal, ignorando os outros padrões que compõe o banco de dados de defeitos, permite um aumento de desempenho de acertos e queda no tempo de criação e de teste. Portanto, é proposto para trabalhos futuros um outro layout de sistema de diagnóstico, que utiliza um

sistema de inferência fuzzy para a etapa da detecção, e nos casos diagnosticados como sendo com defeito, a classificação do tipo de defeito é realizada por um outro sistema de inferência fuzzy.

Além disso, conforme pôde ser notado através das análises realizadas percebe-se que diversos fatores influenciam a desempenho dos sistemas de inferência fuzzy. Entre eles, foram estudados o valor limiar α e dispersão f_l .

Com relação à metodologia de criação de sistema de inferência fuzzy proposta neste trabalho, foram obtidos resultados consideravelmente bons (melhor desempenho de acerto de 97% para *detecção*). Esta metodologia proporcionou um ganho no tempo para criação do sistema de inferência fuzzy.

Todos os testes foram realizados utilizando um único banco de dados (composto de sinais de vibração de defeitos de rolamentos), porém, o conceito utilizado neste trabalho pode ser aplicado a qualquer outro tipo de banco de dados.

6. FUZZY C-MEANS

O algoritmo FCM permite que se obtenha as funções de pertinência automaticamente, porém, ele não fornece automaticamente a regra de inferência que relaciona estas funções de pertinência a uma resposta esperada.

Neste capítulo é proposto um procedimento utilizado após o algoritmo do FCM que permite utilizar o conhecimento da relação entre os dados de treinamento e os seus respectivos alvos para encontrar as regras de inferência automaticamente.

6.1. *OBTENÇÃO DAS REGRAS DE INFERÊNCIA AUTOMATICAMENTE*

O objetivo do FCM é basicamente obter um determinado número de *clusters* a partir de um conjunto de dados. Normalmente, na criação dos *clusters*, utiliza-se um *cluster* para cada grupo que se queira identificar.

Porém, existem casos onde se deseja encontrar relacionar diversos conjuntos diferentes entre si (considerando um determinado conjunto de características descritivas), em um único grupo. Para estes casos, é proposto neste trabalho um algoritmo que permite utilizar o algoritmo do FCM.

Um outro modo de se interpretar este algoritmo a ser apresentado, é que ele permite relacionar diversas funções de pertinências obtidas através do algoritmo FCM com um determinado grupo, criando uma regra de inferência mais complexa do que a utilizada normalmente no FCM.

O procedimento inicia definindo o número de *clusters* c . Considerando que o banco de dados de treinamento possui g conjuntos ou grupos definidos (por exemplo, rolamentos

normais, rolamentos furados, rolamentos corroídos,...), é claro a necessidade de definir um número de *cluster* c maior que g . Neste trabalho foi escolhido utilizar um valor de c proporcional a g . Portanto, a escolha deste parâmetro depende somente do conhecimento do usuário.

Apenas para *fins ilustrativos*, considere um exemplo de banco de dados hipotético. Este exemplo é muito mais simples que um banco de dados real, mas permite uma melhor compreensão dos passos utilizados na metodologia.

Neste exemplo, separou-se um conjunto de 80 dados divididos em dois grupos ou *condições a ser identificadas* (Grupo G1 e Grupo G2). Para cada uma delas, como se pode observar pela figura, existem duas *condições experimentais* (Condição C1 e Condição C2).

Para cada elemento destes grupos são obtidos dois valores de *Características* (1 e 2). Para facilitar a visualização destes grupos foi feita a representação da Figura 6.1. O objetivo neste exemplo é criar um sistema de diagnóstico que determine a *condição a ser identificado* (**G1** ou **G2**) através dos valores das *Características* (1 e 2).

Neste exemplo, existem dois grupos a serem identificados, porém, como podem ser observados na Figura 6.1, os dados podem ser separados em quatro *clusters* distintos.

Figura 6.1 – Mapeamento dos dados de exemplo para treinamento

O parâmetro m , expoente fuzzy, é normalmente escolhido empiricamente, neste exemplo foi definido arbitrariamente um valor de 2.0. Uma vez que como o exemplo é muito simples, este parâmetro não possui grande influência.

Utilizando o algoritmo FCM com um número de *cluster* igual a dois, foram obtidos as funções de pertinência da Figura 6.2.

(a)

(b)

**Figura 6.2 – Funções de Pertinência para o banco de dados de exemplo utilizando $c = 2$,
(a) Grupo 1 e (b) Grupo 2.**

Ambas as funções de pertinências dos *clusters* obtidos englobaram dados dos dois grupos a serem identificar, resultando em um erro de identificação.

Portanto, uma melhor escolha, confirmada visualmente na Figura 6.1, é utilizar quatro *clusters*. Ao se aplicar o FCM encontrou-se as funções de pertinência da Figura 6.4 para cada combinação de *grupo* e *condição experimental* (G1-C1, G1-C2, G2-C1 e G2-C2) definido na Figura 6.1.

Na Figura 6.5 são apresentados os graus de pertinência de todas as 80 amostras que compõe o banco de dados para cada um dos *clusters*. Nesta figura, utilizou-se a seguinte

ordem, as primeiras 40 amostras pertencem ao grupo 1, enquanto as outras pertencem ao grupo 2.

(a)

(b)

Figura 6.3 - – Funções de Pertinência para o banco de dados de exemplo utilizando $c = 4$, (a) *Cluster 1* e (b) *Cluster 2*.

Figura 6.4 - – Funções de Pertinência para o banco de dados de exemplo utilizando $c = 4$, (c) *Cluster 3* e (d) *Cluster 4*.

Após se alcançar os diversos *clusters* resta definir qual deles está relacionada com os grupos a serem identificados. É sobre este problema que o procedimento a ser apresentado a seguir se aplicará.

Figura 6.5 – Graus de pertinência de cada uma das 80 amostras do banco de dados de exemplo relacionadas a um determinado *cluster*.

Conhecendo a relação que existe entre cada amostra e o grupo a qual ele pertence, tem-se que os graus de pertinências ideais para cada amostra são mostrados na Figura 6.6, ou seja, valor 1 para o grupo ao qual pertence e 0 para o outro. Este vetor de graus de pertinência para cada grupo é utilizado para relacionar um *cluster* ao grupo mais semelhante.

Figura 6.6 – Graus de pertinência ideais para o banco de dados de exemplo.

Definindo g como sendo o número de grupos descritos no banco de dados, N como o número total de amostra no banco de dados, x_j como sendo um objeto do banco de dados e $\mu(ideal)_{k,j}$ como o grau de pertinência ideal deste objeto a um grupo G_k , tem-se para estes graus de pertinências ideais as seguintes equações:

$$\mu(ideal)_{k,j} = \begin{cases} 1 & , x_j \in G_k \\ 0 & , x_j \notin G_k \end{cases} \quad \forall j = 1, \dots, N \quad e \quad \forall k = 1, \dots, g \quad \textbf{Equação 6.1}$$

Deve-se lembrar que os graus de pertinência da Figura 6.5 são representados pela matriz U de graus de pertinência $\mu_{i,j}$, sendo j o índice do *cluster*.

Para se determinar a qual grupo G_k um determinado *cluster* C_i pertence, propõe-se a seguinte comparação:

$$indice \left\{ \max_{k=1, \dots, g} \left[\sum_{j=1}^N \mu_{i,j} \cdot \mu_{k,j} \right] \right\} \quad \forall i = 1, \dots, c \quad \textbf{Equação 6.2}$$

O índice k obtido na equação acima representará o grupo ao qual o *cluster* C_i pertence. Esta operação serve para verificar a representatividade do *cluster* no grupo em estudo.

Uma vez que os graus de pertinências sofrem a restrição da Equação 2.9, definiu-se como sendo o grau de pertinência $\mu_{k,j}$ de um objeto x_j a um grupo G_k :

$$\mu_{k,j} = \sum_i \mu_{i,j} \quad \forall i / \text{indice} \left\{ \max_{k=1,\dots,g} \left[\sum_{j=1}^N \mu_{i,j} \cdot \mu_{k,j} \right] \right\} = k \quad \text{Equação 6.3}$$

Portanto, as restrições apresentadas nas Equação 2.9 e Equação 2.10 são mantidas, já que se somaram os graus de pertinência dos *clusters* relacionados a um determinado grupo. Esta operação pode ser vista na Figura 6.7 (em comparação à Figura 6.5), onde o grupo 1 é representado pelos *clusters* 1 e 2, enquanto o grupo 2 pelos *cluster* 3 e 4, resultando na soma de seus respectivos graus de pertinência.

Como se define função de pertinência como sendo a representação dos graus de pertinência de um componente do universo de discurso em relação a um conjunto, as funções de pertinências relacionadas a cada grupo pode ser obtida de modo análogo aos graus de pertinências. As funções de pertinências finais para o exemplo proposto são mostradas na Figura 6.8.

Figura 6.7 – Graus de pertinência de cada uma das 80 amostras do banco de dados de exemplo relacionadas a um determinado grupo.

(a)

(b)

Figura 6.8 – Funções de Pertinência para o banco de dados de exemplo utilizando $c = 4$, e posterior processo de adaptação, (a) Grupo 1 e (b) Grupo 2.

Uma grande vantagem do FCM é ser um algoritmo “não-supervisionado”, ou seja, ele é um algoritmo que não necessita que os padrões do banco de dados de criação estejam relacionados a um padrão alvo. Porém, na maioria dos problemas de reconhecimento de padrão existe este tipo de informação, e ele deve ser utilizado. Um modo de se ver o procedimento proposto neste trabalho, é que ao mesclá-lo ao algoritmo do FCM, obtém-se um

algoritmo “supervisionado”, ou seja, que considera a relação entre padrão de treinamento e seus respectivos alvos.

Outra modificação proposta aqui é, uma vez que já existe um prévio conhecimento dos grupos do banco de dados, os centros b_i iniciais, necessários no algoritmo, são inicializados como sendo elementos deste banco de dados ou vetores de características médios que representam um grupo que se quer obter o *cluster*. No exemplo apresentado acima, os centros b_i iniciais poderiam ser, por exemplo, $\{1,1\}$, $\{2,2\}$, $\{4,3\}$ e $\{4,1\}$. Esta pequena modificação permite aumentar a velocidade de convergência do algoritmo se comparada com a escolha aleatória destes centros iniciais.

6.2. DISCUSSÕES DA TEORIA

O algoritmo FCM é uma metodologia para obtenção do sistema de inferência fuzzy que descreve um problema, quando não existem informações descritivas sobre ele. Portanto, existem diversas particularidades com relação ao FCM e o sistema de inferência fuzzy obtido com regras descritivas lógicas, entre eles, podemos apresentar a função de pertinência fuzzy.

Como visto no item 2.4.3, as funções de pertinência são descritas pela equação abaixo.

$$\mu_{i,j} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{i,j}}{d_{k,j}} \right)^{\frac{2}{m-1}}} \quad \forall i = 1, \dots, c \quad e \quad \forall j = 1, \dots, N \quad \textbf{Equação 6.4}$$

Por esta equação verifica-se que diferente das outras funções de pertinências comumente utilizadas para o sistema de inferência fuzzy (mostrado no Apêndice C), esta depende não apenas de seus próprios dados, mas também das outras funções descritas no universo de discurso. Isto pode ser visto, por exemplo, quando se utiliza um perfil de função de pertinência gaussiana, onde a função é descrita por um valor médio e uma abertura ou

dispersão. Portanto, ela independe das outras funções descritas no universo de discurso, diferente da apresentada acima.

Através da equação apresentada acima, percebe-se também que o grau de pertinência não é descrito explicitamente pelas características de entrada, mas sim pela distância destes aos vetores protótipos b_i . Rigorosamente, pode-se dizer que os valores característicos de entrada do sistema fuzzy são estas distâncias, e não as características de entrada definidas previamente. Isto implica em uma redefinição da complexidade do sistema fuzzy, de modo que, diferente dos sistemas de inferência fuzzy obtidos da metodologia apresentada no Capítulo 5, onde a complexidade era função do número de características de entrada, no FCM, a complexidade é uma função direta do número de *clusters* ou funções de pertinências descritas no sistema fuzzy.

Outra discussão interessante é a interpretação do procedimento de adaptação (ou método proposto para obter a regra de inferência). Considerando que cada *cluster* obtido pelo algoritmo do FCM representa uma função de pertinência (p. e. $\mu_A, \mu_B, \mu_C, \dots$), o processo de se somar graus de inferências apresentado na Figura 6.7 e na Figura 6.8 é equivalente ao operador **OU** definido como *Bounded Sum* e apresentada no item 2.2.4.

Portanto, utilizando esta definição de operador, uma descrição da regra de inferência obtida pelo processo apresentado acima, para o FCM é:

SE $\{[X] \text{ é } [N(k,1)] \text{ OU } [X] \text{ é } [N(k,2)] \text{ OU } \dots \text{ OU } [X] \text{ é } [N(k,p(k))]\}$ **ENTÃO** $[Y(k)] \text{ é } [G_k]$
SENÃO ...

SE $\{[X] \text{ é } [N(k+1,1)] \text{ OU } [X] \text{ é } [N(k+1,2)] \text{ OU } \dots \text{ OU } [X] \text{ é } [N(i+1,p(k+1))]\}$ **ENTÃO**
 $[Y(k+1)] \text{ é } [G_{k+1}]$ **SENÃO** ...

...

Figura 6.9 – Regra de inferência padrão utilizado pelo algoritmo FCM

onde G_k é cada grupo ou *condição a ser identificado*, X o vetor de valores característico de entrada, $N(k,i)$ as funções de pertinência dos *clusters* relacionados a um grupo G_k , e $Y(k)$ a saída, e:

$k= 1...g$ (número de grupos ou *condições a serem identificadas*);

$i= 1...p(k)$ (número de *clusters* relacionados a um grupo ou *condição a ser identificada*)

Assim, são definidas g (número de grupos ou condições a serem identificadas) regras de inferências.

6.3. TESTES

O algoritmo FCM apresentado neste capítulo para criação de sistema de inferência fuzzy necessita de poucos parâmetros para ser utilizado. Estes parâmetros podem ser basicamente divididos nas categorias apresentadas neste item. Nos testes realizados foram estudadas as influências destes parâmetros sobre o desempenho de acertos destes sistemas fuzzy.

6.3.1. Complexidade do Banco de Dados de Criação

Este é um dos principais parâmetros de influência em qualquer sistema inteligente. Nos testes realizados foi definida uma menor quantidades de estratégias de diagnóstico (ou complexidades do banco de dados) em relação ao utilizado para os sistemas de inferência fuzzy, uma vez que o algoritmo é iterativo podendo não alcançar um mínimo global. Foram

utilizadas as seguintes variações de complexidade do banco de dados apresentadas na Tabela 6.1.

Tabela 6.1 – Tabela com o resumo das variações de complexidades utilizadas nos testes deste algoritmo de criação de sistemas fuzzy.

<i>Divisão do Banco de Dados</i>	
Rotação	## (com todas as rotações) 400 (apenas com 400 rpm) 600 (apenas com 600 rpm) 800 (apenas com 800 rpm) 1000 (apenas com 1000 rpm) 1200 (apenas com 1200 rpm) 1400 (apenas com 1400 rpm)
Carga	## (com todas as cargas) 3 (apenas com 600 N) 2 (apenas com 400 N) 3 (apenas com 200 N)
Defeitos	Todos os defeitos Apenas o furo (pista interna e externa)

Em todas as análises realizadas, foram feitos testes considerando todas as rotações e considerando apenas uma única rotação. Com relação às outras divisões possíveis, carga e defeitos, quando não é dito quais as divisões utilizadas, considerar que foi analisado um banco de dados utilizando todas as cargas e todos os defeitos.

Uma outra particularidade com relação a este banco de dados são os parâmetros de análise de vibração utilizados para a criação do sistema fuzzy. Foram utilizados 5 grupos de parâmetros descritos na Tabela 6.2.

Tabela 6.2 – Resumo dos grupos de parâmetros de análise de vibração utilizados para testar o algoritmo de FCM.

<i>Grupo</i>	<i>Características</i>	
1º	OUTROS	RMS, Kurtosis, ER do sinal;
2º	ENVPSD_64	Envelope do Espectro de Vibração de Aceleração com 65 pontos e frequência máxima de 1250 Hz
3º	ENVPSD_64(1 a 21)	Idem à ENVPSD_64 (foram utilizados apenas 21 pontos do espectro, do 1º ao 21º ponto).
4º	ENVPSD_64(22 a 43)	Idem à ENVPSD_64 (foram utilizados apenas 21 pontos do espectro, do 22º ao 43º ponto).
5º	ENVPSD_64(44 a 65)	Idem à ENVPSD_64 (foram utilizados apenas 22 pontos do espectro, do 44º ao 65º ponto).

Todos estes grupos de parâmetros foram utilizados em cada análise realizada.

6.3.2. Expoente Fuzzy (m)

Em todas as análises onde este parâmetro não era o foco de comparação, foi utilizando o valor de $m = 2,0$. No caso da análise da influência deste parâmetro, ele foi variado entre 1,1 e 4,0.

6.3.3. Número de Centros (ou *clusters*)

Nos casos onde este parâmetro não é analisado, foi utilizado um número de centro $c = 3$ para cada condição a ser diferenciado. Por exemplo, onde se queiram diferenciar todos os defeitos (NORMAL, FURO INTERNO E EXTERNO, CORROSÃO, ...), foi utilizado $c = 27$.

Para a análise da influência deste parâmetro, foram utilizados ($c = 27, 54, 81$).

6.3.4. Critério de Parada

O critério de parada utilizado durante o treinamento (ou seja, a máxima variação dos graus de pertinência de uma iteração à outra), em todos os testes, possui um valor de $CP = 0,01$. Este valor foi determinado por tentativa e erro.

6.4. RESULTADOS

6.4.1. Influência do Expoente Fuzzy (m)

Após diversos testes, com diversos tipos de banco de dados de entradas (utilizando as variações de rotação, carga, defeitos a serem diferenciados e parâmetros de análise de vibração apresentados na Tabela 6.1 e na Tabela 6.2), foram observados diversos comportamentos diferentes de desempenhos em função do expoente fuzzy (m) (considerando m entre 1,1 e 4,0).

Pela análise destes comportamentos, percebeu-se que não existe um comportamento padrão onde se pode determinar o expoente fuzzy (m) ótimo. Estas características dificultam a obtenção dos valores ótimos, para cada combinação de variações no algoritmo de criação de sistema fuzzy.

Para uma análise mais apurada da influência deste parâmetro, foram escolhidos três expoentes fuzzy ($m = 1.2, 2.0$ e 3.0). Um resumo de seus desempenhos é apresentado abaixo.

Figura 6.10 – Desempenho de acerto de classificação dos sistemas FCM influenciados pelos diversos expoentes fuzzy.

Figura 6.11 - Desempenho de acerto de detecção dos sistemas FCM influenciados pelos diversos expoentes fuzzy.

Figura 6.12 – Influência do expoente fuzzy sobre o número de iterações no treinamento.

A maior influência do expoente fuzzy observada é sobre o número de iterações de treinamento (relacionado diretamente ao tempo de treinamento) que é uma função crescente com o expoente fuzzy (m).

Com relação ao desempenho de acerto na detecção e classificação, nada pode ser dito, sendo que não foi encontrada nenhuma relação entre o expoente fuzzy (m) e a desempenho do sistema FCM.

6.4.2. Influência do Número de Centros (ou *clusters*)

Para esta análise, após diversos testes, com diversos tipos de banco de dados de entradas (utilizando as variações de rotação, carga, defeitos a serem diferenciados e parâmetros de análise de vibração apresentados na Tabela 6.1 e na Tabela 6.2), foram obtidos os diversos desempenhos apresentados abaixo. Neste caso, foram analisados três números de centros (c) (27, 54 e 81 centros).

Figura 6.13 – Desempenho de acerto de classificação dos sistemas FCM influenciados pelo número de centros (ou *clusters*).

Figura 6.14 – Desempenho de acerto de detecção dos sistemas FCM influenciados pelo número de centros (ou *clusters*).

Figura 6.15 – Influência do número de centros sobre o número de iterações no treinamento.

Do mesmo modo que o expoente fuzzy (m), não foi observado, através dos testes, uma grande influência do número de centros sobre o desempenho de acertos na detecção e classificação. O que foi observado, é que uma menor quantidade de centro ($c = 27$) permitiu um comportamento mais estável dos resultados obtidos, ou seja, menor variação quando se modificou os outros fatores, conforme pode ser visto na Figura 6.14.

Outro item interessante a ser observado é com relação ao número de iterações, pois foi observada uma maior necessidade de iterações para um número de centros intermediário ($c = 54$).

6.4.3. Complexidade do Banco de Dados

Para a análise da influência da complexidade do banco de dados de criação sobre o desempenho do sistema fuzzy, foram realizados diversos testes com diversas combinações das variações apresentadas no item 6.3.

Nas figuras abaixo é apresentado um resumo dos resultados obtidos, considerando apenas os defeitos de furo e a condição normal, consideração de todos às cargas juntas ou individualmente, e a variação do número de centros (c).

Figura 6.16 – Desempenho de acerto de classificação dos sistemas FCM influenciados pelo número de centros (ou *clusters*) e pela complexidade do banco de dados, considerando uma única carga ou todas (diferenciando apenas a condição normal do defeito furo e variando todas as outras condições de rotação e parâmetros de análise de vibração apresentados na Tabela 6.1 e na Tabela 6.2).

Figura 6.17 – Desempenho de acerto de detecção dos sistemas FCM influenciados pelo número de centros (ou *clusters*) e pela complexidade do banco de dados, considerando uma única carga ou todas (nas condições apresentadas na Figura 6.16).

Figura 6.18 – Influência do número de centros (ou *clusters*) e da complexidade do banco de dados, considerando uma única carga ou todas sobre o número de iterações no treinamento (nas condições apresentadas na Figura 6.16).

Através destes gráficos observa-se uma grande influência da variação de complexidade do banco de dados considerada. Em alguns casos, alcançou-se desempenho de acertos de 100%, tanto para a detecção quanto para a classificação, que não é observado quando são consideradas todas as condições de cargas em conjunto.

Para enfatizar esta idéia, foram realizados outros testes onde se variaram os grupos de defeitos a serem *detectados/classificados* com as mesmas combinações de variações utilizadas anteriormente. O resumo dos resultados obtidos é apresentado na Figura 6.19, Figura 6.20 e Figura 6.21.

Figura 6.19 – Desempenho de acerto de classificação dos sistemas FCM influenciados pela complexidade do banco de dados, considerando os defeitos que compõe o banco de dados.

Figura 6.20 – Desempenho de acerto de detecção dos sistemas FCM influenciados pela complexidade do banco de dados, considerando os defeitos que compõe o banco de dados.

Figura 6.21 – Número de iterações no treinamento dos sistemas FCM influenciado pela complexidade do banco de dados, considerando os defeitos que compõe o banco de dados.

Pelos resultados apresentados acima, fica mais claro a influência da complexidade do banco de dados sobre o comportamento do sistema fuzzy. A queda da complexidade do banco de dados (ou seja, ao se passar de 09 grupos de defeitos para 03 (NORMAL, FURO PISTA INTERNA E FURO PISTA EXTERNA)) resultou no aumento do desempenho de acertos de detecção e classificação além de necessitar de menor iteração para o treinamento.

6.4.4. Parâmetros de Análise de Vibração

Uma outra variável de grande influência no desempenho do sistema de diagnóstico são os parâmetros de análise de vibração utilizados como entrada para o sistema fuzzy criado pelo algoritmo FCM.

Para o estudo desta variável, foi considerado o diagnóstico de todos os defeitos e com os fatores c e m constantes (respectivamente, $c = 27$ e $m = 2,0$), podendo em alguns casos observar desempenhos inferiores aos observados anteriormente. Nesta análise, foram consideradas as rotações individuais e todas as cargas. O resumo dos resultados obtidos são apresentados na Figura 6.22, Figura 6.23 e Figura 6.24.

Figura 6.22 - Desempenho de acerto de classificação dos sistemas FCM influenciados pelos parâmetros de entrada utilizados (considerando todos os defeitos).

Figura 6.23 - Desempenho de acerto de detecção dos sistemas FCM influenciados pelos parâmetros de entrada utilizados (considerando todos os defeitos).

Figura 6.24 - Número de iterações no treinamento dos sistemas FCM influenciado pelos parâmetros de entrada utilizados (considerando todos os defeitos).

Como pode ser percebido na Figura 6.22, existe uma grande influência dos parâmetros de entrada utilizados sobre o desempenho do sistema FCM. O melhor desempenho de classificação foi obtido utilizando o grupo **OUTROS** (constituído por valor de RMS, Kurtosis e ER do sinal), que representa o grupo mais simples de entradas utilizado. Este fato enfatiza ainda mais a influência da complexidade do banco de dados sobre o desempenho do sistema FCM, uma vez que o banco de dados mais simples (composto da menor quantidade de parâmetros) obteve melhor desempenho.

No caso do desempenho de detecção (apresentada na Figura 6.23) observa-se o mesmo comportamento, principalmente quando comparado o valor médio obtido pelo sistema FCM criado com os parâmetros do grupo **OUTROS**.

Porém, este melhor desempenho tem um custo, pois o número de iterações (ou seja, o tempo de processamento) necessárias para terminar o algoritmo FCM final é maior para os sistemas fuzzy criados a partir do grupo **OUTROS** do que a partir dos outros grupos.

6.4.5. Melhor Desempenho

Os melhores desempenhos de acertos de detecção e classificação são, respectivamente, 90,7 e 51,1% (desconsiderando os resultados com uma menor complexidade: consideração de apenas uma carga e de apenas 3 grupos de defeitos como os apresentados na Figura 6.19 e na Figura 6.20).

Tabela 6.3 – Tabela com as estratégias que obtiveram a melhor desempenho de acerto de detecção e classificação utilizando o algoritmo FCM.

<i>Variação do Sistema Fuzzy obtido através do FCM</i>	<i>Detecção</i>	<i>Classificação</i>
Grupo	OUTROS	OUTROS
Rotação	1000	1200
Carga	Todas	Todas
Defeitos	Todos	Todos
No. de Centros	27	27
Critério de Parada (CP)	0,01	0,01
Expoente Fuzzy (m)	1,2	1,2
Desempenho de Acertos	90,7 %	51,1 %

6.5. DISCUSSÕES DOS RESULTADOS

Pelas análises realizadas neste trabalho com relação ao algoritmo do FCM, percebe-se que o variável de maior influência sobre o desempenho do sistema fuzzy criado através do algoritmo FCM é o grupo de parâmetros de análise de vibração utilizados como entrada do sistema fuzzy. A escolha deste grupo de parâmetros está ligada diretamente com a complexidade do banco de dados a ser treinado. Esta influência abrange não só o número de

iterações (que é diretamente relacionado ao tempo de treinamento), mas também às desempenhos de acertos de detecção e classificação.

Além disso, como o comportamento deste algoritmo é iterativo e apresenta muitos máximos locais, não existe a garantia que nos testes realizados neste trabalho foram alcançados os máximos globais. Para esta análise seria necessário o estudo dos critérios de parada para observar a influência deste sobre o sistema fuzzy.

Do mesmo modo que no algoritmo de criação automática do sistema de inferência fuzzy, não foi possível determinar um conjunto de fatores otimizados (por exemplo, expoente fuzzy m ótimo ou número de *clusters* c ótimo) ou algoritmos para alcançá-los. A obtenção destes valores ótimos seria possível apenas após uma exaustiva varredura de todos os parâmetros em cada caso específico.

7. CONCLUSÃO

Neste trabalho foram apresentadas três metodologias para automatizar a detecção (e em alguns casos, a classificação) de defeitos em rolamento através de sinais de vibrações, o alarme estatístico, o sistema de inferência fuzzy e o Fuzzy C-Means.

Foi apresentado um resumo da metodologia utilizada em cada método, e também foram propostas algumas modificações para aumentar a eficiência da utilização destes métodos. Esta eficiência é baseada na automatização para criação dos critérios de detecção e classificação (alarmes e sistemas fuzzy) de defeitos em rolamentos.

Para o sistema de inferência fuzzy foi feito um programa de criação de sistema fuzzy utilizando esta metodologia, com grande preocupação com a interface gráfica com o usuário e sua flexibilidade de utilização. 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 são utilizadas como entrada quanto dos parâmetros do sistema fuzzy.

Em relação ao método do Fuzzy C-Means (FCM), foi apresentado o algoritmo FCM para obter automaticamente as funções de pertinências. Em complemento a este, foi proposto um outro algoritmo que, a partir destas funções de pertinências obtidas, possibilita encontrar a regra de inferência que relaciona estas funções de pertinência ao grupo que se quer identificar.

Em complemento a isto, foram realizados diversos testes e análises para avaliar a influência de diversos parâmetros sobre o desempenho destas duas metodologias fuzzy.

Através destas análises, verificou-se que o parâmetro de maior relevância para o desempenho do sistema de diagnóstico (qualquer que seja) é o tipo de parâmetro característico obtido dos sinais experimentais que são usados como entrada para o diagnóstico.

Não existe em qualquer das metodologias apresentadas neste trabalho, um grupo otimizado de parâmetros para ser utilizado genericamente. Um método para se obter um sistema fuzzy com parâmetros otimizados é a varredura de todas as variações possíveis considerando caso a caso.

O máximo desempenho obtido, para cada metodologia, é apresentado na Tabela 7.1. Além das metodologias apresentadas neste trabalho, é realizada uma comparação com a desempenho de redes neurais (MLP e PNN, apresentadas no item 1.2.5) ⁴¹ que utilizaram o mesmo banco de dados deste trabalho.

Tabela 7.1 – Resumo das máximas desempenho obtidas com cada metodologia

<i>Metodologia</i>	<i>Detecção</i>	<i>Classificação</i>
Redes Neurais (MLP ou PNN) ⁴¹	100 %	100 %
Alarme Estatístico	76,0 %	-
Sistema de Inferência Fuzzy	97,3 %	94,7 %
Fuzzy C-Means	90,7 %	51,1 %

Nestes testes, o melhor resultado para detecção e classificação foi obtido através da metodologia para automatizar o sistema de inferência fuzzy. Apesar do desempenho deste sistema fuzzy ser inferior aos obtidos pelas redes neurais, ele apresenta diversas outras vantagens, como ser um modelo aberto ajustável (ao contrário da rede neural que é um modelo do tipo *caixa preta*) e também permitir que o conhecimento heurístico seja adicionado ao sistema de diagnóstico fuzzy após este ser criado.

A principal vantagem da metodologia do sistema fuzzy apresentada neste trabalho é a automatização de sua criação, permitindo uma maior eficiência em seu desenvolvimento.

Com relação ao alarme estatístico, sua utilização é bastante limitada, principalmente por ele ser um método que utiliza apenas um parâmetro escalar de análise de vibração para diagnóstico. Outra limitação é que ele só faz a detecção da falha e não sua classificação, necessitando de uma análise mais aprofundada, por um especialista, para classificar o tipo de falha ocorrida.

O Fuzzy C-Means é um algoritmo iterativo e, portanto, existe uma grande relação entre o esforço computacional e desempenho de diagnóstico com a complexidade do banco de dados a ser analisado. Esta relação limita o grau de complexidade do diagnóstico que se quer realizar, restringindo em demasia a sua aplicação, devendo sua escolha ser analisado com maior critério.

Percebeu-se em todas as metodologias 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 desempenho de acertos e queda no tempo de criação e de teste. Portanto, é proposto para trabalhos futuros um outro layout de sistema de diagnóstico, que separam as etapas de detecção e classificação em dois diagnósticos distintos.

Uma outra proposta para trabalhos futuros é a utilização de uma das características do sistema fuzzy (tanto do sistema de inferência fuzzy quanto do algoritmo Fuzzy C-Means), que seria a utilização dos dados analíticos (utilizados neste trabalho) em conjunto com informações heurísticas a serem agregadas.

8. BIBLIOGRAFIA

1. 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.
2. 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.
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. BILLAUDEL, P.; DEVILLEZ, A.; LECOLIER, G. V.. *Desempenho evaluation of fuzzy classification methods designed for real time application. International Journal of Approximate Reasoning*, v. 20, p. 1-20, 1999.
7. CHEN, L.-H.; KAO, C.; KUO, S.; WANG, T.-Y.; JANG, Y.-C.. *Productivity Diagnosis via Fuzzy Clustering and Classification: An Application to Machinery Industry. International Journal Management Science*, v. 20, n. 3, p. 309-319, 1996.
8. CHEN, M.-S.; WANG, S.-W.. *Fuzzy clustering analysis for optimizing fuzzy membership functions. Fuzzy Sets and Systems*, v. 103, p. 239-254, 1999.
9. CHENG, T. W.; GOLDFOG, D. B.; HALL, L. O.. *Fast fuzzy clustering. Fuzzy Sets and Systems*, v. 93, p. 49-56, 1998.
10. COX, E.. *The Fuzzy Systems Handbook*. Ed. AP Professional, 615 p., 1994.

11. 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.
12. FAG. *Catálogo*, 1985.
13. FLANAGAN, M.. *Innovative tools for automatic vibration analysis and diagnosis – 1a. part. Machine, Plant & Systems Monitor*. p. 17-20, February 1998.
14. FLANAGAN, M.. *Innovative tools for automatic vibration analysis and diagnosis – 2a. part. Machine, Plant & Systems Monitor*. p. 15-18, October 1998.
15. FLORES-SINTAS, A.; CADENAS, J. M.; MARTIN, F.. *Membership functions in the fuzzy C-means algorithm. Fuzzy Sets and Systems*, v. 101, p. 49-58, 1999.
16. FUJIMOTO, R. Y.. *Sistema fuzzy para diagnóstico de defeitos em mancais de rolamentos*. 2002, 85 p., Trabalho de Formatura, EP-USP.
17. GRAUEL, A.; LUDWIG, L. A.; KLENE, G.. *Comparison of Different Intelligent Methods for Process and Quality Monitoring. International Journal of Approximate Reasoning*, v. 16, p. 89-117, 1997.
18. GOLDMAN, S.. *Vibration Spectrum Analysis: A practical approach*. Industrial Press Inc., 1a. ed, 1991.
19. 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.
20. INTERNATIONAL STANDARDS ORGANIZATION. *Mechanical vibration of machines with operating speeds from 10 to 200 rev/s - Basis for specifying evaluation standards: ISO 2372-1994: General guidelines*, ISO, 1995.
21. INTERNATIONAL STANDARDS ORGANIZATION. *Mechanical vibration- evaluation of machine vibration by measurements on non-rotating parts: ISO 10816-1: General guidelines*, ISO, 1995.
22. 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.
23. 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.

24. 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.
25. 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.
26. JONES, R. M.. *Enveloping for Bearing Analysis. Sound and Vibration*, p. 10-15, Fevereiro de 1996.
27. KARNIK, N. N.; MENDEL, J. M.. *Operations on Type-2 Fuzzy Sets. Fuzzy Sets and Systems*. v. 122, p. 327-348, 2001.
28. KARTALOPOULOS, S. V.. *Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications*. IEEE Press, 1996.
29. KIMURA, Y.. *Maintenance Tribology: Its Significance and Activity in Japan. Wear*, v. 207, p. 63-66, 1997.
30. 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.
31. 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.
32. LOCKHEED MARTIN MICHOUUD SPACE SYSTEMS. *Vibration Standard for New and Rebuilt Machinery and Equipment. LMMSS Specification No. V 1.0*, 1997.
33. LOPES, T. A. P.; TROYMAN, A. C. R.. *Manutenção Preditiva por Vibrações: o Sistema AD4. ALCOOLbrás*, p. 44-46, Março/Abril 2001.
34. MATHWORKS, THE. *Fuzzy Logic Toolbox: For Use With MATLAB, User's Guide. Version 2.*, MathWorks Inc., Janeiro de 1995, 227 p.
35. MECHEFSKE, C. K.. *Objective Machinery Fault Diagnosis Using Fuzzy Logic. Mechanical Systems and Signal Processing*, v. 12 n. 6, p. 855-862, 1998.
36. 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.

37. MISHKOFF, H. C.. *Understanding Artificial Intelligence*. Radio Shack, 1986.
38. 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.
39. NSK. *NSK Bearing Doctor: Diagnóstico Rápido de Ocorrência em Rolamentos*. 2002.
40. 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.
41. PADOVESE, L. R. *Automatização de Diagnóstico de Falhas em Plantas Industriais*, 2002, 142 p., Tese de Livre Docência, EP-USP.
42. PHAM, D. L.. *Spatial Models for Fuzzy Clustering*. *Computer Vision and Image Understanding*, v. 84, p. 285-297, 2001.
43. 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.
44. PROAKIS, J.G.; MANOLAKIS, D.G.. *Digital Signal Processing*, 3rd Ed., Prentice Hall, 1996.
45. SHAW, I. S.; SIMÕES, M. G.. *Controle e Modelagem Fuzzy*. Ed. Edgard Blücher, 1999.
46. 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.
47. SKF CONDITION MONITORING. *Prism4 for Windows: User Manual*, 1997.
48. SKF, *Bearing Failures and their Causes*, Product Information PI401, 1994.
49. SYTSMA, S.. *Quality and Statistical Process Control*. Disponível em: <http://www.isixsigma.com/offsite.asp?A=Fr&Url=http://www.sytsma.com/tqmttools/charts.html>. Acesso em: 01 Junho 2005.
50. TANDON, N.. *A Comparison of Some Vibration Parameters for the Condition Monitoring of Rolling Element Bearings*. *Measurements*, v. 12, p. 285-289, 1994.
51. 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.

52. TARIFA, Enrique E.; SCENNA, Nicolás J.. *Fault Diagnosis, Direct Graphs, and Fuzzy Logic. Computers Chem. Engng.*, v. 21, p. S649-S654, 1997.
53. TSOUKALAS, L. H.; UHRIG, R. E.. *Fuzzy and Neural Approaches in Engineering*. John Wiley & Sons Inc., 1997.
54. 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.
55. VEREIN DEUTSCHER INGENIEURE. *Standards of evaluation for mechanical vibrations of machines: VDI 2056*, VDI, 1997.
56. 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.
57. 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.
58. 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.
59. 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.
60. WEI, J.. *Recommended Initial Alarm Criteria for Bearing Condition Assessment Using Enveloped Acceleration Measurements. SKF Application Note*, CM3068, 2003.
61. WIER, W.. *How to Use the Statistical Alarms Wizard in Machine Analyst . SKF Application Note*, CM3089, 2004.

APÊNDICE

Apêndice A ANÁLISE DE VIBRAÇÃO

Atualmente, a análise de vibração é amplamente utilizada como parte integrante da manutenção preditiva. Com esta ferramenta, pode-se detectar e estabelecer uma tendência de desenvolvimento das falhas. Entre as falhas que podem ser estudadas através da análise de vibração, podem-se citar: falhas em rolamentos e engrenagens, problemas de alinhamento e balanceamento, fenômenos elétricos em motores, anormalidades em processo de produção, entre outros.

A importância da análise de vibração é descrita por Liu³¹:

- 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 utilizada para monitorar uma variedade de tipos de máquinas e equipamentos;
- sensores de vibração (acelerômetros) têm resposta confiável e precisa;
- particularmente para rolamentos, suas resposta dinâmica é bem conhecida.

A análise de vibração é baseada na resposta dinâmica (o sinal de vibração) do equipamento (que é um sistema dinâmico) e esta resposta é composta pelas características dinâmicas do sistema. Este comportamento é denominado assinatura mecânica da máquina.

Para a realização da análise, pode-se utilizar tanto o estudo de valores e tendências de alguns parâmetros, quanto o comportamento do sinal tanto no domínio temporal quanto frequencial.

Existem diversas fontes na literaturas onde se discute a eficiência de diversos parâmetros no diagnóstico de defeito em mancais de rolamentos^{1,19,31, 46,50}. Cada um destes parâmetros fornece informações mais precisas em uma situação particular, tanto com relação às condições operacionais, quanto ao método de coleta de dados.

1. Análise por Parâmetros

Os parâmetros de vibração são utilizados para uma pré-análise das condições do equipamento alertando ou alarmando para a necessidade de uma análise mais detalhada tanto do espectro de vibração quanto dos próprios parâmetros, com o objetivo de obter um diagnóstico mais detalhado da causa da anormalidade do equipamento.

Entre estes, pode-se citar os apresentados na Tabela A.1 e na Tabela A.2^{1,19,50,51}. Estes parâmetros foram utilizados nos testes realizados para este trabalho. Eles foram aplicados tanto para o sinal de vibração em aceleração e para seu sinal de envelope (apresentado no item 3 do Apêndice A).

Tabela A.1 – Parâmetros para análise de vibração

<i>Parâmetros</i>	<i>Equação / Observações</i>
RMS ou Valor Eficaz	$V_{ef}(x(t)) = RMS(x(t)) = \sqrt{\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T (x(t))^2 dt}$ <p>(p/ sinal contínuo)</p>
	$V_{ef}(x(t)) = RMS(x(t)) = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$ <p>(p/ sinal discreto composto por N pontos)</p>
	<ul style="list-style-type: none"> ✓ fornece um valor relacionado com o nível de energia ou potência de um dado sinal. ✓ parâmetro mais usado para alarme de vibração com propósito de <i>detecção/diagnóstico</i> de falhas, sendo utilizado por normas e na indústria para especificar níveis de alarme de vibração^{2,20}.

Tabela A.2 - Parâmetros para análise de vibração (continuação)

<i>Parâmetros</i>	<i>Equação / Observações</i>
Skewness ¹⁹	$Sk(x(t)) = \frac{1}{N \times \sigma^3} \sum_{i=1}^N \left(x_i - \bar{x} \right)^3$ <ul style="list-style-type: none"> ✓ parâmetro adimensional que é função do momento estatístico de terceira ordem do sinal, sendo normalizado pelo desvio padrão σ. ✓ representa a assimetria da função de distribuição de probabilidade do sinal. Portanto, para um sinal com distribuição gaussiana tem-se um valor nulo.
Kurtosis ¹⁹	$Kurt(x(t)) = \frac{1}{N \times \sigma^4} \sum_{i=1}^N \left(x_i - \bar{x} \right)^4$ <ul style="list-style-type: none"> ✓ parâmetro adimensional que é função do momento estatístico de quarta ordem do sinal, sendo normalizado pelo desvio padrão σ. ✓ 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.
Valor de Pico	$X_{m\acute{a}x}(x(t)) = m\acute{e}dia \left(\max_{i=1}^M (x_M(t)) \right) \text{ ou}$ $X_{m\acute{a}x}(x(t)) = m\acute{e}dia(x_i > 0.9 \times \max(x[t]))$ <ul style="list-style-type: none"> ✓ é o valor de pico máximo de um dado sinal no tempo³¹. ✓ uma vez que este parâmetro é altamente sensível ao ruído, normalmente se escolhe uma média de valores de picos máximos de M sinais ou dos valores de picos que ultrapassam 90% do valor de pico global.
ER ^{1,41}	$ER(x[t], x_{normal}[t]) = \frac{1}{N_{espectro}} \sum_{f\hat{i}=1}^{N_{espectro}} X[f\hat{i}] - X_{normal}[f\hat{i}] $ <p>(onde $N_{espectro}$ é o número de pontos do espectro de frequência)</p> <ul style="list-style-type: none"> ✓ 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 ($X_{normal}[f_i]$)

Além destes, existem outros que são representados por combinação entre dois parâmetros, tais como os apresentados na Tabela A.3.

Tabela A.3 – Parâmetros para análise de vibração (outros)

<i>Parâmetro</i>	<i>Equação</i>
Fator de Crista ¹⁹	$Fc(x(t)) = \frac{X_{\max}(x(t))}{Kurt(x(t))}$
Fator K ¹	$Fk(x(t)) = V_{ef}(x(t)) \times Kurt(x(t))$

2. Análise Espectral para Mancais de Rolamentos

A análise espectral de um sinal pode fornecer informações mais detalhadas sobre o estado do equipamento que a análise de parâmetros.

Um método bastante utilizado para realizar a análise espectral é o DEP (Densidade Espectral de Potência) ¹⁸. Ela é definida como sendo a Transformada de Fourier (TF) da função de autocorrelação do sinal.

A análise do espectro de frequência é baseada normalmente em frequências de defeitos ^{5,18,41} que podem ser calculadas previamente, e no estudo da relação entre a evolução do espectro e a progressão da falha. Para a progressão da falha, 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 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 A.4.

Tabela A.4 –Frequência de defeitos em rolamento

<i>Frequência</i>	<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 rolante.

Portanto, além da própria análise do espectro, existem diversos parâmetros baseados na amplitude da frequência que podem ser utilizados também para o diagnóstico de defeitos. Alguns deles são apresentados na Tabela A.5.

Tabela A.5 – Parâmetros para análise de vibração (baseado no espectro)

<i>Parâmetro</i>	<i>Equação</i>
Amplitude da frequência de defeito	Relacionados às seguintes frequências: ✓ frequência de rotação do eixo e suas harmônicas; ✓ frequência de defeitos localizados em rolamentos ou engrenamentos; ✓ entre outros.
Energia de uma banda de frequência	
Razão de Pico	$Rp(x(t)) = \frac{N_{espectro} \times \sum_{j=1}^n X_{f(j)}}{\sum_{j=1}^{N_{espectro}} X_{f(j)}}$ ✓ é definido como sendo a relação da amplitude das n harmônicas da frequência característica de defeito e a energia total do espectro de frequência (composto por $N_{espectro}$ pontos) ⁴¹ .

Estes parâmetros são apresentados apenas com intuito informativo, não sendo utilizados para os testes feitos neste trabalho.

3. Envelope

O envelope ⁴¹ 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 de amplitude presentes no sinal. A informação mais utilizada desta ferramenta é o seu espectro, que informa a frequência de modulação de amplitude do sinal.

Conforme visto no item 2, as frequências excitadas por um defeito de rolamentos em sua fase inicial estão em uma faixa de alta frequência ($>5\text{kHz}$). Normalmente as frequências de falhas de rolamento modulam (em amplitude) uma frequência nesta faixa. Isto permite que o método do envelope extraia a informação de falha do rolamento em um estágio inicial.

Este sinal é utilizado nos testes apresentados neste trabalho, em conjunto com alguns dos parâmetros apresentados no item 1 do Apêndice A.

4. Outros

Outros métodos utilizados que trabalham com parâmetros vetoriais (como o DEP), são: transformada wavelet ³⁸, modelos paramétricos auto-regressivos ¹¹, distribuição tempo-frequência ³⁴, cepstrum ⁴¹, além da análise do envelope ²⁶.

Também se utilizam parâmetros escalares baseados nestes tratamentos vetoriais, tais como os coeficientes da transformada wavelet ³⁸ e amplitude de frequências características.

Apêndice B CARACTERÍSTICA DO PROGRAMA “SISTEMA_FUZZY”

Para implementar a metodologia apresentada no item 5.1, foi criado o programa “Sistema_Fuzzy” para automatizar a criação de um sistema de inferência fuzzy genérico. 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 ***Conhecimento Heurístico***) quanto através da metodologia apresentada acima (denominada no programa como ***Conhecimento Analítico***). Esta diferença é mostrada na Figura B.1.

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 B.1 – 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 no item 5.1).

A seguir são descritas algumas características deste programa.

5. 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 2.2.1, 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.

6. Operadores Lógicos

Os operadores lógicos que podem ser utilizados neste programa, são os mesmos apresentados no item 2.2.2, ou seja, para os operadores AND e OR:

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

E para o operador NOT:

- Zadeh
- Yager
- Sugeno
- Threshold
- Cosine

7. Operador THEN

As funções que podem ser utilizadas para este operador, são as mesmas descritas no item 2.2.8, ou seja:

- Mínimo
- Produto

8. Operador de Agregação

As funções que podem ser utilizadas para este operador, são as mesmas descritas no item 2.2.9, ou seja:

- Máximo
- Soma

9. Operador de Desfuzzificação

As funções que podem ser utilizadas para este operador, são as mesmas descritas no item 2.2.10, ou seja:

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

10. Discretização (N_{discret})

Uma característica específica do programa “Sistema_Fuzzy”, é a discretização das funções de pertinência que é o número de pontos que as funções de pertinência devem ser discretizadas.. A discretização é necessária para a execução das operações de agregação e de desfuzzificação. A escolha desta característica 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.

11. 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.

12. Regras de Inferência

Além da regra padrão definida na Figura 5.5, 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 B.2 – 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 exemplificado na Figura B.3, que também apresenta exemplos de algumas regras de inferências), 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 seqüência. Ao lado de cada regra são colocados os seus respectivos pesos de relevância.

Figura B.3 – Exemplo da visualização das regras de inferência

13. Teste com o programa “Sistema_Fuzzy”

Nesta parte do programa, o usuário poderá testar se um dado vetor é descrito por alguma das *condições a serem identificadas*, representadas no sistema de inferência fuzzy criado previamente através deste programa. 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 (conforme exemplo da Figura B.4).

No exemplo da Figura B.4, 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.

Figura B.4 – (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

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

14. 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 B.5.

Figura B.5 – Propriedades de um sistema de inferência fuzzy

Apêndice C EQUAÇÕES QUE DESCREVEM AS FUNÇÕES DE PERTINÊNCIA

1 Trapezoidal

Apresentada na Figura C. 1, ela é definida pela seguinte equação:

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

A função pode ser obtida através dos parâmetros a , b , c e d , ou, para um 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:

$$\begin{aligned} a &= m - f_2 \cdot \Delta \\ b &= m - f_1 \cdot \Delta \\ c &= m + f_1 \cdot \Delta \\ d &= m + f_2 \cdot \Delta \end{aligned} \quad \text{Equação C. 2}$$

Figura C. 1 – Parâmetros da função trapezoidal

2 Triangular

Apresentada na Figura C. 2, ela é definida pela seguinte equação:

$$\mu_{TRI\Delta}(x, a, b, c) = \begin{cases} \frac{(x-a)}{(b-a)} & a < x \leq b \\ \frac{(x-c)}{(b-c)} & b < x < c \end{cases} \quad \text{Equação C. 3}$$

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

$$\begin{aligned} a &= m - f_1 \cdot \Delta \\ b &= m \\ c &= m + f_1 \cdot \Delta \end{aligned} \quad \text{Equação C. 4}$$

Figura C. 2 – Parâmetros da função triangular

3 Gaussiana

Apresentada na Figura C. 3, ela é definida pela seguinte equação:

$$\mu_{GAUSS}(x; m, \Delta) = e^{-\left(\frac{m-x}{\Delta}\right)^2} \quad \text{Equação C. 5}$$

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, a dispersão ***Δ*** da equação acima, definido pelo ***Δ*** fornecido pelo usuário multiplicado por ***f_I***.

Figura C. 3 – Parâmetros da função gaussiana

4 Pi

Apresentada na Figura C. 4, ela é definida pela seguinte equação:

$$\mu_{TRIA}(x; a, b) = \begin{cases} S\left(x; a - b, \frac{(a - b)}{2}, a\right) & x \leq a \\ 1 - S\left(x; a, \frac{(a + b)}{2}, a + b\right) & x > a \end{cases} \quad \text{Equação C. 6}$$

Sendo S a função sigmodal definida por:

$$S(x; a_1, a_2, a_3) = \begin{cases} 0 & x \leq a_1 \\ 2\left(\frac{x - a_1}{a_3 - a_1}\right)^2 & a_1 < x \leq a_2 \\ 1 - 2\left(\frac{x - a_3}{a_3 - a_1}\right)^2 & a_2 < x \leq a_3 \\ 1 & x > a_3 \end{cases} \quad \text{para } a_2 = \frac{(a_3 - a_1)}{2} \quad \text{Equação C. 7}$$

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 C. 4 – Parâmetros da função pi

5 Beta

Apresentada na Figura C. 5, ela é definida pela seguinte equação:

$$\mu_{BETA}(x; m, \Delta) = \frac{1}{1 + \left(\frac{x - m}{\Delta} \right)^2} \quad \text{Equação C. 8}$$

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 acima, definido pelo Δ fornecido pelo usuário multiplicado por f_I .

Figura C. 5 – Parâmetros da função beta