

MON
621:534
M551m
TESISEM

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

FACULDADE DE ENGENHARIA MECÂNICA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

MONITORAMENTO EM TEMPO REAL DA QUALIDADE DE SINAIS DE VIBRAÇÕES,
UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Dissertação apresentada à Universidade Federal de Uberlândia por:

TATIANA MEOLA

como parte dos requisitos para obtenção do título de Mestre em Engenharia Mecânica

Aprovada por:

Prof. Dr. Marcus Antonio Viana Duarte - (UFU) - Orientador

Prof. Dr. Francisco Paulo Léopore Neto - (UFU)

Prof. Dr. Marcos Moraes de Sousa - (UFU)

Prof. Dr. Robson Pederiva - (Unicamp)

Uberlândia, 05, de agosto de 2005

SISBI/UFU



1000237798

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
BIBLIOTECA

D

SISBI/UFU
237798

FICHA CATALOGRÁFICA

Elaborada pelo Sistema de Bibliotecas da UFU / Setor de Catalogação e Classificação

M551m Meola, Tatiana, 1980-
Monitoramento em tempo real da qualidade de sinais de vibrações, utilizando inteligência artificial / Tatiana Meola. - 2006.
118f. : il.
Orientador: Marcus Antonio Viana Duarte.
Dissertação (mestrado) – Universidade Federal de Uberlândia, Programa de Pós-Graduação em Engenharia Mecânica.
Inclui bibliografia.
1. Vibração - Teses. 2. Inteligência artificial - Teses. 3. Mancais - Teses. I. Duarte, Marcus Antonio Viana. II. Universidade Federal de Uberlândia. Programa de Pós-Graduação em Engenharia Mecânica. III. Título.

621:534

A meus pais, Antonio e Isabel,
a meus irmãos, Juliana e Murilo,
à minha tia Bete,
e a meus tios Marcos e Beto.

Agradecimentos

A Deus, pelos obstáculos ultrapassados.

A meu Orientador Marcus Duarte pelos anos de ensino e principalmente pela amizade.

À Maria Alzira pelo apoio e ajuda nos momentos difíceis.

A todos os funcionários, em especial ao Márcio (projetista) e ao “Passarinho”, que colaboraram com o desenvolvimento de minha Dissertação.

Ao CNPq pela ajuda financeira.



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA
Av. João Naves de Ávila, 2121 - 38400-902 Fone: 0XX(34)32394149 Ramal 42
FAX: 0XX(34)32394282 - Campus Santa Mônica - Uberlândia MG



ALUNO: Tatiana Meola

NÚMERO DE MATRÍCULA: 5032210-6

ÁREA DE CONCENTRAÇÃO: Mecânica dos Sólidos e Vibrações



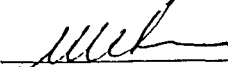

PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA: NÍVEL MESTRADO

TÍTULO DA DISSERTAÇÃO:

“Monitoramento em Tempo Real da Qualidade de Sinais de Vibrações utilizando Inteligência Artificial”

ORIENTADOR: Prof. Dr. Marcus Antônio Viana Duarte

A Dissertação foi **APROVADA** em reunião pública, realizada na Sala 218, Bloco “1M”, Campus Santa Mônica, em 05 de agosto de 2005, às horas 14:00 horas, com a seguinte Banca Examinadora:

NOME		ASSINATURA
Prof. Dr. Marcus Antônio Viana Duarte	UFU	
Prof. Dr. Francisco Paulo Léopore Neto	UFU	
Prof. Dr. Marcos Morais de Sousa	UFU	
Prof. Dr. Robson Pederiva	FEM / UNICAMP	

Uberlândia, 05 de agosto de 2005.

Sumário

Capítulo I	1
Introdução	1
1.1. Objetivo	5
1.2. Descrição do Trabalho	6
Capítulo II	7
Fundamentos de Análise de Vibrações	7
2.1. Técnicas Utilizadas em Análise de Sinais	7
2.1.1. Análise no Domínio do Tempo	7
Média no Domínio do Tempo (Time Domain Average - TDA)	7
Quantificação do Nível de Vibração	8
Fator de Crista	9
Método da Curtose	10
2.1.2. Análise Espectral	12
Transformada de Hilbert	15
Método do Cepstrum	17
Análise de Ordem	18
Técnica do Envelope	19
2.2. Identificação da Origem das Vibrações	20
Desbalanceamento	21
Desalinhamento ou Empenamento	21
Rodopio (Oil Whirl)	22
Aumento da turbulência em Rotores	22
Correias	22
Engrenagens	22
Folgas Mecânicas	22
Vibração Induzida Eletricamente	23
Rolamentos	23
2.3. Determinação dos Níveis de Referência via Critérios de Severidade	25

Níveis de Referência para Motores elétricos	26
Níveis de Referência para Rolamentos	26
Capítulo III	29
Redes Neurais artificiais	29
3.1. Redes Biológicas	29
3.1.1. Neurônios Biológicos	30
3.2. Neurônios Artificiais	30
3.3. Funções de Ativação	31
3.4. Arquitetura das Redes Neurais	33
3.4.1. Nodos de conexão tipo feedforward	34
3.4.2. Nodos de conexão tipo feedback	35
3.5.1. Aprendizado Supervisionado	35
3.5.2. Aprendizado Não Supervisionado	36
3.5.3. Aprendizado por Reforço	36
3.6. Rede Neural Probabilística (PNN)	37
3.6.1. Método de Classificação de Bayes	39
3.6.2. Método de Estimativa da fdp	39
3.6.3. Arquitetura e Funcionalidade da Rede Neural Probabilística	41
Capítulo IV	42
Lógica Difusa	42
4.1. Conjuntos Fuzzy	42
4.1.1. Funções fuzzy mais comuns	43
4.1.2. Operações com conjuntos fuzzy	46
4.1.3. Variáveis Lingüísticas	48
4.2. Sistema de Inferência Fuzzy	49
4.2.1. Saída do Modelo Fuzzy	49
Criação da regra fuzzy	49
Fuzzificação	49
Combinação das entradas nas regras fuzzy	50
Parte conseqüente de cada regra	52
Combinação de todas as partes conseqüentes	53
Desfuzzificação	54
4.2.2. Alguns Modelos Fuzzy	55
Modelo fuzzy de Mandani	55
Modelo fuzzy de Larsen	56

Modelo fuzzy de Sugeno	57
Modelo fuzzy de Tsukamoto	58
Capítulo V	60
Metodologia e Procedimentos	60
5.1. Bancada Experimental	63
5.2. Calibração do Sensor de Deslocamento	66
5.3. Aquisição de Dados	68
5.3.1. Calibração dos sensores	70
5.3.2. Procedimento de Aquisição dos dados	70
5.4. Características do Sistema	73
5.5. Determinação de parâmetros indicativos da qualidade do sinal e de falhas em rolamentos	76
5.5.1. Análise de Sensibilidade	79
5.6. Desenvolvimento das Redes Neurais e da Lógica Fuzzy	81
Capítulo VI	86
Resultados e Análises	86
6.1. Parâmetros indicativos da qualidade do sinal	86
6.1.1. Manca 2	86
6.1.2. Manca 6	94
6.2. Parâmetros indicativos de falhas em rolamentos	101
Capítulo VII	106
Conclusões	106
7.1. Trabalhos Futuros	108
Referências Bibliográficas	109
Anexo I	114

Simbologia

Letras Latinas

A_0	Nível médio do sinal
A_i	Termo real da Série de Fourier.
B_i	Termo imaginário da Série de Fourier
$C(t)$	Cepstrum de um sinal
C_i	Amplitude do Coeficiente de Fourier
D	Diâmetro da esfera do rolamento [mm]
FC	Fator de Crista
F_{xx}	Função Densidade Espectral de Potência
\mathfrak{F}	Transformada de Fourier
K	Valor da curtose multiplicado pelo valor RMS do sinal [m/s^2]
M	Número de pontos por período de um sinal
N	Número de períodos
N_e	Número de esferas do rolamento
Nível_Médio	Nível médio do sinal [m/s^2]
Nível_Pico	Nível máximo do sinal [m/s^2]
Nível_Pico a Pico	Máxima excursão do sinal [m/s^2]
Nível_RMS	Nível eficaz do sinal [m/s^2]
$P(x)$	Função de Distribuição de Probabilidade
RMS_i	i-ésimo parâmetro indicativo da qualidade de sinal
RSR	Relação Sinal Ruído [dB]
S-norms	Co-normas Triangulares
T	Período de um sinal ; Tempo de duração do sinal [s]
T-norms	Normas Triangulares
T_{sig}	Parâmetro que determina a suavidade da curva sigmoidal
$W(d)$	Função de ponderação conhecida
X	Amostra desconhecida
$X(f)$	Transformada de Fourier de um sinal [m/s^2]
a_i	i-ésimo coeficiente de um polinômio
c_k	Custo associado com um erro de classificação cometido
d	Diâmetro primitivo do rolamento [mm]
d_{pe}	Diâmetro da pista externa do rolamento [mm]
d_{pi}	Diâmetro da pista interna do rolamento [mm]

dt	Intervalo de aquisição [s]
f	Freqüência [Hz]
f_{de}	Freqüência característica de defeito na esfera do rolamento [Hz]
f_{dp}	Função densidade de probabilidade para toda a coleção de amostras.
f_{dpe}	Freqüência característica de defeito na pista externa do rolamento [Hz]
f_{dpi}	Freqüência característica de defeito na pista interna do rolamento [Hz]
f_g	Freqüência característica de defeito na gaiola do rolamento [Hz]
$f_k(X)$	Concentração (densidade) de membros da classe k ao redor da amostra desconhecida.
h_k	Probabilidade da classe k
m	Valor de máximo da função de pertinência
n	Número de entradas do neurônio
n_i	Número de elementos (dados) do i -ésimo grupo
$p(x)$	Função Densidade de Probabilidade.
s_i^2	Estimativas das variâncias do i -ésimo grupo.
t	Tempo [s]
v	Tensão [Volts]
w_i	i -ésimo peso de ponderação associado a um neurônio artificial
$x(idt)$	Vetor do sinal no domínio do tempo [m/s ²]
$x(t)$	Sinal em função do tempo
$x=[x_1, x_2, \dots, x_m]$	Coleção de amostras aleatórias
x_i	i -ésimo parâmetro de entrada de uma rede neural
\bar{x}	Valor estimado para a média de um sinal [m/s ²]
\bar{x}_i	Estimativas das médias do i -ésimo grupo.
$\tilde{x}(t)$	Transformada de Hilbert de um sinal [m/s ²]
y	Parâmetro de saída da rede neural
$y(idt)$	Valor da média sincronizada do i -ésimo componente da TDA [m/s ²]
y_{max}	Maior valor possível para a função de pertinência
y_{min}	Menor valor possível para a função de pertinência
$z(t)$	Sinal Analítico [m/s ²]

Letras Gregas

Δ	Deslocamento [mm]
----------	-------------------

ψ_A	Função característica de um conjunto clássico A
θ	Valor de ativação de um neurônio
α	Coefficiente de inclinação da reta
α_t	Nível de confiança para o Teste de Hipótese
β	Ângulo de contato do rolamento [graus]
γ_4	Coefficiente de Curtose
γ_6	Razão entre o sexto momento de tendência central e o desvio padrão do sinal elevado à sexta potência
μ	Momento central
$\mu_A(x)$	Função de pertinência ou função característica de um conjunto fuzzy A
$+\gamma$	Valor máximo da saída da rede neural
$-\gamma$	Valor mínimo da saída da rede neural
σ	Desvio padrão [m/s ²]
σ_s	Parâmetro de escala que define a largura da curva sino centrada em cada membro da coleção de dados.

Símbolo

\otimes Significa convolução

Meola, T., 2005, "Monitoramento em tempo real da qualidade de sinais de vibrações, utilizando inteligência artificial", Dissertação de Mestrado, Universidade Federal de Uberlândia, MG

Resumo

Este trabalho tem como objetivo estudar a possibilidade de avaliar, em tempo real, os sinais de vibrações adquiridos para fins de monitoramento. Para isto, utilizou-se uma bancada experimental com cinco mancais de rolamentos de esferas, sem vedação e com carga aplicada no mancal central. O sistema foi caracterizado via técnicas de análise espectral e Funções Resposta em Frequência. Cinco grupos de sinais de vibração adquiridos foram classificados da seguinte forma: sinal bom, problemas de instrumentação (cabo danificado, condicionador de sinais desligado, cabo desconectado), sensores trocados de posição, ocorrência de eventos transientes e máquina desligada. Monitoraram-se apenas os mancais de apoio para verificação da qualidade do sinal e os demais para detecção de possíveis falhas. Utilizando-se um Teste de Hipótese Nula para comparação de médias, e gráficos Boxplot, foi realizada uma análise de sensibilidade para filtrar 22 parâmetros de vibração escolhidos como sintomas de qualidade de sinal. Após a seleção dos cinco parâmetros mais sensíveis para cada mancal, os mesmos foram utilizados para treinamento de uma Rede Neural Probabilística e num Sistema de Inferência Fuzzy, os quais se mostraram aptos a classificar os sinais coletados para teste, não apresentando diferenças significativas entre os resultados ($\approx 100\%$ de acerto) obtidos na classificação. Como um dos mancais apresentou uma falha na gaiola durante o funcionamento, foi possível avaliar os melhores parâmetros indicativos deste defeito.

Palavras Chave: Monitoramento on line. Qualidade de sinais de vibração. Inteligência Artificial. Manutenção Preditiva. Mancais de Rolamento.

Meola, T., 2005, "Real Time Monitoring of Vibration Signals Quality Using Artificial Intelligence", M. Sc. Dissertation, Universidade Federal de Uberlândia, MG

Abstract

This work has the objective to evaluate, in real time, the signals of vibrations acquired for monitoring purpose. An experimental setup compound by an electric motor and five ball bearings, with a load applied in the central bearing. The support bearings are self-aligning ball bearings and the central three are rigid bearings of single career. Was built techniques of spectral analysis and Frequency Response Functions have been applied to characterize the vibratory behavior of the studied system. Five data sets of signal condition were acquired, as: good signal, sensors in wrong position, cable problems, transient events and turned off machine. Only the self-aligning ball bearings were monitored. A Null Hypothesis Test for average comparison and a Boxplot graphics analysis were used to filter the 22 chosen vibration parameters in order to select the best sensitivity of the signals set. After identifying of the five more sensible parameters for each ball bearing, they have been used to training a Neural Probabilistic Network and into a Fuzzy Inference System. The classification tools showed good results close to 100 % of success with a test set. As one of the ball bearings presented a cage defect during the operation, it was possible to evaluate the best indicative parameters, of the studied ones, to detect this kind of defect. In this case, the global RMS value and the peak values of envelopes in the frequency range 50 Hz to 1 kHz and 500 Hz to 8 kHz, respectively.

Words Key: Real Time Monitoring, Signal Quality of Signal, Artificial Intelligence. Predictive Maintenance. Ball Bearings.

Capítulo I

Introdução

Segundo Trigo, A. A., (2004), numa entrevista para o web site <http://www.jornalcana.com.br/>, a Manutenção Preditiva assume um papel de grande importância em plantas industriais quando consegue atender às duas prementes demandas do competitivo mercado dos dias de hoje : redução de custos e garantia de disponibilidade.

Através da adoção de técnicas preditivas, é possível antecipadamente detectar e diagnosticar defeitos em desenvolvimento nos equipamentos industriais antes da quebra destes, propiciando a programação pontual das intervenções de manutenção. Com isto, o estoque de peças sobressalentes e o custo da intervenção são reduzidos, juntamente com a eliminação das perdas de produtos provenientes de uma possível parada não-programada.

Tem-se verificado uma redução de até 40% no volume de troca de rolamentos com a adoção da manutenção preditiva (Tebchirani, 2003). E, por outro lado, garantindo-se a boa condição de funcionamento dos equipamentos industriais, é possível utilizar-se de toda a vida útil projetada para o equipamento. Por consequência, o número de quebras ou “taxa de falha” é diminuído, garantindo-se a confiabilidade do equipamento. Portanto, pode-se dizer que o equipamento fica mais tempo disponível para a produção, daí o impacto da Manutenção Preditiva no regime de produção das plantas industriais.

Vaz Pinto (2004) publicou um artigo na National Instruments o qual discute alternativas para a elaboração de um programa de manutenção preditiva eficaz para máquinas de navios e plataformas de petróleo, avaliando em que tipo de máquina a combinação de técnicas como análise de óleo lubrificante, monitoração de parâmetros operacionais (pressão, temperatura, etc) e análise de vibração pode ser efetiva, e apresenta ainda aspectos interessantes relativos a diagnóstico de máquinas, a partir de alguns casos reais ocorridos em navios e plataformas. O autor menciona sobre os benefícios da manutenção preditiva, em que os custos de manutenção, dependendo do tipo de indústria, podem representar entre 15% a 30% do custo dos bens produzidos, sendo que 1/3 dos custos de manutenção é desperdiçado como resultado de manutenção desnecessária ou inadequada. Relata, também, que levantamento recente em indústrias mostrou que, considerando a potência total da Planta Industrial, se gasta, em média, de US\$ 17,00 a US\$ 18,00 / HP / ano com manutenção corretiva; de US\$ 11,00 a US\$ 13,00 / HP / ano com manutenção preventiva, enquanto que para manutenção preditiva esses números ficam em torno de US\$ 7,00 a US\$ 9,00 / HP / ano.

Em trabalhos de manutenção preditiva por análise de vibrações, os maiores problemas encontrados referem-se à detecção de uma anomalia e a avaliação da gravidade desta em relação à necessidade de planejamento de uma parada programada do equipamento. Em função destas necessidades, Lasse Hansen (1998) desenvolveu um trabalho, o qual visa mostrar a evolução dos métodos de detecção e as diversas formas hoje existentes de aperfeiçoar os procedimentos de detecção e a avaliação da gravidade de um determinado defeito em relação à necessidade de intervenção no equipamento.

Barkov et all (1995) utilizaram um método de medição simples para avaliar a condição e o tempo de vida de mancais de rolamento. No trabalho, os autores citam que há três vantagens principais desse método com relação aos outros métodos de diagnose utilizados com maior frequência. A primeira trata-se da alta sensibilidade do método, em que a modulação da vibração produzida por um pequeno defeito com intensidade de aproximadamente 1 % é facilmente detectada. Anomalias severas são caracterizadas por intensidades de 10 %. A segunda é a aptidão em se obter grande precisão na avaliação da condição de uma medição de vibração simples em um pequeno período de tempo. E, a terceira vantagem é que os requisitos para se realizar as medições não são muito restritos. Num caso simples, precisa-se medir a vibração na faixa de frequência de 2 a 10 KHz, sem necessidade de comparação com resultados de medições anteriores.

Segundo Cunha (2004), "Caçar faz parte da sobrevivência humana desde o começo dos tempos. Pessoas caçam para adquirirem coisas necessárias à sobrevivência, água e alimento. Hoje, engenheiros e cientistas usam a aquisição de dados para "abater" as informações necessárias à sobrevivência na era da informação. Os sistemas de monitoramento "on-line" de vibração e parâmetros operacionais caçam em tempo real as informações necessárias à sobrevivência da manutenção em um mundo dinâmico e competitivo, onde rapidez na disponibilidade das informações representa a diferença entre o sucesso e o fracasso".

Sick (2002) mostra que um sistema inteligente consiste na maioria das vezes de uma seqüência de subsistemas para a condução dos dados, desde a detecção dos sinais até o diagnóstico do estado da ferramenta: aquisição (sensoriamento); pré-processamento (condicionamento de sinais); representação (tratamento de sinais); avaliação e resposta (reação ou tomada de decisão), tudo feito de maneira automática.

O monitoramento em tempo real é, portanto, de suma importância na aplicação das técnicas de manutenção preditiva. O conhecimento da condição de integridade de equipamentos e estruturas sujeitos a danos promovidos pela condição de operação é a grande preocupação, quer seja por razões econômicas, quer seja para evitar acidentes de trabalho. Associando as técnicas de medições de vibração aos recursos da Internet, obtém-se uma combinação significativa para o controle de integridade dos equipamentos em tempo real.

Visando utilizar a Internet como ferramenta de informação e comunicação, é possível avaliar a criticidade e severidade de defeitos quando os equipamentos e estruturas estão submetidos a diferentes condições operacionais, possibilitando uma interação on-line para tomada de decisões de intervenção, retirada ou continuidade operacional (Feres, 2003).

Em relação ao método de coleta de vibração "off-line", com a utilização de coletores/analísadores portáteis, o método "on-line" apresenta inúmeras vantagens, tais como: Acesso em tempo real a partir de qualquer ponto da companhia, possibilitando o monitoramento em diversas condições operacionais, incluindo partidas e paradas. Proporcionando, portanto, uma otimização de recursos humanos especializados, diagnósticos precisos e a operação segura em condições críticas (Cunha, 2004).

Um sistema de monitoramento em tempo real das condições de uma turbina pode reduzir custos de manutenção de um turbo-gerador em plantas industriais. Isso se baseia no conceito de análise de assinatura da vibração, utilizando a informação vibratória adquirida de vários pontos da turbina, realizando-se o monitoramento de vibração, o qual objetiva a detecção da mudança na condição vibratória do objeto sob investigação, durante sua operação (Bandyopadhyay et al, 1999). O artigo publicado sobre o sistema de monitoramento on line da condição do rolamento da turbina, envolve as assinaturas de vibração analisadas por meio de dois parâmetros, denominados Vibração Absoluta do Mancal de Rolamento e Vibração Relativa entre a Gaiola do Rolamento e o Eixo. Os autores concluíram que para se efetuar uma implementação do sistema de análise on line, há necessidade de se ter uma coleção de dados de vibração (mancal ou eixo) sobre um longo período de tempo para se adquirir a história comportamental da turbina e a análise de vibração da mesma pode prever uma quebra catastrófica se o diagnóstico de falha for feito na hora certa.

Azovtsev et al (1994) realizaram um trabalho em que o método proposto foi desenvolvido para identificar a presença, tipo e magnitude de defeitos em mancais de rolamento para o espectro de envelope de vibração aleatória. De modo automático, o Módulo de Diagnóstico de Rolamento (DREAM) pôde ser utilizado para as análises de vibrações.

Para se observarem os níveis de alarme dos equipamentos e elementos de máquinas para manutenção preditiva, há necessidade de se averiguar a integridade do sinal coletado, ou seja, se o sensor de vibração está colocado no seu devido lugar, se um cabo encontra-se em perfeita condição de operação, se a máquina a ser monitorada está ligada ou não, e demais problemas relacionados com processos de medições Assim, são utilizadas técnicas que envolvam o raciocínio aproximado, obtendo-se soluções mais próximas possíveis ao raciocínio humano. Os sistemas fuzzy vêm sendo utilizados com sucesso, nos últimos anos, em problemas que envolvam o raciocínio aproximado (Zadeh, 1997 e Sandri, 1999), por exemplo.

As técnicas de reconhecimento de padrão, utilizando redes neurais têm sido aplicadas em dados de vibração no domínio de tempo e de frequência (Tandon, 1999), destacando-se na verificação das condições de medição e dos níveis de alarme (Meola et al, 2004), uma vez que consistem em um método de solucionar problemas de inteligência artificial, construindo um sistema que tenha circuitos que simulem o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas.

Vicente, Fujimoto e Padovese (2001) realizaram um trabalho envolvendo sistemas de lógica fuzzy para diagnosticar falhas em mancais de rolamento. O artigo descreve um sistema automático de diagnose e classificação de falhas em rolamentos, o qual tem a capacidade de classificar três tipos de defeitos pré estabelecidos em rolamentos operando com condições severas de velocidade e carga. Os parâmetros de análise utilizados foram Skewness, curtose, RMS global, Envelope do Sinal e Energia Residual. Os autores concluíram que, comparando-se os resultados obtidos via lógica fuzzy com os adquiridos via redes neurais perceptron multicamadas (MLP) e probabilísticas (PNN), o sistema fuzzy fornece um terceiro resultado, a indecisão (não sendo considerada como um erro, mas sim como um talvez).

Brito, Pederiva e Garcia (2002), demonstram que os problemas presentes nos motores de indução trifásico se mostram adequados para representação por meios de regras de produção, ou seja, um sistema especialista, baseado em lógica difusa, pode ser utilizado como ferramenta de apoio na manutenção preditiva para fins de diagnose. Um sistema especialista foi utilizado com sucesso na detecção de barras quebradas num motor de indução trifásico.

Darley, Brito e Pederiva (2002) utilizaram, com sucesso, redes neurais artificiais para diagnóstico de defeito elétrico, folga mecânica, desbalanceamento vertical e folga, e desbalanceamento horizontal num motor elétrico. O algoritmo de rede utilizado foi do tipo BackPropagation, sendo testadas doze arquiteturas diferentes de rede.

A detecção de falhas em máquinas rotativas de uma refinaria de Milazzo (Itália), utilizando-se sistemas baseados em redes neurais, foi realizada no trabalho desenvolvido por Crupi, Guglielmino e Milazzo (2004). O sistema de diagnóstico utilizado elimina as restrições dos métodos convencionais, baseados em regras pré-programadas, introduzindo uma aproximação heurística a qual adquire novos aprendizados de forma mais fácil. A idéia é obter bons resultados, mesmo quando novos dados ou defeitos de ruído são introduzidos no sistema, sendo este, capaz de diagnosticar uma nova falha não presente no conjunto de dados de treinamento. Tal objetivo foi alcançado, utilizando-se a Rede Neural Probabilística (PNN).

Bezerra, Arruda e Pederiva (2004) desenvolveram um trabalho utilizando redes neurais para identificar falhas induzidas nas pistas interna e externa, e nas esferas de rolamentos, a partir de parâmetros estatísticos, os quais são RMS, Variância, Skewness, Curtose, Momento de Sexta Ordem e Fator K. Os autores concluem que a rede facilita a análise dos dados sem a

necessidade de um conhecimento técnico para a interpretação dos resultados obtidos e, mostrou-se capaz de identificar as falhas no seu estágio inicial.

Da Silva, Vicente e Padovese (2004), comparam três diferentes métricas ou distâncias utilizadas na função de Parzen da Rede Neural Probabilística (PNN). Os autores utilizam o sistema de diagnóstico de PNN para detectar, identificar a localização e classificar diferentes defeitos em mancais de rolamento operando sob severas velocidades de rotação e condições de carga. Foram discutidas as métricas de Euclidean, Cityblock e Dotprod, e concluíram que esta última mostrou-se ineficiente na identificação e classificação das falhas. As demais, por sua vez, apresentaram cerca de 98 % de acerto na detecção, identificação e classificação dos defeitos.

BoLi, Chow, Tipsuwan e Hung (2000), desenvolveram um diagnóstico de falhas em mancais de rolamento de motores, utilizando rede neural artificial. Utilizou-se o software MotorSim do Matlab, para se simularem sinais de vibrações no domínio do tempo em diferentes condições de deficiência do rolamento. Os dados foram aplicados no treinamento de uma rede feedforward de três camadas, utilizando-se o algoritmo de Levenberg Marquardt. Efetuaram-se medições em tempo real no mancal de rolamento de um motor, para se testar a eficiência de diagnose da rede, a qual mostrou-se apta para execução de tal tarefa.

Meola, Duarte e Assumpção (2005), utilizaram lógica fuzzy e redes neurais probabilísticas como ferramentas de classificação da qualidade dos sinais de vibração coletados em um motor elétrico e um ventilador radial. Utilizaram-se teste de hipótese nula e gráficos Boxplot para a escolha, dentre os 159 parâmetros de vibrações, os 6 melhores a serem aplicados no treinamento da rede neural e para a construção do projeto fuzzy. Comparando-se os resultados obtidos via rede PNN com os obtidos via lógica fuzzy, inferiu-se que não apresentaram diferenças significativas entre si. Ambos os meios de monitoramento mostraram-se bastante eficientes.

1.1. Objetivo

Este trabalho tem como objetivo monitorar em tempo real a integridade dos sinais de vibrações coletados para mancais de rolamentos de esferas, para realização da manutenção preditiva. Isso será desenvolvido, utilizando-se redes neurais artificiais e lógica fuzzy.

1.2. Descrição do Trabalho

Nos Capítulos II, III e IV serão, respectivamente, discutidos os fundamentos de Análise de Vibrações, Redes Neurais Artificiais, com destaque para a Rede Neural Probabilística (PNN) e de Lógica Fuzzy.

O Capítulo V refere-se à metodologia e ao procedimento experimental desenvolvidos neste trabalho.

Por fim, serão apresentados e discutidos os resultados no Capítulo VI e as conclusões com possíveis trabalhos futuros no Capítulo VII.

Capítulo II

Fundamentos de Análise de Vibrações

2.1. Técnicas Utilizadas em Análise de Sinais

2.1.1. Análise no Domínio do Tempo

Durante um processo de medição, fazem-se a aquisição e o tratamento dos dados coletados, efetuando-se análises detalhadas dos mesmos. De modo a se facilitar o processo de análise, existem algumas técnicas que podem ser utilizadas para a extração da história do sinal. Uma das maneiras de se extrair informações dos sinais vibratórios é analisar o seu comportamento no domínio do tempo.

Média no Domínio do Tempo (Time Domain Average - TDA)

A TDA, a qual pode ser representada pela Equação 2.1, consiste basicamente em se fazer a média de um sinal periódico, de modo a se calcular os valores médios do sinal sobre um período do mesmo.

$$y(i\Delta t) = \frac{1}{N} \sum_{r=0}^{N-1} x(i\Delta t + rM\Delta t) \quad (2.1)$$

Na Equação 2.1, $x(i\Delta t)$ são os valores do sinal original, $y(i\Delta t)$ é o valor médio do i -ésimo valor do sinal, M é o número de pontos por período, N é o número de períodos e Δt é o intervalo de aquisição.

A Figura 2.1 representa esquematicamente o princípio da Média no Domínio do Tempo.




Figura 2.1. Esquema da TDA

A TDA permite promover uma filtragem linear do sinal, além de proporcionar uma alta redução de dados, uma vez que somente um período do sinal é retido. Duarte e Simões (2000), utilizaram a TDA com sucesso para a redução de dados num procedimento de identificação de falhas em câmbios automotivos.

Quantificação do Nível de Vibração

Segundo Nepomuceno (1989), a amplitude de vibração é a característica que descreve a severidade da mesma, podendo ser quantificada de diversas maneiras. Na Figura 2.2 é mostrada a relação entre os níveis pico a pico, o nível médio (Equação 2.2) e o nível eficaz (Equação 2.3), ou nível RMS, de um sinal harmônico.

$$\text{Nível_Médio} = \frac{1}{T} \int_0^T x(t) dt \quad (2.2)$$

$$\text{Nível_RMS} = \sqrt{\frac{1}{T} \int_0^T x^2(t) dt} \quad (2.3)$$




Figura 2.2. Quantificação de um sinal harmônico

O valor de pico a pico indica a excursão máxima da onda, uma quantidade importante para definir, por exemplo, quando um elemento da máquina atinge valores críticos, considerando-se máximas tensões ou folga mecânica.

O valor de pico, por sua vez, indica níveis máximos de sinais transientes (curta duração) em choques, proporcionando apenas o valor máximo sem considerar a cronologia da onda.

O valor médio, nível DC, indica o quanto o sinal está deslocado em relação à referência, tendo pouca, ou nenhuma utilidade no monitoramento de vibrações uma vez que, por definição, vibrações são o estudo das oscilações em torno da posição de equilíbrio de um sistema mecânico. .

O valor eficaz (RMS) é uma das medidas mais importantes de amplitude, uma vez que quantifica a energia que está diretamente ligado ao fenômeno estudado, no caso é um indicativo do poder destrutivo da vibração. É muito utilizado como parâmetro global para determinação de níveis de alerta e alarme usados em procedimentos de manutenção preditiva (Ângelo, 1987).

De acordo com Tandon (1999), dos diversos métodos de detecção de falhas, no domínio do tempo, os mais comuns são o nível RMS e o Fator de Crista, que é a razão entre o valor pico e o valor RMS de aceleração.

Fator de Crista

O Fator de Crista (FC) leva em consideração a variação do pico e do valor RMS, em que a relação entre ambos tem o comportamento mostrado na Figura 2.3, com a evolução do desgaste de mancais de rolamento (Nepumoceno, 1989). Para um rolamento novo e sem

defeito, a diferença entre o valor de pico e o nível RMS é de aproximadamente 3 dB ($20\log_{10}(\text{Nível Pico}/\text{Nível_RMS})$). Com o surgimento de um defeito e seu aumento progressivo, esta diferença vai aumentando até atingir um valor de aproximadamente 18 dB, quando em função do desgaste generalizado do rolamento, a diferença entre os níveis começa a diminuir novamente. Estatisticamente tem-se mostrado que quando esta diferença diminuir para 3 dB, o rolamento deverá ser trocado o mais rápido possível para evitar uma quebra imprevista. O que foi mencionando acima pode ser visualizado na Figura 2.4, que mostra a incursão do fator de crista com o desgaste do rolamento.




Figura 2.3. Variação dos valores de Pico e RMS com o desgaste progressivo de mancais de rolamentos.




Figura 2.4. Comportamento do Fator de Crista no tempo

Método da Curtose

Os momentos estatísticos são úteis para descrever o comportamento de variáveis randômicas, estes momentos também são definidos como momentos de área da função densidade de probabilidade, e quando calculado em torno da média são então definidos como

Momento Central. Portanto, o quarto momento de tendência central é estimado pela Equação 2.4.

$$\mu^4 = \int_{-\infty}^{\infty} [x - \bar{x}]^4 p(x) dx \quad (2.4)$$

Onde \bar{x} é o valor médio de $x(t)$ e $p(x)$ é a função distribuição de probabilidade. A determinação da função densidade de probabilidade $P(x)$ torna-se bastante complicada, porém, o momento central de quarta ordem pode ser representado pela Equação 2.5, onde T é o tempo de duração do sinal, o coeficiente de curtose, designado por γ_4 (Equação 2.6), é então obtido dividindo-se μ^4 pelo desvio padrão σ elevado a quarta potência.

$$\mu^4 = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T [x(t) - \bar{x}]^4 dt \quad (2.5)$$

$$\gamma_4 = \frac{\mu^4}{\sigma^4} \quad (2.6)$$

Com isso, substituindo-se a Equação 2.5 na Equação 2.6, tem-se que:

$$\gamma_4 = \lim_{T \rightarrow \infty} \frac{1}{T \sigma^4} \int_0^T [x - \bar{x}]^4 dt \quad (2.7)$$

Na Equação 2.7, a fim de se facilitar a notação, utilizou-se x no lugar de $x(t)$.

A Curtose é bastante aplicada na detecção de falhas incipientes em rolamentos (Büchner, 2001). Muitos sinais aleatórios possuem um comportamento que descrevem com bastante aproximação a função distribuição de Gauss, ou distribuição Normal (Martin e Honarvar, 1984). Segundo os autores, as rugosidades das superfícies em boas condições também possuem este tipo de comportamento, ou seja, a distribuição das alturas segue o padrão de distribuição definida pela função normal.

A Figura 2.5 ilustra a o comportamento da curtose com a evolução do desgaste em mancais de rolamentos.




Figura 2.5. Comportamento da curtose com a evolução do desgaste em mancais de rolamentos.

Vale lembrar que para um rolamento em boas condições, o sinal de vibração emitido pelo mesmo é de natureza aleatória, e seu comportamento tende à distribuição normal ($\gamma_4 \approx 3$). Com o aparecimento de uma falha pontual, o valor da curtose aumenta significativamente e com a evolução da mesma, como no caso do fator de crista, o seu valor volta a diminuir. Para compensar esta diminuição definiu-se o fator K (Equação 2.8), onde o valor da curtose é multiplicado pelo valor RMS do sinal, o qual é sempre crescente com a evolução do defeito (Bezerra, apud Silva, 2004).

$$K = \text{RMS} \cdot \gamma_4 \quad (2.8)$$

Um parâmetro estatístico que pode ser utilizado para fornecer informações sobre o estado do rolamento é o momento central de sexta ordem γ_6 . O mesmo, dado pela Equação 2.9, foi utilizado como dado de entrada em uma rede neural, estudada no trabalho desenvolvido por Bezerra, Arruda e Pederiva (2004).

$$\gamma_6 = \frac{\mu^6}{\sigma^6} \quad (2.9)$$

2.1.2. Análise Espectral

Comumente, devido à alternância e limitação do movimento, as perturbações existentes em máquinas são predominantemente periódicas como pode ser visto na Figura 2.6, a qual representa uma curva de aceleração de um pistão de um motor de combustão interna.

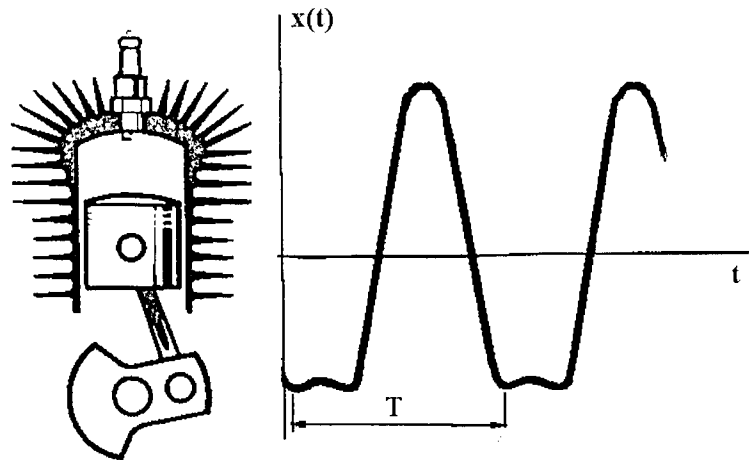


Figura 2.6. Curva de aceleração de um pistão de motor de combustão interna.

Nestes casos, Fourier demonstrou que qualquer função periódica pode ser representada por uma série de senos e cossenos dadas pela Equação 2.18, onde A_0 é o nível médio do sinal, A_i e B_i são os coeficientes de Fourier. Graças às propriedades de ortogonalidade das funções seno e cosseno, os termos A_i e B_i da série podem ser calculados pelas Equações 2.19 e 2.20.

$$x(t) = \frac{A_0}{2} + \sum_{i=1}^{\infty} A_i \cos\left(\frac{2\pi i}{T} t\right) + \sum_{i=1}^{\infty} B_i \sin\left(\frac{2\pi i}{T} t\right) \quad (2.18)$$

$$A_i = \frac{2}{T} \int_0^T x(t) \cos\left(\frac{2\pi i}{T} t\right) dt \quad (2.19)$$

$$B_i = \frac{2}{T} \int_0^T x(t) \sin\left(\frac{2\pi i}{T} t\right) dt \quad (2.20)$$

Utilizando a notação fasorial, os termos da série de Fourier podem ser representados pela Equação 2.21.

$$x(t) = \frac{A_0}{2} + \sum_{i=1}^{\infty} C_i e^{j\left(\frac{2\pi i}{T}t + \phi_i\right)} \quad (2.21)$$

onde:

$$C_i = \sqrt{(A_i)^2 + (B_i)^2}; \quad \phi_i = \text{tg}^{-1}\left(\frac{B_i}{A_i}\right) \quad \text{e} \quad j = \sqrt{-1}$$

A representação das componentes C_i do sinal de aceleração da Figura 2.7 em função da freqüência resulta num gráfico similar àquele mostrado na Figura 2.6. Este tipo de gráfico recebe o nome de espectro em freqüência e a análise dos mesmos recebe o nome de análise espectral.

Nos casos em que o sinal não é periódico basta lembrar que o mesmo pode ser considerado como um sinal em que período T tende para infinito. Neste caso, a freqüência fundamental $1/T$ tende para zero e o espectro em freqüência que é discreto para sinais periódicos num intervalo finito torna-se contínuo, sendo a série substituída pela integral de Fourier.




Figura 2.7. Espectro da Curva de aceleração de um pistão de motor de combustão interna.

A análise espectral é provavelmente a técnica mais utilizada em Análise de Assinatura de Mecanismos (Braun, 1986), e isto ocorre devido a:

- Forte redução de dados que se consegue com a análise espectral. Por exemplo: uma função harmônica no domínio do tempo é representada por uma grande quantidade de

pontos, enquanto que no domínio da frequência, bastam apenas três informações (a magnitude do termo cosseno, a magnitude do termo seno e a frequência).

- Algumas características do mecanismo de geração do sinal são facilmente observáveis no domínio da frequência, tais como: frequências características de mecanismos, ressonâncias do sistema mecânico, faixa de frequência na qual se concentram as vibrações, modulação em amplitude, etc.
- Relações entre entrada e saída são facilmente avaliadas, ao contrário do domínio do tempo onde as relações entre entrada e saída são dependentes de uma integral de convolução.
- Equipamentos e ferramentas poderosas para apoio, tais como: geradores de sinais, filtros, analisadores espectrais, a FFT e etc.

Segundo (Duarte, 1999), a maioria das máquinas e equipamentos existentes executam movimentos com ciclo limitado, sendo alternativos ou rotativos. Com isso, o espectro de frequência das grandezas vibratórias destas máquinas e equipamentos é caracterizado por um ruído de banda larga somado a componentes discretas de amplitudes significativas, cujas frequências estão intimamente relacionadas com a cinemática do movimento de cada parte dos mecanismos, ou com as frequências naturais do sistema. Portanto, conhecendo-se as frequências com que os principais elementos de máquinas geram vibrações forçadas devido à alternância de movimentos, é possível identificar, via análise de espectro de frequência, o órgão da máquina que está com problemas.

Transformada de Hilbert

A Transformada de Hilbert de um sinal $x(t)$ de valor real no domínio do tempo é outro sinal de valor real no mesmo domínio, denotado por $\tilde{x}(t)$, tal que $z(t) = x(t) + j\tilde{x}(t)$ é um sinal analítico. Sabendo-se que o sinal analítico é um sinal complexo com a parte imaginária sendo a Transformada de Hilbert da parte real, o mesmo pode ser definido pela Equação 2.10.

$$z(t) = 2 \frac{1}{\sqrt{2\pi}} \int_0^{\infty} \hat{X}(f) e^{j\omega t} df \quad (2.10)$$

Com:

$$\hat{X}(f) = \begin{cases} 0 & p / X(-f) \\ 2 \cdot X(f) & p / X(f) \end{cases} \quad (2.11)$$

Onde $X(f)$ é o espectro de $x(t)$, ou seja:

$$X(f) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x(t) e^{jft} dt \quad (2.12)$$

A partir disso, pode-se obter a forma explícita de $z(t)$ em termos do sinal real $x(t)$, como verificado na Equação 2.13. (Cohen, 1995)

$$z(t) = \frac{1}{\pi} \int_0^{\infty} \int_{-\infty}^{\infty} x(t') e^{jf(t-t')} dt' df \quad (2.13)$$

Onde $\int_{-\infty}^{\infty} e^{jft} df = \pi \delta(t) + \frac{j}{t}$, que substituída na Equação 2.14, resulta em:

$$z(t) = x(t) + \frac{j}{\pi} \int_{-\infty}^{\infty} \frac{x(t')}{t-t'} dt' \quad (2.14)$$

Sendo assim, a Transformada de Hilbert é definida pela Equação 2.15.

$$\tilde{x}(t) = H\{x(t)\} = \int_{-\infty}^{\infty} \frac{x(t')}{\pi(t-t')} dt' \quad (2.15)$$

Onde $\tilde{x}(t)$ é a integral de convolução de $x(t)$ e $\frac{1}{\pi t}$, dada pela Equação 2.16.

$$\tilde{x}(t) = x(t) \otimes \left(\frac{1}{\pi t} \right) \quad (2.16)$$

Vale lembrar que \otimes representa convolução

O módulo do sinal analítico, que é uma ferramenta de deconvolução, é bastante utilizado para o monitoramento de mancais de rolamento, quer seja para a identificação do tipo de falha (Mancuzo, 1999), quer seja para a determinação de valores limites para sintoma (Pereira e Barbosa, 2004).

Método do Cepstrum

Segundo Randall (1987), a definição mais utilizada, atualmente, para o cepstrum é o inverso da Transformada de Fourier do logaritmo do espectro de potência. A escala logarítmica da amplitude enfatiza a estrutura harmônica do espectro e reduz a influência de qualquer caminho de transmissão aleatória, pelo qual o sinal vai do ponto de geração ao ponto de medição. O que define o cepstrum não é o de ser o espectro do espectro, mas sim, a conversão logarítmica do espectro original. O cepstrum pode ser representado pela Equação 2.17.

$$C(t) = \left| \Im \{ \log F_{xx}(f) \} \right|^2 \quad (2.17)$$

O cepstrum possui a característica de agrupar famílias de bandas laterais em um único componente, tendo a propriedade de detectar a periodicidade do espectro, a qual pode ser causada pela modulação de um sinal em amplitude ou mesmo em frequência.

Outra grande vantagem do cepstrum é que por ser um excelente detector de ecos (Braun, 1986), o mesmo tem pouca sensibilidade com respeito ao caminho de transmissão do sinal. Pequenas mudanças no posicionamento de um acelerômetro podem ter grande influência na função de transferência, e conseqüentemente, pode mascarar completamente o nível do sinal em uma dada frequência específica. Por outro lado, a componente cepstral de uma família de bandas laterais é uma média de todas as suas componentes, portanto muito menos afetada por modificações localizadas.

Defeitos típicos em engrenagens e engrenamento são caracterizados por um espectro composto pelas frequências de engrenamento (e suas harmônicas) em conjunto com uma família de bandas laterais, provenientes de modulações de amplitude e frequência devido à pequenas variações na linha de contato do engrenamento, os quais ocorrem quer devido às tolerâncias inerentes ao processo de fabricação e montagem, ou devido às deflexões dos dentes das engrenagens em função dos esforços mecânicos que ocorrem durante o engrenamento (Barreto, 2003). O cepstrum é uma boa ferramenta para identificar em qual engrenagem ocorreu o defeito (Duarte, 1999).

Análise de Ordem

A análise de ordem pode ser utilizada para se estudar, projetar e monitorar máquinas rotativas. Através da medição e análise dos sinais de vibração e ruído gerado por um sistema com componentes rotativos, pode-se adquirir um melhor conhecimento do sistema, associar as características vibro-acústicas com os aspectos físicos do sistema, e identificar as características que mudam com o tempo e com as condições de operação.

A análise de ordem e a análise harmônica têm muito em comum, em que o termo harmônico refere-se à frequências que são múltiplos inteiros ou fracionários de uma frequência fundamental.

Em muitas indústrias, os harmônicos relacionados com a velocidade de rotação são tratados como ordens. O harmônico na mesma frequência da velocidade de rotação é taxado como de primeira ordem, o harmônico referente a duas vezes a frequência de rotação é por sua vez de segunda ordem, e assim sucessivamente. Portanto, pode-se dizer que a análise de ordem é uma aplicação da análise harmônica para máquinas rotativas.

Alguns casos podem ser estudados através de análise de ordem, onde se pode observar as seguintes relações:

- Desbalanceamento resulta em um pico de espectro na primeira ordem;
- Desalinhamento ou empenamento de eixo gera uma grande componente de segunda ordem;
- Rodopio (oil whirl) proporciona componentes de ordens fortemente fracionárias;
- Engrenagens, correias, e pás aumentam as componentes de ordens mais altas.

A Figura 2.8 mostra o espectro de ordem de um sinal de vibração medido para um ventilador com sete pás e quatro aletas direcionadoras de fluxo.




Figura 2.8. Espectro de Ordem de um ventilador com sete pás e quatro aletas direcionadoras de fluxo.

O sinal de vibração mostrado na Figura 2.8 contém componentes de alta energia vibratória de quarta e de sétima ordens, respectivamente. As componentes de quarta e sétima ordens tratam-se dos produtos entre as quatro aletas da voluta e a frequência de rotação do eixo e

entre as sete pás do ventilador e a frequência de rotação do eixo, respectivamente. Um objetivo importante de análise de ordem é descobrir informações sobre as ordens que podem se mascarar no espectro de potência devido a mudança de rotação. As ordens que estão escondidas no espectro de potência podem apresentar características distintas no mapa espectral velocidade de rotação-freqüência. Tal fato serve como ponto de partida para descobrir informações sobre as ordens que são difíceis de se ver no espectro de potência.

A técnica básica da análise de ordem envolve a obtenção instantânea da velocidade de rotação do eixo da máquina, adquirida utilizando um tacômetro ou encoder. Esta velocidade está relacionada com o sinal de vibração e ruído produzido pela máquina para se obter informações sobre as componentes de ordem relacionadas a determinados defeitos.

Técnica do Envelope

Quando se efetua uma medição em uma máquina, geralmente, vários de seus componentes ou vizinhos podem estar gerando ruídos ao mesmo tempo. Estes são normalmente em baixas freqüências, com um grande conteúdo de energia, e acabam encobrendo o sinal de falha no estágio inicial do rolamento, tornando praticamente impossível realizar um diagnóstico do espectro direto (Büchner, 2001). A este fenômeno dá-se o nome de mascaramento, o qual se trata de uma baixa relação entre o sinal e o ruído. Sendo assim, utiliza-se a técnica do envelope para solucionar casos como este.

Folgas excessivas e falhas iniciais em componentes de máquinas produzem uma série de impactos, os quais são equivalentes à uma excitação do tipo impulsiva, a qual atua sobre a estrutura, ou seja, a máquina é excitada em suas freqüências naturais. Matematicamente, diz-se que a freqüência de excitação é modulada pelas freqüências naturais da máquina. Como estes impactos são, em geral, de curta duração, contêm uma taxa muito alta de energia que é distribuída em todo o espectro de freqüências. Uma vez que nas médias e baixas freqüências, o espectro de vibração das máquinas encontra-se repleto de componentes, o efeito desses impactos é melhor visualizado nas ressonâncias de freqüências mais altas, em especial no caso de falhas em mancais de rolamentos, os quais têm rigidez muito elevada.

A técnica de envelope é um conceito aplicado mais precisamente na parte de transmissão e recepção de dados. Um sinal em alta freqüência, taxado de Portador, é utilizado para transportar o sinal de um ponto para outro. O sinal de interesse é rotulado como Modulador, uma vez que, como o próprio nome diz, é modulado pelo sinal portador. Assim, o processo de modulação é definido como sendo um sinal de alta freqüência modulando um outro de baixa freqüência.

O processo de demodulação nada mais é do que separar os dois sinais. O objetivo, portanto, é decodificar o sinal recebido encontrando o sinal modulador, que na verdade, é o próprio sinal do defeito. Na Figura 2.9 é ilustrado o envelope de um sinal.




Figura 2.9. Envelope de um sinal para efeito de exemplo.

Uma das técnicas de análise de envelope envolve os seguintes passos:

- O sinal é adquirido no domínio do tempo;
- Aplica-se a Transformada Rápida de Fourier no sinal, passando-o para o domínio da frequência. Com base neste espectro, verifica-se em qual ressonância houve alteração significativa;
- Realiza-se a filtragem do sinal, aplicando-se um filtro passa banda, o qual pode variar de 3 a 24 % em torno da ressonância escolhida. Deve-se observar que o espectro da assinatura é necessário para a verificação de tal alteração;
- O sinal é, então, filtrado na região de frequência de interesse;
- Obtém-se o sinal analítico via Transformada de Hilbert.
- Calcula-se o espectro do módulo do sinal analítico, para fins de análise.

2.2. Identificação da Origem das Vibrações

Tendo-se observado que os níveis de vibração de uma máquina ultrapassaram os valores considerados normais para aquele tipo de equipamento, torna-se necessário identificar qual é o órgão da máquina que se encontra falhando, para que se planeje a intervenção de forma a reduzir ao mínimo, tanto o tempo de parada da máquina quanto o risco de quebra posterior inerente em toda intervenção.

Os diagnósticos para fins de manutenção das máquinas, com o objetivo de identificar as possíveis causas das vibrações são obtidos separando-se as harmônicas do sinal global e associando-as com os elementos defeituosos ou desvios de montagem (Tebchirani, 2003).

Dentre as diversas fontes de vibração, aquelas mais comuns e que, portanto podem ser responsabilizadas pela quase totalidade das vibrações mecânicas indesejáveis são:

- Desequilíbrio de massas girantes (desbalanceamento);
- Desalinhamento de eixos, correias e correntes;
- Folgas generalizadas e bases soltas;
- Dentes de engrenagens;
- Rolamentos.
- Corrente elétrica;
- Campo magnético desequilibrado (motores elétricos);
- Outros.

A seguir, serão apresentados alguns casos de fontes de vibração.

Desbalanceamento

O desbalanceamento de massa é uma fonte comum de vibração em máquinas e equipamentos, e sua consequência é um aumento de amplitude na frequência de rotação da máquina (1 x rpm). Essa amplitude é proporcional à quantidade de desbalanceamento presente.

Este tipo de defeito ocorre devido à uma alteração no equilíbrio das forças radiais que atuam sobre o eixo da máquina. A causa mais comum é o acúmulo de material sobre volantes de inércia, hélices de ventiladores, hélices de ventoinhas de motores, e outros, mas pode ser causado também por perda de massa, como a quebra de uma hélice, por exemplo.

Desalinhamento ou Empenamento

O desalinhamento é um problema mais freqüente que o desbalanceamento, uma vez que o número de variáveis as quais podem causar um desalinhamento é maior do que no caso de desbalanceamento. Falhas de montagem, defeitos na base, parafusos de fixação folgados, e outros, são exemplos de tal anomalia.

Mesmo com acoplamentos flexíveis, o desalinhamento resulta em duas forças, axial e radial, mesmo quando estiver dentro dos limites de flexibilidade do acoplamento. As frequências que caracterizam este defeito são a de rotação do eixo, o segundo harmônico, o terceiro e possivelmente o quarto harmônico.

Rodopio (Oil Whirl)

O rodopio é um tipo de defeito que pode ocorrer em máquinas de altas velocidades, como turbomáquinas, por exemplo, devido à falhas de projeto, lubrificação ou desgaste de mancais hidrodinâmicos. A frequência característica desta falha é um pouco menor (entre 42 e 48 %) do que a metade da velocidade do eixo (Angelo, 1987).

Aumento da turbulência em Rotores

Este defeito ocorre na frequência da passagem de pás de aletas (número de pás x rpm) e harmônicos superiores.

Correias

Problemas com correias resultam no aumento dos harmônicos na frequência de rotação 1 rpm, 2 rpm, 3 rpm e 4 rpm.

Engrenagens

As frequências típicas dos sistemas de engrenagens são as frequências de engrenamento, as quais são resultantes do produto da frequência de rotação do eixo pelo número de dentes da engrenagem.

O primeiro indício de anormalidade é a presença de harmônicos do engrenamento. É normal que a componente de engrenamento apresente algumas bandas laterais em configuração simétrica de amplitude e espaçamento, sendo que qualquer desvio na simetria desta configuração é indício de início de problemas nas engrenagens. O espaçamento entre as bandas laterais é igual à frequência de rotação da engrenagem. Se houver variação entre este espaçamento isto indica folga excessiva entre as engrenagens (back slash). Se houver variação nas amplitudes das bandas laterais isto indica dente quebrado (Barreto, 2003).

Folgas Mecânicas

As folgas mecânicas causam vibrações no sistema geralmente na frequência de rotação da máquina e várias harmônicas, sendo mais evidente na direção radial e sentido vertical.

Estas vibrações são muitas vezes geradas por parafusos frouxos, folgas excessivas nos mancais ou talvez uma trinca na estrutura ou nos pedestais de mancais.

A vibração característica de folga mecânica não ocorre sem que haja outras forças excitando o sistema, tais como desalinhamentos e desbalanceamentos.

Vibração Induzida Eletricamente

As principais causas de vibração induzida eletricamente em motores de indução trifásicos, são decorrentes de:

- Enrolamento do secundário do motor desbalanceado, irregularidades ainda no secundário como contatos frouxos, escovas rompidas e reostato defeituoso;
- Rompimento da caixa de suporte ou das barras;
- Entreferro não uniforme seja devido a rolamentos gastos, excentricidade estática ou mesmo desbalanceamento magnético;
- Fonte elétrica de energia, desbalanceada.

As vibrações induzidas eletricamente ocorrem para frequências iguais à de rotação do motor (1 rpm) , uma e duas vezes a frequência síncrona. Se os níveis de vibração diminuírem instantaneamente ao se desligar a energia, a causa é elétrica.

Rolamentos

Como qualquer peça ou componente, os rolamentos apresentam deterioração com o uso, sendo inevitável o desgaste. Entretanto, um rolamento pode apresentar falha prematura por uma série de razões (Nepomuceno, 1989). Dentre as diversas falhas, em rolamentos, pode-se destacar:

- Lubrificação inadequada: escassez de lubrificante, perda das propriedades do mesmo, ou lubrificante inadequado, permite o contato entre os componentes do rolamento.
- Montagem incorreta: pressão para montagem no anel inadequada, deslocamento excessivo em assento cônico e sobrecarga enquanto o rolamento não gira.
- Retentores inadequados: retentores que permitem a passagem de partículas para dentro do rolamento ou que se deterioram e contaminam o rolamento.
- Desalinhamento: rolamentos martelados em seu assento, corpos estranhos entre o anel e o assento, eixo torto ou envergado.
- Passagem de corrente elétrica: para que este tipo de dano ocorra, não é necessária uma diferença de potencial muito grande entre as pistas e os elementos girantes dos rolamentos.

- Vibrações externas: rolamentos quando parados são submetidos a vibrações vindas de outros sistemas.
- Defeitos de fabricação: defeitos provenientes de processos de fabricação nas pistas, esferas ou gaiolas de rolamentos.
- Fadiga: proveniente do rolamento de um elemento sobre outro após um certo número de ciclos.

Quando uma superfície defeituosa de um elemento do rolamento entra em contato com outra superfície do rolamento, este choque produz um impulso que excita ressonâncias no rolamento e na máquina. Estes impulsos irão ocorrer periodicamente com uma frequência que é determinada, unicamente, pela localização do defeito, sendo ele na pista interna, externa ou no elemento girante (Bezerra, apud MacFadden, 2004).

Na Figura 2.10 estão indicadas as dimensões do rolamento utilizadas para calcular as frequências características de seus elementos. Também são mostrados o ângulo de contato e as frequências características típicas.




Figura 2.10. Frequências, Dimensões e Ângulo de contato do rolamento

Na figura têm-se:

D é o diâmetro da esfera;

d é o diâmetro primitivo;

d_{pi} é o diâmetro da pista interna;

d_{pe} é o diâmetro da pista externa;

β é o ângulo de contato.

N_e é o número de esferas.

Para o caso em que a pista externa permanece estacionária, ou seja $f_{pe} = 0$, as frequências típicas do rolamento são calculadas pelas equações de Equação 2.21 a 2.24.

A Equação 2.21 representa a frequência característica de defeito na gaiola do rolamento.

$$f_g = \frac{f_{pi}}{2} \left(1 - \frac{D \cos \beta}{d} \right) \quad (2.21)$$

A frequência característica de defeito na pista interna do rolamento pode ser determinada pela Equação 2.22.

$$f_{dpi} = -\frac{N_c f_{pi}}{2d} \left(1 + \frac{D \cos \beta}{d} \right) \quad (2.22)$$

A Equação 2.23 representa a frequência característica de defeito na pista externa do rolamento.

$$f_{dpe} = \frac{N_c f_{pi}}{2d} \left(1 - \frac{D \cos \beta}{d} \right) \quad (2.23)$$

A frequência característica de defeito na esfera do rolamento pode ser determinada pela Equação 2.24.

$$f_{de} = \frac{df_{pi}}{2D} \left(1 - \frac{D^2 \cos^2 \beta}{d^2} \right) \quad (2.24)$$

2.3. Determinação dos Níveis de Referência via Critérios de Severidade

Há uma grande variedade de especificações (ISO, ANSI, BSI, DIN, VDI, JIS) que classifica o nível de qualidade de máquinas e equipamentos em função do nível global de vibrações. Estas especificações podem ser utilizadas como valores de referência, normal, para o monitoramento periódico dos níveis de vibração, visando a manutenção preditiva. Para uma determinada máquina, existe um consenso geral segundo o qual o nível de segurança deve ser estabelecido entre duas a três vezes (de 6 a 10 dB) o nível de vibração considerado normal (Bruel & Kjaer, 1982).

Neste trabalho, dar-se-á uma maior ênfase para as vibrações advindas de rolamentos e motores elétricos. Tal saliência deve-se ao fato de a bancada experimental ser composta

principalmente por um eixo, apoiado em mancais de rolamentos de esferas, movido por um motor elétrico trifásico.

Níveis de Referência para Motores elétricos

Existem diversos sistemas para se determinar a classificar o nível de vibração permissível em motores elétricos. Contudo, esses sistemas não são padronizados, em que algumas normas tomam por referência a medição das amplitudes de deslocamento pico a pico, outros utilizam como base o nível RMS ou a análise das amplitudes das velocidades de vibração.

A norma ISO 2373, a qual é uma adaptação especial da norma ISO 2372, aplica-se a motores trifásicos de corrente alternada e a motores de corrente contínua, com altura do eixo (distância vertical entre a base do motor e a linha de centro de seu eixo) entre 80 e 400 mm e que operam dentro da faixa de 10 a 1000 Hz. A norma adota como critério para determinação da severidade de vibração, o valor RMS da amplitude de velocidade para vários tamanhos de motores (Duarte, 1998).

Na Tabela 2.1 são apresentados os limites recomendados de severidade de vibração para os motores elétricos.

Tabela 2.1. Limites recomendados de severidade de vibração para os motores elétricos.

Nível de Qualidade	Rotação RPM	Amplitude de Velocidade (Máximos Valores RMS)		
		80 < h < 132 (mm) mm/s	132 < h < 225 (mm) mm/s	225 < h < 400 (mm) mm/s
N (normal)	600 a 3600	1.80	2.80	4.50
	600 a 1800	0.71	1.12	1.80
R (reduzida)	> 1800 a 3600	1.12	1.80	2.80
	600 a 1800	0.45	0.71	1.12
S (especial)	> 1800 a 3600	0.71	1.12	1.80

Níveis de Referência para Rolamentos

Pereira e Barbosa (2004) desenvolveram um trabalho o qual identifica os estágios de falha em rolamentos. As informações a seguir foram tiradas de tal artigo publicado da SKF Condition Monitoring (www.vibra.dynamiczone.com).

Os autores propõem que um rolamento no *primeiro estágio* ainda é um “bom” rolamento. Porém, depois de uma parcela significativa da vida do rolamento, microcavidades resultam na degeneração do mesmo até o ponto onde cavidades muito pequenas se desenvolvem nas pistas. Estes pequenos defeitos nem sempre sofrem impactos com força suficiente para gerar sinais de vibração mensurável no domínio de velocidade.

Um rolamento no *estágio dois* já se encontra com algum dano, o qual pode ser observado em seus harmônicos. Não há nenhuma razão para se trocar um rolamento neste ponto. De fato, foram retirados rolamentos nesta fase e o único dano aparente são diminutas descamações nas pistas. No entanto, na medida em que os harmônicos aumentam em amplitude, torna-se prudente aumentar a frequência de coleta de dados. A degradação do rolamento é normalmente linear por um período de tempo e pode ser acompanhada em um gráfico de tendência, mas com o encurtamento da vida em serviço, tal degradação torna-se não linear.

Na *fase três*, o rolamento está chegando ao estado terminal. Os espectros de FFT mostram a frequência fundamental de defeito e os harmônicos começarão freqüentemente a indicar bandas laterais do rolamento na velocidade de rotação do eixo. Isto é particularmente verdade para a Frequência de Passagem de Esfera na Pista Interna, onde o defeito passa através da zona de carga do rolamento. A vibração aumenta com a passagem através do defeito na zona de carga e o sinal é modulado, produzindo as bandas laterais da rotação. O sinal da Frequência de Passagem de Esfera na Pista Externa, geralmente tem carregamento constante do rolamento até que a amplitude das folgas do mesmo, desbalanceamento, desalinhamento ou flexão do eixo modulem o sinal de defeito resultando freqüentemente em bandas laterais na velocidade de rotação. No *estágio quatro*, a vida de serviço é extremamente curta e requer ação corretiva imediata. Tal estágio é caracterizado freqüentemente no domínio espectral da velocidade ou aceleração como amplitudes “monte de feno” (ruído de banda larga) na região de defeito do rolamento. Nos espectros de envelope de aceleração aparecerão componentes de frequência de defeito com altas amplitudes, como também bandas laterais de velocidade 1x, 2x (indicando folgas) sobre a Frequência de Passagem de Esfera na Pista Externa e no caso extremo, aparecerão freqüentemente componentes de defeitos de gaiola.

Os níveis globais de vibração em envelope de aceleração são mais relativos do que absolutos, devido ao fato de critérios de alarme dependerem de variáveis como velocidade, carregamento dinâmico, e sinal de transmissão da estrutura. Em geral, o método indicado para definir os tais níveis, é usar alarmes estatísticos que são determinados por tendências históricas de leituras globais. Estes métodos assumem que as variáveis são constantes e as medidas são específicas para os mesmos locais na máquina. Usuários experientes ajustam o alarme de alerta para mais ou menos 2x o desvio padrão e alarme de perigo para mais ou

menos 3x o desvio padrão. Uma outra opção é utilizar dados estatísticos de grandes conjuntos de máquina para a definição dos limites de alerta e alarme (Cempel, 1989).

Existe uma quantidade razoável de dados históricos, derivados de métodos de envelope semelhantes que sugerem a Tabela 2.2 (Pereira e Barbosa, 2004) como uma diretriz para níveis pico a pico G (envelope de aceleração).

Tabela 2.2. Níveis Pico a pico de envelope de aceleração, em bandas de frequências para classificação do estado do rolamento.

Estado (G)	Filtros de Bandas do Microlog			
	Banda I (5-100 Hz)	Banda II (50-1000 Hz)	Banda III (0,5-10 KHz)	Banda IV (5-40 KHz)
Bom	0 – 2 ($\times 10^{-3}$)	0 – 20 ($\times 10^{-3}$)	0 – 0.4	0 – 1,5
Satisfatório	2-10 ($\times 10^{-3}$)	20-200 ($\times 10^{-3}$)	0,4 – 4	1,5-15
Insatisfatório	10-50 ($\times 10^{-3}$)	200-500 ($\times 10^{-3}$)	4-10	15-75
Inaceitável	50 + ($\times 10^{-3}$)	500 + ($\times 10^{-3}$)	0-2	75+

Capítulo III

Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) foram desenvolvidas na década de 40, pelo neurologista McCulloch e pelo matemático Walter Pitts (1943), os quais fizeram uma analogia entre os neurônios do cérebro e o processo eletrônico.

O final da década de 80 marcou o ressurgimento da área das RNAs, também conhecida como *conexionismo* ou sistemas de processamento paralelo e distribuído. Esta forma de computação não algorítmica é caracterizada por sistemas que, em algum nível, relembram a estrutura do cérebro humano.

As RNAs são sistemas paralelos distribuídos compostos por unidades de processamento simples (nodos) que computam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. O funcionamento dessas redes é baseado em uma estrutura física concebida pela natureza: o cérebro humano.

Em RNAs, o procedimento usual na solução de problemas passa inicialmente por uma fase de aprendizagem, onde um conjunto de exemplos é apresentado para a rede, a qual extrai automaticamente as características necessárias para representar a informação fornecida. Essas características são utilizadas posteriormente para gerar respostas para o problema.

A capacidade de aprender através de exemplos e de generalizar a informação aprendida são, sem dúvida, os atrativos principais da solução de problemas através das RNAs. Não obstante, estas são capazes de atuar como mapeadores universais de funções multi-variáveis, com custo computacional que cresce apenas linearmente com o número de variáveis. Outras características importantes são a capacidade de auto-organização e de processamento temporal que fazem das redes neurais uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos.

3.1. Redes Biológicas

O cérebro humano é responsável pelo que se chama de emoção, pensamento, percepção e cognição, assim como pela execução de funções senso-motoras e autônomas. Além disso, sua rede de nodos tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar

conhecimento por experiência, além de interpretar observações. Apesar do estudo contínuo, não se sabe ao certo a forma como as funções cerebrais são realizadas, utilizando-se até o momento, apenas modelos. No entanto, a estrutura fisiológica básica destas redes de nodos naturais é conhecida e é exatamente nesta estrutura fisiológica que se baseiam as RNAs. Essas tentam reproduzir as funções das redes biológicas, buscando implementar seu comportamento básico e sua dinâmica.

3.1.1. Neurônios Biológicos

O neurônio biológico é a unidade celular fundamental do sistema nervoso do cérebro humano. Os nodos são divididos em três seções: o corpo da célula, os dendritos e o axônio, cada um com funções específicas, porém complementares. Os dendritos têm por função receber as informações, impulsos nervosos, oriundas de outros nodos e conduzi-las até o corpo celular. Ali, a informação é processada e novos impulsos são gerados. Estes impulsos são transmitidos a outros nodos, passando através do axônio até os dendritos dos nodos seguintes (Braga, Carvalho e Ludermir, 1998).

Uma vez captado o estímulo nas terminações nervosas, ele é transmitido em um impulso elétrico. Esse potencial em ação (impulso), percorre o axônio e atinge outras células. Os neurônios proporcionam um fluxo preciso das informações. Um forte (fraco) potencial em ação entre os contatos sinápticos, que ocorrem no núcleo ou soma de um neurônio, estimula um fluido neurotransmissor a produzir uma carga elétrica que acelera (retarda) o fluxo das informações a outros dendritos de milhares de neurônios. Quando existem fortes combinações sinápticas, diz-se que as condutâncias ou impedâncias das cargas elétricas estão ajustadas, o que permite ao cérebro aprender e armazenar as informações processadas.

3.2. Neurônios Artificiais

McCulloch e Pitts (1943) desenvolveram um modelo matemático análogo ao neurônio biológico, denominado neurônio artificial McCulloch-Pitts (modelo MCP), que possui múltiplas entradas (x_1, x_2, \dots, x_n) e uma única saída (y), onde cada uma das entradas possui um peso associado (w_1, w_2, \dots, w_n).

O neurônio artificial possui duas fases de processamento. Na primeira fase, calcula-se o somatório do produto das entradas pelos pesos associados. Na segunda fase, é atribuída uma função não linear, chamada de função de ativação, a qual é aplicada ao somatório resultante da primeira fase.

Na descrição original do modelo MCP, a função de ativação é dada pela função de limiar descrita na Equação 3.1. O nodo MCP terá então sua saída ativa quando:

$$\sum_{i=1}^n x_i w_i \geq \theta \quad (3.1)$$

onde n é o número de entradas do neurônio, w_i é o peso associado à entrada x_i e θ é o limiar do neurônio.

A Figura 3.1 representa o modelo McCulloch-Pitts.




Figura 3.1. Neurônio de McCulloch e Pitts.

3.3. Funções de Ativação

A partir do modelo proposto por McCulloch e Pitts foram derivados vários outros modelos que permitem a produção de uma saída qualquer, não necessariamente zero ou um, e com diferentes funções de ativação. Em nível de exemplo, a Figura 3.2 representa graficamente quatro funções de ativação diferentes, sendo elas: função linear, função rampa, função degrau (step) e função sigmoideal.




Figura 3.2. Algumas Funções de Ativação utilizadas em redes neurais artificiais

A função de ativação linear na Figura 3.2a é definida pela Equação 3.2.

$$y = \alpha x \quad (3.2)$$

Onde α é um número real que define a saída linear para os valores de entrada, y é a saída e x a entrada.

A função linear pode ser restringida para produzir valores constantes em uma faixa $[-\gamma, +\gamma]$, e neste caso a função passa a ser a função rampa como mostrada graficamente na Figura 3.2b e definida pela Equação 3.3.

$$y = \begin{cases} +\gamma & \text{se } x \geq +\gamma \\ x & \text{se } |x| < +\gamma \\ -\gamma & \text{se } x \leq -\gamma \end{cases} \quad (3.3)$$

Os valores máximo e mínimo da saída são $+\gamma$ e $-\gamma$, respectivamente. A função rampa é geralmente usada como uma função não linear simplificada.

A função degrau, apresentada na Figura 3.2c produz a saída $+\gamma$ para os valores de x maiores que zero, caso contrário a função produz o valor $-\gamma$. A função degrau é definida pela Equação 3.4.

$$y = \begin{cases} +\gamma & \text{se } x > 0 \\ -\gamma & \text{se } x \leq 0 \end{cases} \quad (3.4)$$

A função sigmoidal, conhecida também como S-shape, mostrada na Figura 3.3d, é uma função semilinear, limitada e monotônica. É possível definir várias funções sigmoidais. Uma das mais importantes delas é a função logística representada pela Equação 3.5.

$$y = \frac{1}{1 + e^{-x/T_{\text{sig}}}} \quad (3.5)$$

Onde o parâmetro T_{sig} determina a suavidade da curva.

3.4. Arquitetura das Redes Neurais

Uma rede neural consiste em um sistema de processamento de dados, com muitos neurônios artificiais interconectados e organizados em seqüências de camadas. Este arranjo entre camadas de neurônios configura a arquitetura de uma rede neural artificial, inspirado na estrutura cerebral do córtex. As camadas de uma rede são interconectadas através de parâmetros internos denominados pesos (w). A camada de entrada somente apresenta os dados à rede neural, não tendo neurônios de processamentos e a camada de saída resulta nos valores de saída da rede. As outras camadas são chamadas de intermediárias ou ocultas. A Figura 3.3 representa uma rede cuja arquitetura é composta por uma camada de entrada com dois neurônios, uma de saída com um neurônio e uma oculta com quatro neurônios.




Figura 3.3. Arquitetura típica de redes neurais artificiais.

3.4.1. Nós de conexão tipo feedforward

Quando a rede neural não apresenta em sua arquitetura interconexões entre os neurônios de uma mesma camada ou interconexão de realimentação com neurônios de camadas anteriores, e é caracterizada por um fluxo unidirecional, recebe o nome de rede neural feedforward. Neste caso, o vetor de entradas é aplicado à camada de entrada e as funções de ativação são rapidamente calculadas, com o processo fluindo, posteriormente, da camada de entrada para a oculta e desta para a camada de saída. Tal arquitetura pode ser verificada na Figura 3.4.




Figura 3.4. Exemplo de arquitetura da rede neural feedforward

3.4.2. Nós de conexão tipo feedback

Quando a rede neural apresenta arquitetura com conexões de realimentações, tanto entre neurônios de uma mesma camada como entre neurônios de camadas anteriores, recebe o nome de feedback. O processo de obtenção das operações matemáticas para saídas é mais complexo, porém após o treinamento as saídas são calculadas instantaneamente. Uma rede realimentada é chamada de recorrente, cujo exemplo está ilustrado na Figura 3.5. São exemplos de redes recorrentes as redes de Hopfield (1982) e Kohonen (1984), as quais apresentam uma realimentação após a propagação, o que favorece o treinamento. Deste modo, a rede é treinada com propagações e realimentações, até que haja um equilíbrio entre as entradas, os pesos e as saídas ou algum critério de convergência seja atingido.




Figura 3.5. Exemplo de arquitetura da rede neural feedback

3.5. Aprendizado das Redes Neurais Artificiais

As redes neurais artificiais possuem a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprendem. Um conjunto de procedimentos bem definidos para adaptar os parâmetros de uma RNA para que a mesma possa aprender uma determinada função é chamado de algoritmo de aprendizado. O que se tem é um conjunto de ferramentas representadas por diversos algoritmos, cada qual com suas vantagens e desvantagens. Esses algoritmos basicamente diferem pela maneira através da qual o ajuste dos pesos é feito.

A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando.

Diversos métodos para treinamento de redes foram desenvolvidos, podendo estes ser agrupados em dois paradigmas principais: Aprendizado Supervisionado e Aprendizado Não Supervisionado. Outros dois paradigmas bastante conhecidos são os de Aprendizado por Reforço e Aprendizado por Competição.

3.5.1. Aprendizado Supervisionado

Este método de aprendizado é supervisionado porque a entrada e saída desejadas para a rede são fornecidas por um supervisor (professor) externo. O objetivo é ajustar os parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos. O professor indica explicitamente um comportamento bom ou ruim para a rede, visando direcionar o processo de treinamento. A rede tem uma saída corrente (calculada) comparada com a saída desejada, recebendo informações do supervisor sobre o erro da resposta atual. A cada padrão de entrada submetido à rede, compara-se a resposta desejada com a resposta calculada, e ajustando-se os pesos das conexões para minimizar o erro. A minimização da diferença é incremental, já que pequenos ajustes são feitos nos pesos à cada etapa de treinamento, de tal forma que estes caminhem, se possível, para uma solução. A soma dos erros médios quadráticos de todas as saídas é normalmente utilizada com medida de desempenho da rede e também como função de custo a ser minimizada pelo algoritmo de treinamento.

A desvantagem do aprendizado supervisionado é que, na ausência do professor, a rede não conseguirá aprender novas estratégias para situações não cobertas pelos exemplos do treinamento da rede. Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta e a sua generalização para redes de múltiplas camadas, o algoritmo backpropagation (Braga, Carvalho e Ludermir, 1998).

Esse aprendizado pode ser implementado basicamente de duas formas: off-line e on-line. Para aquele, os dados do conjunto de treinamento não mudam, sendo que uma vez obtida uma solução para a rede, esta deve permanecer fixa. Caso novos dados sejam adicionados ao conjunto de treinamento, novo treinamento, envolvendo também os dados anteriores, deve ser realizado para se evitar inferência no treinamento anterior. Por sua vez, no aprendizado on-line, o conjunto de dados muda continuamente, sendo que a rede deve estar em contínuo processo de adaptação.

3.5.2. Aprendizado Não Supervisionado

Neste aprendizado, como o próprio nome sugere, não há um professor ou supervisor para acompanhar o processo de aprendizado. Para esses algoritmos, somente os padrões de entrada estão disponíveis para a rede, ao contrário do supervisionado, cujo conjunto de treinamento possui pares de entrada e saída. A partir do momento em que a rede estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se nela uma habilidade de formar representações internas para codificar características da entrada e criar novas classes ou grupos automaticamente. Este tipo de aprendizado só é possível se houver redundância nos dados de entrada, pois, caso contrário, seria impossível encontrar quaisquer padrões ou características dos dados de entrada.

O Aprendizado Hebbiano, o Modelo de Linsker, a Regra de Oja e a Regra de Yuille são exemplos de aprendizado não supervisionado, os quais não serão detalhados neste trabalho, uma vez que não foram utilizados como ferramentas de análise.

3.5.3. Aprendizado por Reforço

No aprendizado por reforço, o qual é um caso particular de aprendizado supervisionado, a única informação de realimentação fornecida à rede é se uma determinada saída está correta ou não, isto é, não é fornecida à rede a resposta correta para o padrão de entrada.

Este aprendizado é uma forma de aprendizado on-line obtido por um mapeamento de entrada-saída através de um processo de triagem e erro desenvolvido para maximizar o índice de desempenho escalar chamado de sinal de reforço.

O paradigma de aprendizagem por reforço pode ter:

- Aprendizagem Associativa: o meio fornece outras informações além do reforço e um mapeamento, na forma estímulo-ação, deve ser aprendido.

- **Aprendizagem Não Associativa:** o sinal de reforço é a única entrada que o sistema recebe do meio. O sistema seleciona uma única ação ótima, ao invés de associar diferentes ações com diferentes estímulos.

3.6. Rede Neural Probabilística (PNN)

Dos vários modelos de redes neurais artificiais será apresentado, neste trabalho, apenas a Rede Neural Probabilística, pois foi uma das ferramentas utilizadas no mesmo para o desenvolvimento do procedimento de monitoração em tempo real da qualidade do sinal medido.

O algoritmo padrão para as Redes PNN foi baseado na teoria dos Classificadores Bayesianos (desenvolvido nos anos 50) e descrito por Meisel em 1972. Este algoritmo leva em consideração a probabilidade relativa dos eventos ocorridos e usa esta informação para predição. As PNN também utilizam os conceitos de Estimadores Parzen, que foram desenvolvidos para construir as funções densidade de probabilidade requeridas pela teoria Bayesiana (Masters, 1995).

Apesar de ser uma ferramenta extremamente poderosa, o algoritmo permaneceu no esquecimento em função das exigências de elevado processamento computacional. Entretanto, Specht (1990) mostrou que o algoritmo poderia ser implementado na forma de rede neural, bastando para isso, que fosse dividido em vários componentes individuais (neurônios ou processadores) para operação em paralelo. É esta capacidade de operação em paralelo que permite a associação do algoritmo de Meisel (1972) à uma rede neural, pois a grosso modo, as PNN operam segundo conceitos consolidados da estatística tradicional (Masters, 1995).

A PNN é intrinsecamente um algoritmo projetado para executar tarefas de classificação, sendo treinada para avaliar amostras desconhecidas e associá-las com uma determinada classe do conjunto de treinamento.

As redes neurais diretas com múltiplas camadas também são excelentes classificadoras. De qualquer, forma apresentam dois problemas: o primeiro é o desconhecimento da forma de operação e o comportamento esperado do mesmo. O segundo e mais sério, é a velocidade de treinamento da rede, a qual pode ser extremamente baixa. Por outro lado, as PNN têm um modelamento matemático consolidado, são treinadas rapidamente e classificam significativamente bem, comparadas com as redes diretas de múltiplas camadas (Masters 1995).

As principais desvantagens das redes probabilísticas são a relativa lentidão para classificar e a exigência de grande quantidade de memória computacional. No entanto, como

foi mencionado anteriormente, uma PNN pode ser implementada através de vários processadores, facilitando a implementação da máquina.

Na Figura 3.6 são apresentadas duas classes (\clubsuit, \diamond), onde a coordenada do eixo das abscissas de um elemento qualquer de uma das classes é definida por uma variável, ao passo que a coordenada do eixo das ordenadas é definida por outra variável. Se uma amostra desconhecida (?), como observado na figura, for apresentada a um classificador que avalia apenas tendências centrais, a mesma será classificada como (\diamond), enquanto que esta amostra pertence verdadeiramente à classe dos (\clubsuit).




Figura 3.6. Exemplo de um problema de classificação: tendências centrais.

Um método que calcula a distância entre a amostra desconhecida e todos os membros do conjunto de treinamento, chamado comumente de “classificador do vizinho mais próximo”, terá desempenho satisfatório num caso como este, entretanto, falha numa situação como a da ilustrada na Figura 3.7. Nesta, verifica-se que a amostra desconhecida (?) pertence à classe dos (\clubsuit), a despeito de estar mais próxima de um membro da classe dos (\diamond).




Figura 3.7. Exemplo de um problema de classificação: vizinho mais próximo.

3.6.1. Método de Classificação de Bayes

A rede neural probabilística tem como base o método estatístico de Bayes, o qual será detalhado a seguir.

Considerando-se uma coleção de amostras aleatórias de K populações, onde cada amostra, indexada de $k=1, 2, \dots, K$, é um vetor $x=[x_1, x_2, \dots, x_m]$. Num caso geral, admite-se que tais amostras tenham diferentes probabilidades, denominadas h_k . Quando um erro de classificação é cometido com um caso que certamente pertence à população k , o custo associado com este erro é c_k , entretanto, em muitos casos, segundo (Masters, 1995), as probabilidades h_k são admitidas iguais para todas as amostras, e o mesmo é feito para o custo c_k .

A coleção completa é chamada de conjunto de treinamento, contendo n_1 amostras da classe 1, n_2 da classe 2 e n_k da classe k . Um algoritmo apto a associar corretamente uma amostra desconhecida à uma das classes do conjunto de treinamento, deve ser gerado a partir desse procedimento. O algoritmo taxado como um Bayes ótimo ocorre para o caso em que o mesmo tenha um custo de erro de classificação maior do que qualquer outro.

Prova-se que haverá uma regra de decisão de Bayes ótima caso seja fornecida a verdadeira função densidade de probabilidade (fdp) para toda a coleção de amostras. Faz-se a classificação de uma amostra desconhecida X como pertencente à uma classe i se:

$$h_i c_i f_i(X) > h_j c_j f_j(X) \quad (3.6)$$

para toda amostra $j \neq i$.

$f_k(X)$ trata-se da concentração (densidade) de membros da classe k ao redor da amostra desconhecida. De acordo com a regra de Bayes, deve-se favorecer a classe que possui maior densidade de membros na vizinhança da amostra desconhecida. Há, no entanto, um problema da regra de Bayes, em que não se conhece a verdadeira fdp $f_k(X)$. Neste caso, deve-se utilizar uma estimativa para a fdp. (Parzen, 1962) apresenta um excelente estimador para a fdp unidimensional que converge para a verdadeira fdp quando o número de amostras cresce.

3.6.2. Método de Estimativa da fdp

O estimador da fdp de Parzen utiliza uma função de ponderação $W(d)$, conhecida como função Kernel, a qual possui os maiores valores para $d=0$ e, decresce rapidamente com o valor absoluto de d . Um Kernel é centrado em cada ponto da amostra, com o valor de cada uma dessas funções, em uma coordenada x , determinado pela distância d entre x e o ponto da

amostra. O estimador da função densidade de probabilidade da amostra é a soma escalonada destas funções para todos os casos da amostra.

Dada uma amostra de uma variável aleatória unidimensional de tamanho (n), a sua fdp pode ser estimada por:

$$g(x) = \frac{1}{n\sigma} \sum_{i=1}^n W\left(\frac{x - x_i}{\sigma_s}\right) \quad (3.7)$$

onde σ_s é o parâmetro de escala que define a largura da curva sino centrada em cada membro da coleção de dados.

Para um valor muito pequeno de σ , o estimador tende a valorizar os pontos amostrais demasiadamente, e para valores muito grandes, o estimador despreza quase que completamente a influência dos pontos amostrais vizinhos.

As propriedades impostas para as funções candidatas à janela Kernel foram estabelecidas por Parzen (1962) e Specht (1990), como segue:

- A função deve ser limitada

$$\max_x |W(x)| < \infty \quad (3.8)$$

- A magnitude de função de ponderação deve tender a zero à medida que o módulo do seu argumento aumenta. Tal restrição é representada pelas Equações 3.9 e 3.10.

$$\int_{-\infty}^{\infty} |W(x)| dx < \infty \quad (3.9)$$

$$\lim_{x \rightarrow \infty} |W(x)| = 0 \quad (3.10)$$

- A função de ponderação deve ser apropriadamente normalizada, atendendo à Equação 3.11.

$$\int_{-\infty}^{\infty} W(x) dx = 1 \quad (3.11)$$

- A função de ponderação deve estreitar-se com o aumento do tamanho amostral, com intuito de se obter um comportamento assintótico. As Equações 3.12 e 3.13 representam ambas as condições que devem ser satisfeitas para o parâmetro de escala em função de n .

$$\lim_{x \rightarrow \infty} \sigma_n = 0 \quad (3.12)$$

$$\lim_{x \rightarrow \infty} n\sigma_n = \infty \quad (3.13)$$

3.6.3. Arquitetura e Funcionalidade da Rede Neural Probabilística

Numa rede treinada para executar tarefas de classificação, o número de entradas é exatamente igual ao número de parâmetros necessários para identificar uma determinada classe. A camada de entrada é fictícia, uma vez que seus neurônios não executam nenhuma operação. A camada de classificação é constituída de um neurônio para cada caso do conjunto de treinamento. O processo de classificação inicia com a apresentação da amostra desconhecida para todos os neurônios da camada de classificação. Cada neurônio de classificação calcula a distância medida entre a amostra de entrada e o caso do conjunto de treinamento ao qual ele está associado. Esta distância será o argumento da função de ativação do neurônio, que é necessariamente uma janela Parzen. Cada neurônio da camada de somatório simplesmente soma a saída dos neurônios da camada de classificação correspondente à sua classe. O nível de ativação do neurônio somador k é o valor da fdp estimada da população k . O neurônio da camada de saída é um classificador simples, que decide qual das entradas provenientes da camada de somatório possui o valor máximo.

Capítulo IV

Lógica Difusa

O conceito da lógica difusa (fuzzy) vem da necessidade de aproximar o raciocínio humano ao da lógica executada pela máquina. Invariavelmente, utilizam-se conceitos subjetivos para classificar ou considerar certas situações como: siga em frente “alguns metros”, o dia está “parcialmente nublado”, a classificação de certos objetos como “largo”, “sujo”, “velho”, “jovem”, e outros. Nesses exemplos os termos entre aspas são fuzzy, devido ao fato de serem conceitos vagos e imprecisos. Entende-se a lógica fuzzy como sendo uma situação em que não se pode responder simplesmente ‘sim’ ou ‘não’, é mais apropriado o uso das palavras ‘talvez’ ou ‘quase’, por exemplo.

4.1. Conjuntos Fuzzy

A lógica difusa distingue-se da lógica booleana por permitir a utilização de um intervalo entre os limites 0 e 1, e não apenas estes, como no caso binário. Em outras palavras, pode-se trabalhar não apenas com os valores 0 e 1, mas com todo o intervalo [0; 1] entre eles.

De modo geral, as terminologias e notação usadas em conjuntos clássicos também estão presentes nos conjuntos fuzzy. Como uma proposta de generalização da teoria clássica dos conjuntos ordinários Zadeh introduziu, em 1965, os conceitos fundamentais da teoria dos conjuntos fuzzy.

O processo pelo qual se determina quais elementos do conjunto universo são ou não elementos de um conjunto clássico é definido como *função característica*. Supondo um conjunto A e para todo $x \in U$, esta função é denotada por:

$$\Psi_A(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases} \quad \text{ou} \quad \Psi_A(x) : U \Rightarrow \{0,1\} \quad (4.1)$$

Todavia, em muitas situações, é difícil afirmar claramente se um elemento x é membro ou não de um determinado conjunto. Por exemplo, suponha que se queira classificar pessoas em três conjuntos: alto, médio e baixo. É nítido que um indivíduo de 1,70 m de altura tem estatura média. Porém, não há critérios precisos que definam a fronteira deste conjunto. Uma pessoa de 1,50 ou 1,80 m tem estatura média ou não? O indivíduo de 1,50 m é baixo e o de 1,80 m é

alto? Nota-se que há um intervalo vago na fronteira desses conjuntos, dificultando a classificação dos indivíduos.

Para tratar este problema, os conjuntos fuzzy se destacam, uma vez que admitem para as funções características um grau de pertinência, que pode variar no intervalo real $[0, 1]$, assumindo valor 0, para o elemento não pertencer ao conjunto e 1 para o elemento pertencer totalmente ao conjunto.

Na teoria dos conjuntos fuzzy, **A** passa ser caracterizado por sua função característica ou função de pertinência, a qual é a relação entre os valores de um elemento e seu grau de pertinência em um conjunto. Esta função é definida por:

$$\mu_A(x) : U \Rightarrow [0,1] \quad (4.2)$$

onde **U** é o universo de discurso de um elemento particular x . Uma representação possível para o conjunto fuzzy **A** é:

$$A = \{(x, \mu_A(x))\}, x \in U \quad (4.3)$$

onde cada par do conjunto **A** é formado por um elemento x e o seu respectivo valor de pertinência $\mu_A(x)$. Este par é denominado de *singleton* por muitos autores.

Um conjunto pode também ser representado pela notação discreta dada pela Equação 4.4.

$$A = \sum_{i=1}^m \frac{\mu_A(x_i)}{x_i}, x_i \in U \quad \text{ou seja, } A = \frac{\mu_A(x_1)}{x_1} + \frac{\mu_A(x_2)}{x_2} + \dots + \frac{\mu_A(x_m)}{x_m} \quad (4.4)$$

Na Equação 4.4, $\mu_A(x)$ é a função de pertinência e **U** o universo do discurso.

4.1.1. Funções fuzzy mais comuns

Como a lógica fuzzy utiliza valores contínuos, e não discretos, torna-se necessária uma representação por conjuntos, descritos por funções. Dentre estas funções, destacam-se:

a) Função Triangular

Este tipo de função (Figura 4.1) serve para indicar apenas um único ponto de máximo no conjunto. Sua definição pode ser dada por meio da Equação 4.5.

$$f(x) = \begin{cases} y_{\min}, & x \leq i \quad \text{ou} \quad x \geq f \\ y_{\min} + (y_{\max} - y_{\min}) \times (x - i) / (m - i), & i < x \leq m \\ y_{\min} + (y_{\max} - y_{\min}) \times (f - x) / (f - m), & m < x \leq f \end{cases} \quad (4.5)$$

onde y_{\min} é o menor valor possível para a função, y_{\max} o maior valor, i o início da ascendente da função, m o valor de máximo, e f o final da descendente.




Figura 4.1. Função de Pertinência Triangular

b) Função Trapezoidal

Nesta função, a qual está mostrada na Figura 4.2 e definida pela Equação 4.6, é possível representar todo um intervalo de pontos de máximo.

$$f(x) = \begin{cases} y_{\min}, & x \leq i \quad \text{ou} \quad x \geq f \\ y_{\min} + (y_{\max} - y_{\min}) \times (x - i) / (m - i), & i < x < m_1 \\ y_{\max}, & m_1 \leq x \leq m_2 \\ y_{\min} + (y_{\max} - y_{\min}) \times (f - x) / (f - m), & m_2 < x < f \end{cases} \quad (4.6)$$

onde y_{\min} é o menor valor possível para a função, y_{\max} o maior valor, i o início do trapézio, m_1 o início do intervalo de máximo, m_2 o término do intervalo de máximo e f o final do trapézio.




Figura 4.2. Função de Pertinência Trapezoidal

c) LR (Left-Right)

A Figura 4.3 representa este tipo de conjunto, o qual é mais genérico, devido ao fato de permitir a utilização de vários tipos de funções para definir o intervalo de representação. As funções são chamadas de L (left – define a função à esquerda) e R (right – define a da direita). Sua formulação padrão pode ser representada por meio da Equação 4.7.

$$f(x) = \begin{cases} L[(m_1 - x)/\alpha], & x < m_1 \\ 1, & m_1 \leq x \leq m_2 \\ R[(m_2 - x)/\beta], & x > m_2 \end{cases} \quad (4.7)$$

onde L e R podem ser funções do tipo e^{-x} , $1/(1 + x^2)$, ou outra qualquer que tenha $f(0) = f(1) = 0$ e mantenha-se no intervalo $[0, 1]$; m_1 é o início do intervalo de máximo, m_2 o término do intervalo de máximo, α é o espalhamento lateral da esquerda e β o da direita.

A Figura 4.3 representa a função LR, com $L = R = 1/(1 + x^2)$, $\alpha = 5$ e $\beta = 2$.




Figura 4.3. Função de Pertinência LR

4.1.2. Operações com conjuntos fuzzy

Sejam A e B dois conjuntos fuzzy em U com suas funções de pertinências μ_A e μ_B , respectivamente. As operações de conjuntos como união, intersecção e complemento para conjuntos fuzzy, são definidas através de suas funções de pertinências.

União: A função de pertinência $\mu_{A \cup B}$ é definida ponto a ponto para todo $x \in U$, por:

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} \quad \text{ou} \quad \mu_{A \cup B}(x) = \mu_A(x) \vee \mu_B(x)$$

Intersecção: A função de pertinência $\mu_{A \cap B}$ é definida ponto a ponto para todo $x \in U$, por:

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} \quad \text{ou} \quad \mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x)$$

Complemento: A função de pertinência $\mu_{\neg A}$ é definida ponto a ponto para todo $x \in U$, por:

$$\mu_{\neg A}(x) = 1 - \mu_A(x)$$

Tomando-se como exemplo dois conjuntos fuzzy A e B de $X = \{-2, -1, 0, 1, 2\}$, onde $A = 0.5/-2 + 0.4/-1 + 1.0/0 + 0.3/1 + 0.7/2$ e $B = 0.1/-2 + 0.4/-1 + 0.9/0 + 0.2/1 + 0.6/2$, tem-se que:

$$A \cup B = 0.5/-2 + 0.4/-1 + 1.0/0 + 0.3/1 + 0.7/2$$

$$A \cap B = 0.1/-2 + 0.4/-1 + 0.9/0 + 0.2/1 + 0.6/2$$

$$\neg A = 0.5/-2 + 0.6/-1 + 0.0/0 + 0.7/1 + 0.3/2$$

A Figura 4.4 apresenta as operações de união (linha mais forte nos contornos das funções) e intersecção (área hachurada) dos conjuntos fuzzy.




Figura 4.4. Operações de união e intersecção nos conjuntos fuzzy.

Produto Cartesiano: O produto cartesiano entre dois conjuntos A e B é definido por:

$$\mu_A \times \mu_B = \min\{\mu_A(x), \mu_B(x)\}$$

Geralmente as operações de união e intersecção entre conjuntos fuzzy fazem uso, respectivamente da norma triangular (T-norms) e da co-norma triangular (T-conorms).

As normas triangulares foram introduzidas para modelar distância no espaço métrico probabilístico. Essas normas são exaustivamente usadas para modelar a conectiva AND. A tabela 4.1 mostra as T-norms básicas. A maior norma triangular é a intersecção e a menor é o produto drástico (Lee,1990). As operações associadas à norma triangular são definidas para todo $x, y \in [0, 1]$. Essas normas são enunciadas como $T: [0, 1] \times [0, 1] \rightarrow [0, 1]$.

As co-normas triangulares são usadas para modelar a conectiva OR e as mais usuais estão mostradas na Tabela 4.2 (Teixeira, 2001). Essas co-normas são definidas pelo mapeamento $S: [0, 1] \times [0, 1] \rightarrow [0, 1]$.

Tabela 4.1. Normas Triangulares Básicas (T-norms)

Referência	Definição	Função
Intersecção ou Mínimo (Zadeh - 1965)	$\text{MIN}(x,y) = x \wedge y$	$\min(x,y)$
Produto Limitado (Lukasiewicz, Giles - 1976)	$\text{LANG}(x,y) = x \circ y$	$\max(x + y - 1, 0)$
Produto Algébrico ou Probabilístico (Bandler e Kohout - 1980)	$\text{PAND}(x,y) = x \cdot y$	xy
Fraca	$\text{WEAK}(x,y)$	$x \wedge y$, se $x \vee y = 1$ 0 caso contrário
Hamacher - 1978	$H_\gamma(x,y)$	$\frac{xy}{\gamma + (1 - \gamma)(x + y - xy)}$
Dubois and Prade - 1986	$\sigma_\alpha, \alpha \in [0, 1]$	$\frac{xy}{\max(x, y, \alpha)}$
Produto Drástico	_____	$x \cap y = x$, se $y = 1$ y , se $x = 1$ 0, se $x, y < 1$

Tabela 4.2. Co-normas Triangulares Básicas (T-conorms ou S-norms)

Referência	Definição	Função
União ou Máximo (Zadeh - 1965)	$MAX(x,y) = x \vee y = \max\{x,y\}$	$\max(x,y)$
Soma Limitada (Lukasiewicz, Giles - 1976)	$LOR(x,y) = x \oplus y$	$\min(x + y, 1)$
Soma Algébrica ou Probabilística (Bandler e Kohout - 1980)	$POR(x,y)$	$x+y-xy$
Forte	$STRONG(x,y)$	$x \vee y$, se $x \wedge y = 1$ 1 caso contrário
Hamacher - 1978	$H_{\gamma}(x,y)$	$\frac{x + y - (2 - \gamma)xy}{1 - (1 - \gamma)xy}$
Dubois and Prade - 1986	$\sigma_{\alpha}, \alpha \in [0,1]$	$\frac{x + y - xy - \min(x, y, 1 - \alpha)}{\max(1 - x, 1 - y, \alpha)}$
Soma Drástica	---	$x \cup y = x$, se $y = 0$ y , se $x = 0$ 0, se $x, y < 0$

4.1.3. Variáveis Lingüísticas

As variáveis utilizadas em fuzzy são chamadas de lingüísticas por não terem valores precisos, sendo definida como um espectro de valores. Com isso, são definidas através de conjuntos para representar intervalos.

Toma-se como exemplo uma variável T de temperatura, a qual pode assumir três tipos de conjuntos: quente, normal e frio. A representação gráfica da variável, com seus respectivos conjuntos e intervalos, está mostrada na Figura 4.5.




Figura 4.5. Variável Lingüística de Temperatura

4.2. Sistema de Inferência Fuzzy

O sistema de inferência fuzzy (FIS) utiliza a teoria dos conjuntos fuzzy para mapear entradas (característica, no caso de classificador fuzzy) em saídas (classes, para a situação de classificador), (Ferreira e Paranhos, apud Knapp, 2004).

4.2.1. Saída do Modelo Fuzzy

A saída de um modelo fuzzy se realiza através de seis passos (Ferreira e Paranhos, 2004):

- Determinação de um conjunto de regras fuzzy (criação das regras);
- “Fuzzificação” das entradas usando as funções de pertinência;
- Combinação das entradas “fuzzificadas” em cada regra fuzzy para estabelecer a ativação da regra;
- Cálculo da parte conseqüente da regra;
- Combinação das partes conseqüentes de todas as regras para obter a distribuição da saída;
- Desfuzzificação da saída.

Criação da regra fuzzy

As regras fuzzy descrevem como o FIS deve realizar a decisão de classificação ou controle. Cada regra é representada por uma afirmação se-então, escrita na forma: SE (entrada 1) ... E/OU (entrada 2) ... ENTÃO (saída).

Fuzzificação

A etapa de “fuzzificação” mapeia a entrada (ou característica) entre valores de 0 e 1, através das funções de pertinência. As funções mais utilizadas são a triangular, a trapezoidal, a gaussiana, a sino e a sigmoideal, as quais já foram descritas na Seção 4.1.1.

Toma-se como exemplo duas entradas Temperatura (T) e Pressão (P), cada qual descrita em um universo de discurso por três funções triangulares, taxadas de alta (A), média (M) e baixa (B).

São dadas duas regras em que:

R₁: Se T é A e P é B então...

R_2 : **Se T é M e P é B então...**

A Figura 4.6 representa graficamente a “fuzzificação” de duas entradas t e p, as quais são os valores da temperatura e da pressão, respectivamente.




Figura 4.6. Fuzzificação das entradas t e p.

Pode-se observar na Figura 4.6 que a “fuzzificação” das entradas t e p quando aplicada em ambas as regras, obtêm-se os valores de pertinência das intersecções entre as linhas verticais das entradas com os conjuntos.

Com isso, o resultado da “fuzzificação” para ambas as regras fica:

Primeira Regra:

R_1 : **Se T = t é A e P = p é B então...**

R_1 : **Se $\mu_A(t) = 0.7$ e $\mu_B(p) = 0.4$ então...**

Segunda Regra:

R_2 : **Se T = t é A e P = p é B então...**

R_2 : **Se $\mu_M(t) = 0.25$ e $\mu_B(p) = 0.4$ então...**

Logo, a etapa de “fuzzificação” das entradas é o cálculo dos antecedentes de todas as regras, através da conversão de valores numéricos em valores de pertinência do conjunto envolvido nas preposições das regras.

Combinação das entradas nas regras fuzzy

Nas regras fuzzy são utilizados os conceitos AND e OR, cuja implementação é realizada por meio das normas e conormas triangulares. Como visto na Secção 4.1.2, essas normas possuem várias aplicações.

As Equações 4.8 e 4.9 representam os operadores originais propostos por Zadeh. Estes operadores apresentam como vantagem admitir combinações entre duas proposições fuzzy iguais, não ignorando redundâncias. Vantagem esta que não ocorre para as demais propostas.

$$\mu_A \cup \mu_A = \max[\mu_A(x); \mu_A(x)] = \mu_A(x) \quad (4.8)$$

$$\mu_A \cap \mu_A = \min[\mu_A(x); \mu_A(x)] = \mu_A(x) \quad (4.9)$$


Por outro lado, quando as proposições fuzzy não são iguais, mas correlacionadas, outros operadores podem ser utilizados. Neste caso, pode-se utilizar os operadores propostos por Lukasiewicz, os quais estão mostrados nas Equações 4.10 e 4.11.

$$\mu_A \cup \mu_B = \max[\mu_A(x) + \mu_B(x); 1] \quad (4.10)$$

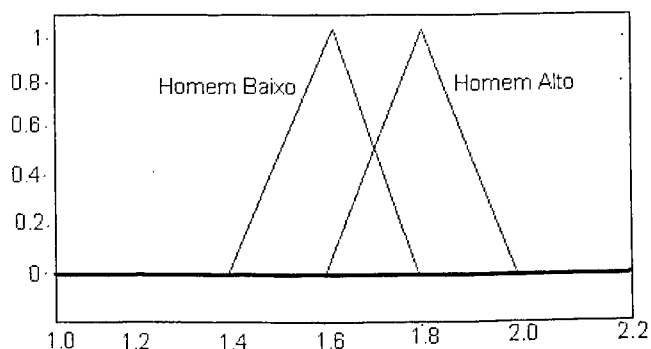
$$\mu_A \cap \mu_B = \min[\mu_A(x) + \mu_B(x) - 1; 0] \quad (4.11)$$

Dadas duas proposições, indicadas da forma “o homem é baixo e o homem é alto”, por exemplo, espera-se que a combinação entre elas resulte em um conjunto vazio, uma vez que um homem não pode ser alto e baixo ao mesmo tempo.

As Figuras 4.7 e 4.8 representam os operadores do conectivo AND segundo Zadeh e Lukasiewicz, respectivamente.



Figuras 4.7. Representação gráfica do operador do conectivo AND segundo Zadeh



Figuras 4.8. Representação gráfica do operador do conectivo AND segundo Lukasiewicz

Vale ressaltar que a escolha das normas e conormas triangulares para representar os conectivos AND e OR depende do contexto da relação entre as variáveis.

Parte conseqüente de cada regra

A parte conseqüente de cada regra é conseguida através do uso de algum operador de implicação. Os mais utilizados são o de Mandani e Larsen (Ferreira e Paranhos, 2004).

Normalmente a implicação significa uma relação de causalidade, ditada pela sentença se-então, em que o sentido da proposição ou sentença tem que ser mantido para representar o conhecimento a respeito do sistema. Então, a implicação fuzzy, ou condição de estado fuzzy, assume a seguinte forma:

Se x é A então y é B ou $A \rightarrow B$

A e B são valores lingüísticos definidos por conjuntos fuzzy no universo de discurso X e Y , respectivamente. A implicação fuzzy se divide em duas partes, uma chamada de antecedente ou premissa (x é A) e outra denominada de conseqüente ou conclusão (y é B).

A regra fuzzy pode ser definida como uma relação binária fuzzy R no produto do espaço X e Y , uma vez que descreve a relação entre duas variáveis x e y . Portanto, $A \rightarrow B$ deve ser definida ponto a ponto, e isso é feito através dos operadores de implicação fuzzy. (Lee, 1990) reporta mais de 40 maneiras distintas para a representação da função de implicação fuzzy. Os operadores mais comuns estão apresentados na Tabela 4.3.

Tabela 4.3. Operadores mais comuns

Referência	$x \rightarrow y$
Larsen (1980)	xy
Zadeh (1975)	$\min(1-x, \min(x,y))$
Mandani (1974)	$\min(x,y)$
Lukasiewicz	$\min(1-x+y, 1)$
Kleene (1938)	$\max(1-x, y)$
Reichenbach	$1-x+xy$
Gödel	y , se $x > y$ ou 1 , caso contrário
Gaines	1 , se $x < y$ ou 0 , caso contrário

Combinação de todas as partes conseqüentes

As saídas de todas as regras devem ser combinadas para obter a distribuição de saída fuzzy. Geralmente é utilizado o operador de união.

A combinação de uma regra fuzzy é feita em uma relação fuzzy que é chamada de agregação. É possível agregar as regras de diferentes maneiras. Para a implicação Mandani, a agregação (senão) é adotada como sendo o operador de união das regras, que faz o uso das normas-T. A agregação pode também assumir o operador de intersecção, utilizando as conormas-T ou normas-S.

Quando se utilizam relações de implicação Mandani e Larsen, com inferência *generalizado modus ponens*, o conseqüente da regra resulta em um subconjunto fuzzy da saída. A agregação, nestes casos, pode ser a união ou intersecção dos subconjuntos dos conseqüentes de cada regra, resultando em um novo conjunto fuzzy.

A Figura 4.9 mostra um exemplo de implicação fuzzy, onde por meio da mesma calcularam-se os valores das implicações de Gödel e Larsen.




Figura 4.9. Exemplo de implicação fuzzy.

Da Figura 4.7 tem-se que:

Se $x = 4 \Rightarrow$ pressão alta $\mu_p = 0.75$

Se $y = 1 \Rightarrow$ volume pequeno $\mu_v = 1$

$x(4) \rightarrow y(1) = 0.75 \rightarrow 1$

Pelo método de Gödel a implicação resulta no valor 1, ao passo que pelo método de Larsen, o resultado é 0.75.

Desfuzzificação

Em muitos casos é desejável que a saída do sistema não seja fuzzy e sim uma saída definida. A etapa de “desfuzzificação” mapeia a saída fuzzy em um valor definido. Teixeira (2001) cita que muitos autores têm sugerido diferentes métodos de “desfuzzificação”, sendo que a escolha do mesmo influencia significativamente nas velocidade e acuracidade do controlador fuzzy.

Algumas estratégias de “desfuzzificação” serão apresentadas a seguir.

- Método do Máximo Critério (MAX): Este método encontra o ponto no qual a distribuição de saída possui o seu primeiro valor de máximo.
- Método da Média dos Máximos (MOM): O MOM obtém o valor médio onde a saída possui seus valores máximos. Isso pode ser computado como:

$$z_0 = \sum (w_j / l)$$

onde w_j são os valores em que a função de pertinência possui seus máximos valores e l é o número de valores máximos encontrados.

- Método do Centro de Massa (COA): Este método é largamente usado e procura pelo centro de gravidade da distribuição de saída fuzzy (Lee, 1990).

Na Figura 4.10 estão ilustradas as três estratégias de “desfuzzificação”, as quais estão apontadas na mesma.




Figura 4.10. Estratégias de *desfuzzificação*.

4.2.2. Alguns Modelos Fuzzy

Alguns modelos fuzzy são largamente utilizados em várias aplicações. Geralmente as diferenças entre os sistemas estão na sua parte conseqüente, no processo de agregação das várias regras e na “desfuzzificação” dos mesmos.

Modelo fuzzy de Mandani

Neste modelo as implicações fuzzy são modeladas pelo operador de Mandani (min) e as regras são agregadas através do operador de união (max), sendo denominado de método composicional de inferência max-min. Assume, portanto, duas regras se-então da seguinte forma:

R_1 : Se x é A_1 e y é B_1 então z é C_1

R_2 : Se x é A_2 e y é B_2 então z é C_2

Fato: x é x_0' e y é y_0'

Conseqüência: z é C

A ativação de cada regra, denotada por a_i , com $i = 1, 2$; é calculada por:

$$a_1 = A_1(x_0) \wedge B_1(y_0) \text{ (conectiva AND)}$$

$$a_2 = A_2(x_0) \wedge B_2(y_0) \text{ (conectiva AND)}$$

onde x_0 e y_0 são as entradas x_0' e y_0' fuzzificadas.

A saída de cada regra é dada por:

$$C_1'(w) = a_1 \wedge C_1(w) \text{ (operador de Mandani)}$$

$$C_2'(w) = a_2 \wedge C_2(w) \text{ (operador de Mandani)}$$

E a saída geral do sistema é calculada pelo operador de união, da seguinte forma:

$$C(w) = C_1'(w) \vee C_2'(w) = (a_1 \wedge C_1(w)) \vee (a_2 \wedge C_2(w)).$$

Este modelo de raciocínio fuzzy está graficamente representado na Figura 4.11.

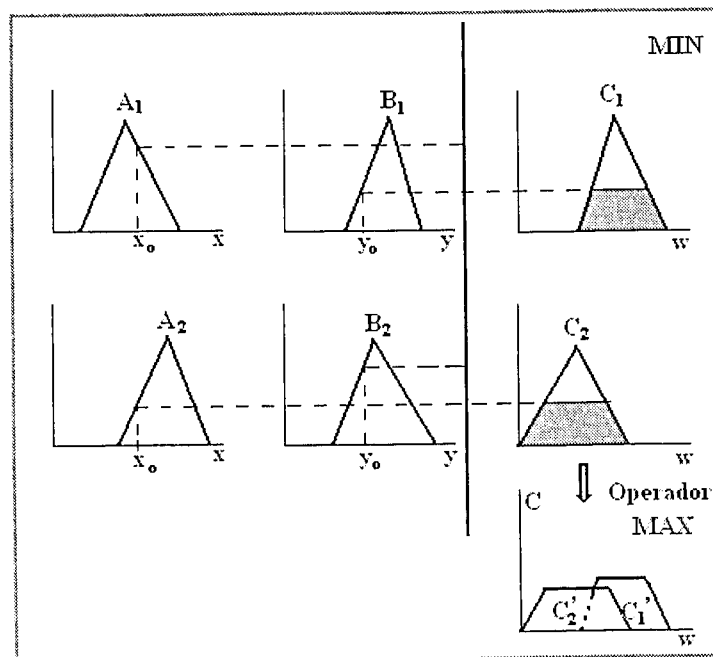


Figura 4.11. Modelo de raciocínio de Mandani

Modelo fuzzy de Larsen

Este método é uma variação do modelo de Mandani, em que se utiliza o operador de Larsen (prod) ao invés do min, sendo, portanto, chamado de método composicional de inferência max-prod.

Então, o modelo emprega, a implicação de Larsen para escalonar o conseqüente por um certo grau de pertinência, resultando em um subconjunto envolvido no conseqüente da regra. Esses subconjuntos de cada regra são agregados pelo operador união para obtenção um único conjunto fuzzy.

A Figura 4.12 mostra o modelo de raciocínio fuzzy de Larsen.

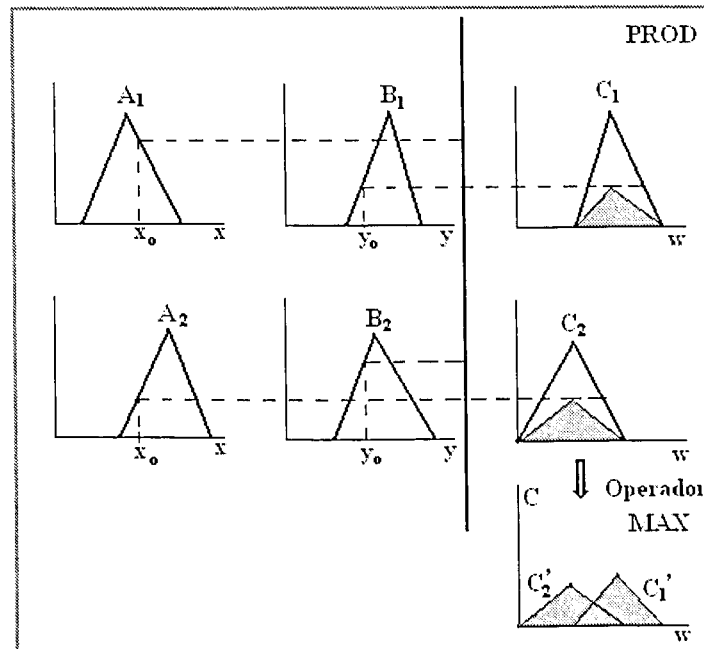


Figura 4.12. Modelo de raciocínio de Larsen

Modelo fuzzy de Sugeno

De acordo com Ferreira e Paranhos (2004), Sugeno e Takagi usaram a seguinte arquitetura:

R_1 : Se x é A_1 e y é B_1 então $z_1 = a_1x + b_1y + r_1$

R_2 : Se x é A_2 e y é B_2 então $z_2 = a_2x + b_2y + r_2$

Fato: x é x_0' e y é y_0'

Conseqüência: z é z_0

A ativação de cada regra é dada por:

$$a_1 = A_1(x_0) \wedge B_1(y_0)$$

$$a_2 = A_2(x_0) \wedge B_2(y_0)$$

A saída de cada regra é conseguida através de uma relação polinomial dada por:

$$z_1 = a_1x_0 + b_1y_0 + r_1$$

$$z_2 = a_2x_0 + b_2y_0 + r_2$$

Na agregação das regras, realizada por meio do centro de massa, consegue-se uma saída definida pela Figura 4.13.




Figura 4.13. Modelo de raciocínio de Sugeno

Modelo fuzzy de Tsukamoto

Neste modelo, todas as funções de pertinência são monotônicas. O centro de massa é utilizado para obter a saída, que no caso já é definida. A Figura 4.14 mostra o raciocínio deste método.




Figura 4.14. Modelo de raciocínio de Tsukamoto

Dos quatro modelos de inferência fuzzy apresentados acima, será utilizado neste trabalho o método de raciocínio de Mandani.

Capítulo V

Metodologia e Procedimentos

Para o desenvolvimento da parte experimental deste trabalho será utilizada uma bancada composta por um motor elétrico e cinco mancais de rolamentos de esferas, sendo os dois mancais de apoio autocompensadores e os três centrais, rígidos de carreira simples.

A caracterização do comportamento vibratório do sistema será realizada via FRF (Função Resposta em Freqüência) e análise espectral, para o sistema em funcionamento.

Tendo-se as freqüências características dos defeitos dos rolamentos determinadas e o comportamento vibratório do sistema identificado, serão adquiridos os sinais de vibrações para posteriores análises.

Objetivando-se monitorar a integridade do sinal coletado para rolamentos em manutenção preditiva, a aquisição dos dados será realizada com sinais considerados em boas condições;, com possíveis problemas de instrumentação, tais como um cabo desconectado, problemas de blindagem em cabos, ou o condicionador de sinais desligado; com os sensores de aceleração fixados fora de sua posição original; com a bancada experimental desligada e um ventilador radial colocado do seu lado funcionando com uma velocidade de rotação de 2204 rpm; e com eventos aleatórios, como uma excitação impulsiva na bancada. Efetuar-se-á a aquisição dos sinais para se ter um histórico das falhas nos rolamentos.

Serão estimados parâmetros que estejam relacionados com a qualidade do sinal e que detectem anomalias nos rolamentos. Para a seleção dos melhores indicativos da integridade do sinal, será realizada uma análise de sensibilidade via Teste de Hipótese Nula (Diamond, 1989), para a comparação das médias dos valores considerados bons (sinal "ok") com os referentes a problemas de instrumentação, sensores trocados e máquina desligada, separadamente. A hipótese assumida é a de que as médias das duas categorias (grupo 1 e grupo 2, por exemplo) sejam iguais e as diferenças observadas entre elas são oriundas exclusivamente de erros aleatórios.

Demonstra-se que t_0 , calculado pela Equação 5.1, tem uma distribuição t de Student, cujo número de graus de liberdade é calculado pela Equação 5.2.

Admitindo-se um nível alto de confiança α_t para o Teste de Hipótese (95%), caso o valor calculado para t_0 seja maior do que t_α , ($t_0 / t_\alpha > 1$), a hipótese é recusada e conclui-se que as duas médias pertencem a grupos estatísticos distintos.

$$t_0 = \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad (5.1)$$

$$v = \frac{\left[\left(\frac{s_1^2}{n_1} \right) + \left(\frac{s_2^2}{n_2} \right) \right]^2}{\frac{\left(\frac{s_1^2}{n_1} \right)^2}{n_1 + 1} + \frac{\left(\frac{s_2^2}{n_2} \right)^2}{n_2 + 1}} - 2 \quad (5.2)$$

onde:

\bar{x}_1 e \bar{x}_2 são as estimativas das médias dos grupos 1 e 2, respectivamente.

s_1^2 e s_2^2 são as estimativas das variâncias dos grupos 1 e 2, respectivamente.

n_1 e n_2 são os números de elementos (dados) dos grupos 1 e 2, respectivamente.

Com os parâmetros selecionados, serão analisados os gráficos "Boxplot" de cada categoria de sinal. Esses gráficos, conhecidos como diagramas de caixas e bigodes, são ferramentas que condensam em um único gráfico, um conjunto grande de informações a respeito da distribuição de um conjunto de dados.

A Figura 5.1 mostra um exemplo de gráfico "Boxplot", onde estão indicados:

1. A linha vermelha referente ao valor da mediana
2. A linha inferior da caixa referente ao primeiro quartil (25% dos dados estão abaixo desta linha)
3. A linha superior da caixa referente ao terceiro quartil (75% dos dados estão abaixo desta linha)
4. O bigode superior referente ao valor máximo de dados que é menor do que o terceiro quartil mais uma constante (normalmente 1,5) vezes o comprimento do interquartil (valor da linha 3 menos o valor da linha 2).
5. O bigode inferior referente ao valor mínimo de dados que é maior do que o primeiro quartil menos uma constante vezes o comprimento do interquartil.
6. As cruces vermelhas representam os valores de dados que estão fora dos limites dos bigodes.




Figura 5.1. Exemplo de um gráfico “Boxplot” com os seus elementos constituintes.

Uma simples análise visual de gráficos “Boxplot” fornece uma grande quantidade de informações estatísticas para o analista, dentre as quais pode-se ressaltar:

- Uma grande qualidade da mediana, em relação à média, reside no fato de que a mesma é menos sensível a valores extremos, o que é muito útil em análise que envolve dados com grandes dispersões, como é o caso do estudo de sinais oriundos de componentes com defeito.
- A distância entre as linhas do primeiro e terceiro quartil e a mediana dá uma idéia sobre o nível de achatamento da distribuição.
- A diferença entre os comprimentos das caixas superior e inferior é um indicativo da assimetria da distribuição.
- A distância entre os bigodes e a mediana é um indicativo das “excursões fora da média” do grupo de dados.
- As cruces estão normalmente relacionadas com problemas na aquisição dos dados.

Meola, Duarte, e Barreto (2003), desenvolveram um trabalho em controle de rumorosidade em câmbios, o qual utiliza comparação de médias e gráficos “Boxplot” para diferenciar câmbios considerados bons de câmbios com problemas de rumorosidade. Estas ferramentas estatísticas também foram utilizadas com sucesso no artigo sobre “Definição de Sintomas para ensaios de Manobrabilidade em Câmbios Automotivos”, desenvolvido por Meola, Duarte e Nunes (2004).

Para o caso de defeitos nos rolamentos, será observada a evolução dos níveis dos parâmetros e se verificarão quais apresentam melhores respostas à falha.

Os parâmetros eleitos serão utilizados como dados de entrada para o sistema de inferência fuzzy e para o desenvolvimento das classes de uma rede neural probabilística.

No caso da lógica fuzzy, serão utilizados os gráficos “Boxplot” para se determinar os limites de suas funções de pertinência.

5.1. Bancada Experimental

Neste trabalho foi utilizada uma bancada experimental composta por um motor elétrico, o qual movimenta um eixo escalonado; dois mancais de rolamentos autocompensadores de esferas, para se evitar pequenos desalinhamentos, e três mancais de rolamentos rígidos de carreira simples de esferas.

Os elementos da bancada, os quais estão ilustrados na Figura 5.2, foram enumerados para se facilitar análises futuras.




Figura 5.2. Bancada Experimental.

As especificações dos componentes da bancada estão listadas a seguir:

- Motor Elétrico:
Weg – GK76381;
2 pólos

- Potência de 0.5 CV ou 0.37 KW;
- Velocidade de Rotação de 3380 RPM
- Rolamentos Autocompensadores de Esferas:
 - Tipo 1200;
 - Número de esferas: 9;
 - Diâmetro das esferas de 4.8 mm;
- Rolamentos Rígidos de uma Carreira de Esferas:
 - Tipo 6200;
 - Número de esferas: 8;
 - Diâmetro das esferas de 4.8 mm;
- Eixo Escalonado: as dimensões (mm) estão mostradas na Figura 5.3.
 - Os desenhos de detalhes da bancada experimental estão mostrados no Anexo I.
- Acoplamento:
 - Flexível Uniflex (Transmotécnica);
 - Número de Ranhuras: 4

Para a construção da bancada experimental, considerou-se uma carga de 652 N aplicada na direção radial do mancal de rolamento central (mancal 4 da Figura 5.2, diâmetro interno de 15 mm). Tal carga foi estimada, utilizando-se o catálogo do fabricante, para uma vida útil do rolamento de aproximadamente dois meses.

A aplicação da carga foi efetuada por intermédio de um parafuso, via imposição de uma deflexão de 0.056 mm, a qual foi calculada utilizando-se um modelo de elementos finitos para a carga de 652 N.

Este procedimento indireto foi adotado devido às dificuldades intrínsecas encontradas para mensurar, de forma direta, a carga aplicada. Não se preocupou, neste trabalho, com a precisão da carga, mas sim com a padronização da mesma, em caso de se desmontar a bancada experimental, para possíveis reparos.





Figura 5.3. Dimensões do Eixo



5.2. Calibração do Sensor de Deslocamento

Para se medir o deslocamento imposto ao mancal, utilizou-se um sensor de proximidade devidamente calibrado.

Vale ressaltar que para efeito de repetibilidade, os parafusos Allen de fixação dos mancais de rolamentos em suas caixas, foram apertados com o auxílio de um torquímetro ajustado para 1 Nm.

O sensor utilizado é da marca Dymac (VibroSyst), do tipo PES – 106 P/N, com faixa de operação de 0 a 6 mm. Para a calibração do mesmo, foram utilizados uma fonte do Dymac, com ganho de -24 a 24 Volts e especificação DYC003-1; um multímetro digital, tipo hp 3054A, com faixa de atuação de 0 a 350 Volts (4 dígitos); um micrômetro Mitutoyo de 0 a 25 mm, com resolução de 0.005 mm e um aparato para a fixação dos mesmos.

Os equipamentos mencionados acima estão ilustrados, e indicados, na Figura 5.5.




Figura 5.5. Calibração do Sensor de Proximidade.

Na calibração do sensor, utilizou-se deslocamento de 0.2 mm cobrindo uma faixa de 0 a 6 mm de um micrômetro. Este deslocamento corresponde à uma variação de 0 a 10 Volts na saída do condicionador, cuja medição foi feita pelo multímetro digital. Repetiram-se três vezes as medições e efetuou-se a curva de calibração e sua interpolação, a qual está mostrada na Figura 5.6.




Figura 5.6. Curva ajustada (—) para a curva de calibração do sensor de proximidade e respectivos valores medidos médios (+++).

A curva foi ajustada utilizando-se um polinômio de grau 5, conforme a Equação 5.3, onde v é a tensão, em Volts, e Δ é o deslocamento (mm). O ajuste, via Método dos Mínimos Quadrados resultou num erro médio quadrático residual de $0,0211V^2$.

$$v = a_0 + a_1 \cdot \Delta + a_2 \cdot \Delta^2 + a_3 \cdot \Delta^3 + a_4 \cdot \Delta^4 + a_5 \cdot \Delta^5 \quad [V] \quad (5.3)$$

Os intervalos de confiança de 95 % para os coeficientes a_i ajustados estão mostrados na Tabela 5.1.

Tabela 5.1. Intervalo de confiança de 95% para os coeficientes da Equação 5.3, ajustados via Mínimos Quadrados.

Coefficiente	Intervalo Inferior	Intervalo Superior
a_0	0,0310	0,0334
a_1	0,3422	0,3728
a_2	0,4569	0,4924
a_3	0,1326	0,1391
a_4	-0,0578	-0,0576
a_5	0,0046	0,0046

Com o polinômio ajustado, um procedimento de bisseção foi utilizado para calcular a voltagem correspondente ao deslocamento imposto. O próximo passo consistiu no acionamento do parafuso até que a tensão, medida no voltímetro digital, correspondente ao deslocamento desejado fosse atingida.

5.3. Aquisição de Dados

Os sinais foram adquiridos com uma frequência de 16384 Hz, sendo amostrados 40 segundos de sinal, na faixa de frequência de 10 Hz a 10 KHz. Para isso, foram utilizados:

- Um condicionador de sinais Nexus, da B&K, do tipo 2692;
- Um micro computador;
- Dois acelerômetros, da B&K, do tipo 4371;
- Dois acelerômetros, da B&K, do tipo 8309;
- Uma placa A/D, da National Instruments, BNC – 2110;
- Um calibrador de acelerômetro, da B&K, tipo 4294, com frequência de 159.2 Hz e nível de 10 m/s^{-2} .

A cadeia de instrumentação e o esquema de aquisição dos dados estão ilustrados nas Figuras 5.7 e 5.8, respectivamente.




Figura 5.7. Cadeia de instrumentação.

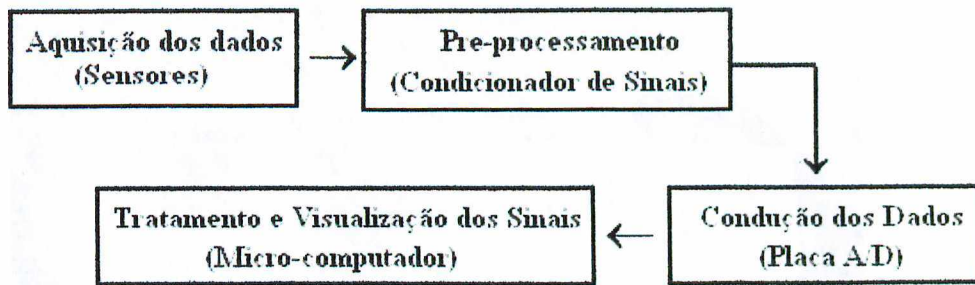


Figura 5.8. Esquema de aquisição dos dados

As posições dos sensores estão indicadas nas Figuras 5.9, 5.10 e 5.11.




Figura 5.9. Acelerômetros tipo 8309, fixados nos mancais 2 e 6.




Figura 5.10. Acelerômetros tipo 4371, fixados nos mancais 3 e 5.




Figura 5.11. Acelerômetro tipo 4371, fixado no mancal 4

Os sensores do tipo 8309 foram fixados nos mancais por meio de roscas, ao passo que os do tipo 4371 foram por meio de base magnética.

Vale lembrar que os canais 1 e 2 do condicionador de sinais foram utilizados, respectivamente, para os sensores (tipo 8309) fixados nos mancais 6 e 2, e (tipo 4371) nos mancais 3 e 5. Para o mancal 4 utilizou-se o canal 1. As aquisições foram feitas para os mancais 2 e 6, 3 e 5 e para o 4 separadamente, uma vez que o condicionador utilizado possui apenas dois canais.

5.3.1. Calibração dos sensores

Os sensores do tipo 8309 (frequências naturais de montagem $f_n = 180$ KHz) foram calibrados para ganhos de 3.16 mV/ms⁻² no amplificador de sinais. E os sensores do tipo 4371 ($f_n = 42$ KHz), foram calibrados para ganhos de 31.6 μ V/ms⁻².

Dos sinais calibrados, obtiveram-se os fatores de calibração dos acelerômetros, para serem aplicados nos sinais adquiridos. Para o caso dos sensores do tipo 8309, esses fatores são de 128.5 ms⁻²/V e 127.1 ms⁻²/V, para os canais 1 e 2, respectivamente. Já para os acelerômetros com $f_n = 42$ KHz, estes são de 58.7 ms⁻²/V para ambos os canais.

5.3.2. Procedimento de Aquisição dos dados

Como o principal objetivo do trabalho é verificar a condição do sinal coletado para fins de manutenção preditiva em tempo real, monitoraram-se os sinais dos mancais 2 e 6, com a presença de um ventilador radial (Figura 5.12) operando do lado da bancada experimental com velocidade de rotação de 2204 rpm o tempo todo, a fim de se simular um ambiente industrial, onde há mais de uma máquina funcionando ao mesmo tempo. As aquisições foram feitas para cinco tipos de sinais:

- “Sinal ok”. Considerado bom, com a instrumentação em perfeitas condições e com os sensores posicionados em seus devidos lugares.
- “Sinal Problemas de Instrumentação”, Neste caso foram incluídos os cabos BNC desconectados da placa de aquisição ou do condicionador, os cabos dos acelerômetros desconectados do condicionador ou dos sensores, os cabos BNC danificados e com o condicionador de sinais desligado.
- “Sinal Sensores Trocados”. Aquisições foram realizadas com os dois sensores trocados de posição.
- “Sinal Máquina Desligada”. Principalmente em ambientes industriais, as máquinas não operam isoladamente. Com a máquina monitorada estando desligada, foi possível adquirir os sinais advindos das vibrações de outro equipamento (ventilador radial).
- “Sinal Eventos Aleatórios”. Para se averiguar a influência de eventos transientes externos à operação da bancada, na integridade dos sinais, realizaram-se aquisições dos sinais com impactos aleatórios aplicados na estrutura do sistema.




Figura 5.12. Ventilador Radial.

A bancada experimental permaneceu funcionando durante 9 dias ininterruptos, até que um dos rolamentos apresentasse falha. No 9º dia ocorreu uma falha na gaiola do rolamento do mancal 2, conseqüentemente, o motor elétrico fundiu. O desgaste prematuro dos rolamentos deveu-se ao fato de trabalharem sem lubrificação e mancal do sistema com o rolamento já sem a gaiola está ilustrado na Figura 5.13.




Figura 5.13. Mancal do rolamento com a gaiola deteriorada

As aquisições foram realizadas diariamente, de acordo com a Figura 5.14, onde estão mostrados os números de ensaios efetuados para o sinal considerado bom em função dos dias de funcionamento da bancada experimental. Nos dias com mais de um ensaio, os dados foram coletados para intervalos de tempo aproximadamente iguais desde às 8 horas da manhã, até às 7 horas da noite. Para o caso dos dias com apenas um ensaio, estes sinais foram adquiridos somente na parte da manhã (\approx às 8 horas).

Após a deterioração da gaiola do rolamento (gaiola soltou-se por inteiro), ou seja, no 10º dia de coleta, utilizando-se um novo motor elétrico, adquiriram-se alguns sinais para a bancada funcionando por mais 1 hora. Nos 11º e 12º dias, a bancada permaneceu funcionando três e quatro horas ininterruptas, respectivamente, sem a gaiola, com os ensaios realizados de hora em hora.




Figura 5.14. Números de ensaios efetuados para o sinal considerado bom em função dos dias de funcionamento da bancada experimental.

Foram adquiridos 31 “Sinais ok”, para os mancais 2 e 6 e 21 para os mancais 3, 4 e 5.

Os “Sinais Problemas de Instrumentação” se deram num total de 22 e 24, para os mancais 2 e 6, respectivamente. E os “Sinais Sensores Trocados” foram de 23 e 22, respectivamente.

Foram coletados 30 dados com a bancada experimental desligada e 26 para os “Sinais Eventos Aleatórios”.

Vale ressaltar que a coleta dos dados para as cinco categorias de sinais foi efetuada aleatoriamente durante os períodos de aquisições mostrados na Figura 5.14.

5.4. Características do Sistema

Considerando-se a pista externa dos rolamentos estacionária, foram determinadas as frequências características dos defeitos da gaiola, da pista interna, da pista externa e da esfera, por meio das respectivas equações apresentadas no Capítulo II.

Os valores dessas frequências, para os rolamentos autocompensadores de esferas e para os rígidos de carreira simples de esferas, podem ser verificados na Tabela 5.2.

Tabela 5.2. Frequências Características dos defeitos nos rolamentos

Frequências Características	Autocompensadores	Rígidos
f_g (Hz)	21.5	21.5
f_{dpi} (Hz)	314	279
f_{dpe} (Hz)	193	172
f_{de} (Hz)	218	223

Com a utilização de um acelerômetro piezoelétrico do tipo 8309 da B&K, e um martelo de impacto, também da B&K, do tipo 8202, obtiveram-se as FRF(s) (Funções Resposta em Frequência) para cada um dos elementos da bancada experimental. Portanto, fixou-se o acelerômetro num mancal, excitando-se os demais e o próprio mancal, repetindo-se a operação para cada rolamento.

A aquisição dos sinais para determinação das FRF(s), cuja cadeia de instrumentação está mostrada na Figura 5.15, foi executada por meio de um analisador de sinais do tipo SD380 da Scientific Atlanta, com a máxima frequência do espectro em 10 KHz e uma resolução em frequência de 12.6 Hz, sendo utilizados o estimador H_1 para o computo das FRF, janela exponencial 3 e 36 aquisições de dados em cada ensaio. A resolução pobre em frequência se

justifica pelo fato de o objetivo deste trabalho ser o de identificar regiões que caracterizem o ponto de medição e não as frequências naturais do sistema.

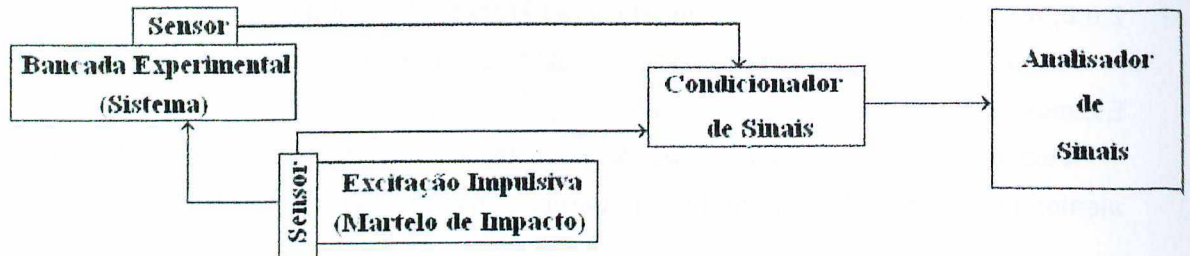


Figura 5.15. Cadeia de Instrumentação para determinação das FRF(s) do sistema

A análise das FRF pode ser sintetizada na Figura 5.16, referente às Magnitudes, em escala logarítmica (dB - ref. 1 m/s^2), em função da frequência, para as FRF(s) pontuais de ambos os mancais (2 e 6) de rolamentos autocompensadores de esferas, com o sistema desligado. As curvas da Figura 5.17 representam os espectros dos sinais coletados para ambos os mancais, com o sistema funcionando.




Figura 5.16. Magnitudes das FRF(s) dos mancais 2 e 6




Figura 5.17. Espectro dos sinais coletados para os mancais 2 e 6.

Analisando-se as Figuras 5.16 e 5.17, as quais apresentam resoluções em frequência de 12.6 e 1 Hz, respectivamente, procurou-se determinar regiões de baixa energia vibratória relativa para um mancal e simultaneamente elevada para o outro. Com isso, escolheram-se seis faixas de frequências, indicadas na Tabela 5.3, sendo que quatro delas são de baixa energia para o mancal 2 e duas para o mancal 6. Um exemplo de banda de frequência selecionada, está mostrado nas Figuras 5.16 e 5.17, onde a faixa encontra-se demarcada pelo retângulo preto.

Tabela 5.3. Regiões Características dos mancais 2 e 6.

Casos	Bandas de Frequências [Hz]
Banda 1	566 – 640
Banda 2	7055 – 7376
Banda 3	10 – 60
Banda 4	800 – 900
Banda 5	1600 – 1700
Banda 6	2300 – 2600

Os casos de bandas indicadas de 1, 3, 4 e 5 são faixas de frequências de baixa energia vibratória para o mancal 2, e as bandas 2 e 6 são para o mancal 6.

Foi realizada a seleção dessas regiões para se estimarem parâmetros que estejam relacionados com características distintas dos dois mancais a serem monitorados (Meola et al., 2005).

5.5. Determinação de parâmetros indicativos da qualidade do sinal e de falhas em rolamentos

Para o monitoramento da qualidade dos sinais coletados nos mancais 2 e 6 (Figura 5.2), estimaram-se 22 parâmetros a serem selecionados como os mais sensíveis à anomalias. Esses parâmetros são representados na forma de símbolos, dados por RMS_i e RSR . Onde $i = 1, 2, \dots, 21$.

O RMS_1 é o nível de energia global do sinal, o qual foi estimado principalmente para se detectar sinal medido com máquina desligada.

Os RMS_i , com $i = 2, 3, \dots, 7$, tratam-se dos níveis de energia nas bandas de frequências para os casos definidos como Banda de 1 até 6 (Tabela 5.2), respectivamente. Esses parâmetros foram determinados com a finalidade de serem possíveis indicativos de sensores trocados de posição, uma vez que representam características distintas de cada um dos dois mancais. Portanto, propõe-se que o nível do sinal na região característica de baixa energia para um mancal aumente quando o sensor for trocado de lugar.

Para se estimar o RMS_8 , o qual é o nível de energia do sinal na banda de 3300 a 4000 Hz, analisou-se o espectro dos sinais adquiridos com a bancada experimental desligada e o ventilador radial ligado. O espectro, em escala logarítmica, está mostrado na Figura 5.18, onde encontra-se destacada a banda de 3300 a 4000 Hz.

Escolheu-se esta faixa de frequência com o objetivo do parâmetro distinguir o sinal de máquina desligada do com problema de instrumentação, principalmente quando o condicionador de sinais encontra-se desligado. Justifica-se a determinação de tal parâmetro, pois se espera que os níveis nesta banda, decrescerão quando houver problemas de instrumentação.

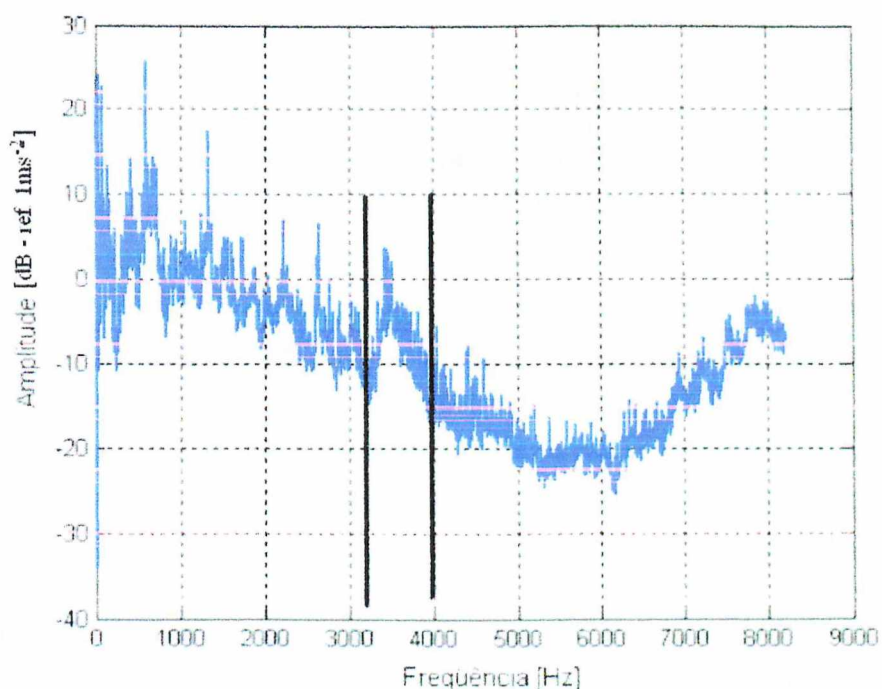


Figura 5.18. Espectro dos sinais adquiridos com a bancada experimental desligada e o ventilador radial ligado.

Os parâmetros RMS_i , com $i = 9, 10, 11$ e 12 , representam, respectivamente, os níveis de energia nas frequências de rotação do eixo da bancada (56.3 Hz), de rede (60 Hz), de 33.8 Hz e de 37.4 Hz e respectivos harmônicos. As análises harmônicas centradas nestas três últimas frequências foram realizadas com intuito de se verificar possíveis problemas na instrumentação. Acredita-se que os níveis para a frequência de 60 Hz e seus harmônicos aumentarão quando houver algum cabo estragado ou desconectado, por exemplo.

Optou-se pela análise harmônica nas frequências de 33.8 e 37.4 Hz, para que se possa diferenciar o sinal com problemas de instrumentação dos sinais "ok" e de máquina desligada. A determinação dessas frequências foi efetuada, via análise espectral dos sinais adquiridos de ambos os mancais (2 e 6), Figura 5.19, onde estão indicadas. As ordens destas frequências contemplam dois picos de amplitudes significativas, o primeiro para o mancal 6 e o segundo para o mancal 2. Espera-se que a energia nestas frequências básicas somadas com as energias de seus harmônicos respectivos harmônicos, decresça para a máquina desligada com relação ao sinal "ok" e que sejam menores ainda para problemas de instrumentação, principalmente por não coincidirem com a frequência de rede.




Figura 5.19. Espectro dos sinais adquiridos de ambos os mancais (2 e 6), com indicação das frequências de 33.8 e 37.4 Hz.

Os RMS_i , com $i = 13, 14, \dots, 21$ são, respectivamente, os mesmos que os RMS_i , com $i = 2, 3, 4, 5, 6, 7, 8, 11$ e 12 , porém normalizados em relação nível de energia global do sinal. Isso é devido ao fato de se tentar evitar que os parâmetros sejam sensíveis à evolução de falhas nos rolamentos.

O RSR, por sua vez, representa a relação sinal ruído, ou seja, é a razão entre o nível de energia para os harmônicos de 60 Hz e o nível global do sinal.

Devido ao fato de os sinais monitorados serem coletados com propósito de se realizar manutenção preditiva em rolamentos, estimaram-se 9 parâmetros para se selecionar quais são os melhores indicativos de falhas nesses elementos. São eles:

- Parâmetro 1: Nível global de energia do sinal (dB – ref. 1 ms^{-2});
- Parâmetro 2: Valor máximo de Pico (ms^{-2});
- Parâmetro 3: Curtose;
- Parâmetro 4: Fator de Crista;
- Parâmetro 5: Média dos máximos valores de pico do envelope de aceleração na faixa de frequência de 10 a 100 Hz (ms^{-2});
- Parâmetro 6: Média dos máximos valores de pico do envelope de aceleração na faixa de frequência de 50 a 1000 Hz (ms^{-2});
- Parâmetro 7: Média dos máximos valores de pico do envelope de aceleração na faixa de frequência de 500 a 8000 Hz (ms^{-2});
- Parâmetro 8: Momento Central de Sexta Ordem;

➤ Parâmetro 9: Fator K.

As faixas de frequências para os envelopes foram baseadas no artigo sobre identificação de estágios de falhas em rolamentos (Pereira e Barbosa, 2002).

Com relação aos parâmetros estatísticos, tomou-se por base o artigo de Bezerra, Arruda e Pederiva (2004). Os autores referem-se ao fator K como sendo o produto entre o valor RMS do sinal e a curtose, ou momento central de quarta ordem.

Para análise de parâmetros de manutenção preditiva, utilizou-se os dados coletados do mancal 2, o qual apresentou defeito em sua gaiola durante o funcionamento do sistema. A escolha dos parâmetros fundamentou-se no aumento abrupto de seus níveis no momento de ocorrência da falha na gaiola. Para isso, traçaram-se as curvas dos valores dos parâmetros (de três em três) e verificaram-se quais deles eram mais significativos. Vale ressaltar que esses valores foram normalizados entre 0 e 1, em relação ao valor máximo de cada um, para fins de comparações entre si.

5.5.1. Análise de Sensibilidade

A Figura 5.20 mostra as curvas dos níveis globais de energia para os sinais considerados "ok", com problemas de instrumentação e do evento "máquina desligada", para o mancal 6.

Como os níveis globais para os dois mancais são semelhantes, foram mostradas apenas as curvas do mancal 6.




Figura 5.20. Curvas dos níveis globais de energia para os sinais considerados "ok", com problemas de instrumentação e do evento "máquina desligada", para o mancal 6.

Pode-se observar, na Figura 5.20, que os sinais com problemas de instrumentação possuem grandes desvios. Isto se deve ao fato de que neste evento foram agrupados os problemas de cabo e instrumentação desligada. A magnitude deste desvio, relativo aos desvios dos outros eventos, inviabiliza um observador de instrumentação, uma vez que os mesmos podem assumir qualquer valor. Como os sinais de instrumentação desligada estão, em média, abaixo dos níveis de vibração do evento "máquina desligada", na região característica do mesmo, inferiu-se que o evento "instrumentação desligada" fosse tratado por uma lógica simples do tipo baixo e alto. Logo, o evento "instrumentação desligada" foi retirado do conjunto de dados. Verifica-se que os sinais "ok" encontram-se com níveis de energia por volta de 10 dB, que os eventos "máquina desligada" estão abaixo deles e que os sinais com problema de instrumentação, exceto instrumentação desligada, estão em média acima deles.

Com isso, consegue-se distinguir com maior precisão as três categorias de sinais, como visto na Figura 5.21.




Figura 5.21. Curvas dos níveis globais de energia para as três categorias de sinais, com dados de instrumentação de níveis acima de 10 dB.

Sendo assim, as análises para sinais com problemas de instrumentação foram feitas apenas com os dados de níveis acima de 10 dB, pois abaixo dos mesmos deve-se preocupar em diferenciar somente sinais com a máquina desligada dos com instrumentação desligada, condicionador de sinais, por exemplo.

Realizou-se, portanto, uma análise de sensibilidade, para se verificar quais dos 22 parâmetros são melhores indicativos da integridade do sinal. Tal análise foi efetuada via Teste de Hipótese Nula, com confiança de 95 %, comparando-se as médias dos valores dos parâmetros de sinal "ok" com as médias dos com problemas de instrumentação, dos de sensores trocados, dos de máquina desligada e de eventos aleatórios, separadamente.

Para se rejeitar a hipótese de que as médias dos valores são iguais, selecionaram-se, em princípio, os parâmetros com razão entre t_0 e t_{α} , maiores do que 1.5, para cada um dos mancais.

Desses parâmetros, escolheram-se os mais sensíveis à possíveis anomalias de sinais, para ambos os mancais, via análise visual, utilizando-se gráficos "Boxplot". Preocupou-se, com os parâmetros que apresentassem maiores distinções entre as quatro classes, ou pelo menos que fossem significativas para diferenciar de duas a três delas.

5.6. Desenvolvimento das Redes Neurais e da Lógica Fuzzy

Para o desenvolvimento das redes neurais e da lógica fuzzy utilizaram-se cerca de 80 % dos dados para cada categoria de sinal, sendo os outros 20 % separados para teste.

No desenvolvimento da lógica fuzzy, utilizou-se o método de Mandani. As funções de pertinência utilizadas foram do tipo triangular para as quatro saídas do sistema de inferência. No caso das entradas, as funções foram trapezoidais para os parâmetros com poucas dispersões e gaussianas de dois lados para os com maiores dispersões.

Independente do método de desfuzzificação, há casos (sinais com grandes desvios) em que um determinado teste não se enquadra em nenhuma regra. Se a função de pertinência for trapezoidal e o conjunto de dados apresentar maiores desvios, os valores dos graus de pertinência dos parâmetros a serem testados anularão as regras fuzzy, ou seja, existem limites onde as curvas atingem o valor zero, e o parâmetro não apresenta probabilidade alguma de pertencer a um determinado conjunto. Isso se deve ao fato de quando utilizado o conectivo "AND" na regra, uma operação de multiplicação é realizada, portanto, basta um parâmetro apresentar grau de pertinência igual a zero que a regra torna-se nula. Por outro lado, se para o mesmo caso for utilizada uma função gaussiana, não ocorrerá anulação de nenhuma regra, uma vez que embora tendendo a zero, a curva não atinge este valor, isso possibilita que o dado testado pertença, a um conjunto mesmo com uma pequena probabilidade.

A determinação dos limites das funções foi efetuada por meio dos gráficos "Boxplot" das quatro categorias de sinais. Atribuíram-se os valores 0, 1, 2 e 3, nas funções triangulares, para as saídas de sinal "ok", problemas de instrumentação, sensores trocados e máquina desligada, respectivamente, como mostrado na Figura 5.22.

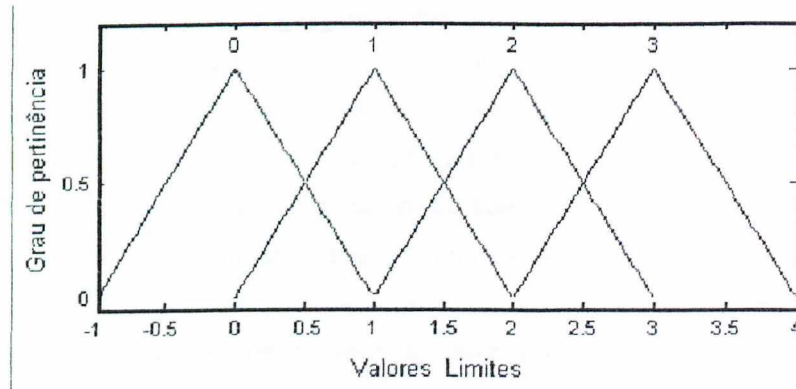


Figura 5.22. Funções de pertinência triangulares para as saídas do sistema de inferência

Para as funções trapezoidais, os limites foram baseados nos valores superiores dos bigodes dos gráficos "Boxplot" de dados considerados de baixos níveis e nos bigodes inferiores dos gráficos de dados com altos níveis. Estas funções estão representadas na Figura 5.23.




Figura 5.23. Funções de pertinência trapezoidais para as entradas do sistema de inferência com dados sem dispersões significativas

Um exemplo de determinação dos limites da função de pertinência trapezoidal está mostrado na Figura 5.24, a qual representa os gráficos "Boxplot" de dois sinais distintos, para um mesmo parâmetro.




Figura 5.24. Exemplo de determinação dos limites da função de pertinência via gráficos “Boxplot” de dois sinais distintos, para um mesmo parâmetro.

Observa-se na Figura 5.24 que os dados de ambos os sinais estão normalmente distribuídos em torno da mediana (linha vermelha central), sem apresetarem dispersões significativas. Verifica-se também, nitidamente, a distinção entre os níveis de ambos os sinais, implicando na confiança de se utilizar funções trapezoidais de conjuntos considerados altos e baixos, como ilustrado na Figura 5.23.

Para as funções gaussianas de dois lados, optou-se por utilizar as medianas dos gráficos “Boxplot” como valores limites da função e 3 vezes o desvio padrão como valor do espalhamento da curva (Capítulo IV, pág. 44). Em casos em que os valores de desvios eram muito grandes, como por exemplo, abaixo 6 dB, tomou-se por base a diferença entre os valores de bigodes inferiores e posteriores dos gráficos da categoria em análise, dividida por 3. Para exemplificar a análise, esses gráficos “Boxplot” estão mostrados na Figura 5.25.

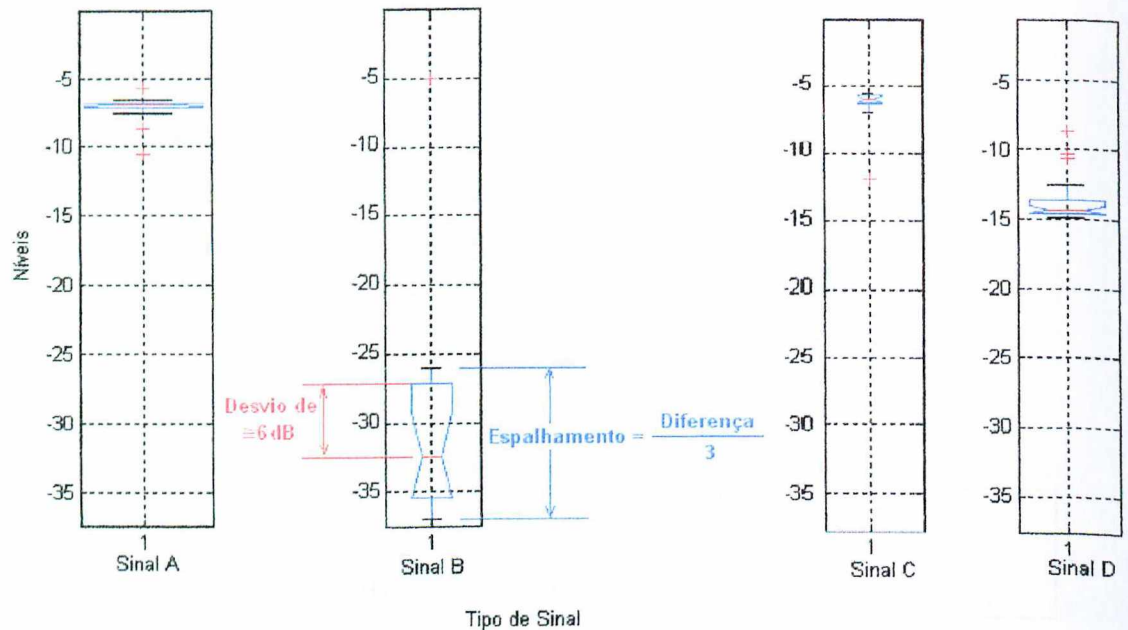


Figura 5.25. Exemplo de Gráficos "Boxplot" para determinação dos limites da função gaussiana.

Os quatro casos da Figura 5.25 foram tratados de forma que fossem criados três conjuntos, alto, médio e baixo. Portanto, os primeiro e terceiro gráficos, pertencem ao conjunto baixo, o quarto gráfico ao conjunto médio e o segundo ao conjunto baixo. Este último, como possui grande desvio padrão, tomou-se por base os valores de seus bigodes para o espalhamento da curva. As funções de pertinência gaussiana estão representadas na Figura 5.26.

Na construção dessas funções, os casos dos conjuntos alto e baixo, tiveram, portanto, seus limites como valor da mediana e para o caso de se ter conjuntos médios, utilizaram-se os valores dos bigodes superior e inferior no lugar das medianas para os dois limites.




Figura 5.26. Funções de pertinência gaussianas de dois lados para as entradas do sistema de inferência de dados com dispersões significativas

O desenvolvimento das regras fuzzy também foi baseado em fundamentos estatísticos, utilizando-se os mesmos gráficos "Boxplot", e em inferências sobre os possíveis comportamentos físicos do sistema.

Utilizou-se o método da média dos máximos na desfuzzificação do sistema fuzzy.

Os parâmetros utilizados como dados de entrada para as redes neurais foram os mesmos aplicados no desenvolvimento do projeto fuzzy, uma vez que a performance de uma rede neural é fortemente dependente dos sintomas aplicados na sua entrada (Meola et al, 2004).

Com relação à rede, foram criadas quatro classes distintas de sinais a serem classificados estatisticamente pela rede probabilística. As classes são para sinal "ok", problemas de instrumentação, sensores trocados de posição e máquina desligada. Foi utilizado um modelo de classificação via Rede Neural Probabilística (PNN), na qual foi empregada a função de ponderação de Kernel do tipo gaussiana, devido ao fato de satisfazer as exigências do método de Parzen, apresentar um bom comportamento matemático e possuir facilidade no cálculo.

Por fim, os dados para teste, foram classificados utilizando redes neurais e lógica fuzzy para validação da metodologia proposta.

Capítulo VI

Resultados e Análises

6.1. Parâmetros indicativos da qualidade do sinal

6.1.1. Mancal 2

Na Tabela 6.1 estão mostradas as razões entre t_0 e t_{α} , da Distribuição t de Student, dos 22 parâmetros estimados para as quatro categorias de sinal, problemas de instrumentação, sensores trocados de posição, máquina desligada e evento aleatório ao sinal dos elementos da bancada, comparadas com sinal "ok".

Tabela 6.1. Razões entre t_0 e t_{α}

Parâmetros		Problemas de Instrumentação	Sensor Trocado	Máquina Desligada	Evento Aleatório
Global	RMS ₁	9,9	1,1	10,8	0,0
Banda 566 – 640 Hz	RMS ₂	0,7	1,4	15,9	0,0
Banda 7055 – 7376 Hz	RMS ₃	3,7	1,1	16,2	0,1
Banda 10 – 60 Hz	RMS ₄	12,9	1,0	5,9	0,2
Banda 800 – 900 Hz	RMS ₅	1,5	0,0	17,1	0,1
Banda 1600 – 1700 Hz	RMS ₆	3,0	0,1	17,8	0,0
Banda 2300 – 2600 Hz	RMS ₇	4,8	2,3	13,4	0,1
Banda 3300 – 4000 Hz	RMS ₈	4,0	0,7	17,6	0,1
Harmônicos 56.3 Hz	RMS ₉	1,0	1,1	17,9	0,2
Harmônicos 60 Hz	RMS ₁₀	4,7	1,1	11,6	0,3
Harmônicos 33.8 Hz	RMS ₁₁	1,2	1,1	10,3	0,1
Harmônicos 37.4 Hz	RMS ₁₂	1,6	1,2	16,8	0,0
RMS ₂ normalizado	RMS ₁₃	4,5	1,7	7,2	0,1
RMS ₃ normalizado	RMS ₁₄	9,0	0,1	6,2	0,0
RMS ₄ normalizado	RMS ₁₅	8,9	0,3	5,1	0,3
RMS ₅ normalizado	RMS ₁₆	5,6	3,7	6,8	0,1
RMS ₆ normalizado	RMS ₁₇	7,4	4,2	7,5	0,0
RMS ₇ normalizado	RMS ₁₈	9,8	4,7	13,2	0,1
RMS ₈ normalizado	RMS ₁₉	9,3	1,8	7,9	0,1
RMS ₁₁ normalizado	RMS ₂₀	11,1	0,3	2,0	0,2
RMS ₁₂ normalizado	RMS ₂₁	11,8	0,5	11,2	0,1
Relação Sinal/Ruído	RSR	0,5	0,2	3,9	0,3

Os valores da Tabela 6.1 que estão em **negrito**, são referentes aos parâmetros que tiveram razões entre t_0 e t_x maiores ou iguais a 1.5.

Como era de se esperar, pode-se observar que o evento “eventos aleatórios” não implicou em variações significativas nos valores dos parâmetros estudados, quando comparados com o evento “sinal ok”. Isto confirma que qualquer incidente eventual ocorrido no sistema não interfere na qualidade do sinal coletado, uma vez que os parâmetros analisados são referentes a valores médios.

A título de ilustração, na Figura 6.1 estão mostradas as amplitudes de aceleração em função do tempo, de um sinal considerado “ok” e de um sinal com eventos aleatórios aplicados à bancada experimental.




Figura 6.1. Amplitudes de aceleração no tempo, de um sinal considerado “ok” e de um sinal com eventos aleatórios aplicados à bancada experimental.

Observa-se na Figura 6.1 que não há diferenças explícitas entre os valores médios de amplitude do sinal “ok” e do com eventos transientes aplicados à bancada, verificando-se evidentemente a ocorrência destes nas regiões de 5 a 10 segundos (s), de 15 a 20 s, de 20 a 25 s e de 35 a 40 s.

Os cinco parâmetros selecionados, via análise visual dos gráficos “Boxplot”, como os mais sensíveis à integridade do sinal, foram os RMS_1 , RMS_6 , RMS_{18} , RMS_{19} e RMS_{21} .

Os parâmetros relacionados com ruído de rede, tais como o nível de energia dos harmônicos de 60 Hz (RMS_{10}) e a relação sinal ruído (RSR), não se mostraram muito eficientes na detecção de sinais com problemas de instrumentação, possivelmente, devido à frequência de rotação da bancada ser próxima a 60 Hz e harmônicos.

Na Figura 6.2 são mostrados os gráficos Boxplot do nível de energia global do sinal (RMS_1) para as quatro classes de sinais, "ok", com problemas de instrumentação, de sensores trocados e com máquina desligada.

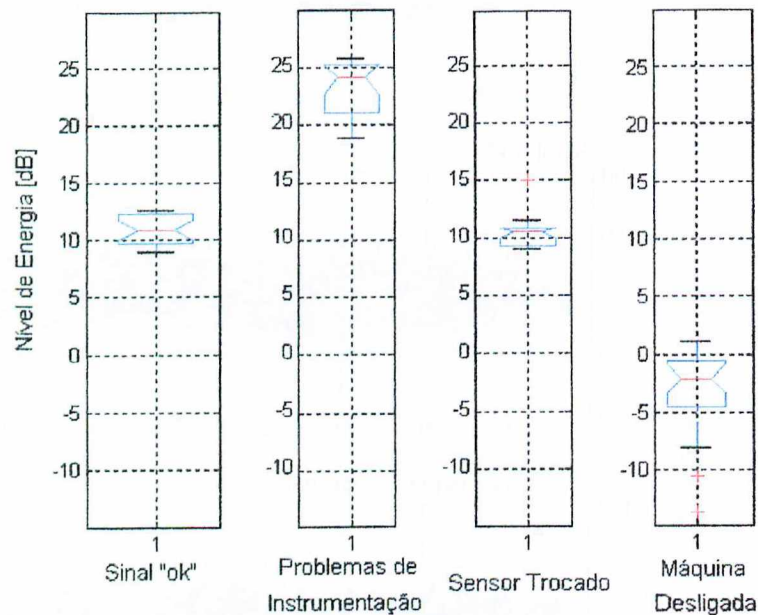



Figura 6.2. Gráficos "Boxplot" do RMS_1 para as quatro categorias de sinal, do mancal 2

Pode-se verificar que o nível de energia do sinal de máquina desligada encontra-se cerca de 8 dB abaixo dos níveis para sinal "ok" e de sensores trocados, e cerca de 17 dB abaixo dos de problemas de instrumentação. Tal fato destaca o parâmetro RMS_1 como um excelente indicativo de sinal coletado com a máquina desligada, apesar de não se mostrar apto a diferenciar sinal "ok" de sensor trocado, devido à bancada experimental ser simétrica e os mancais monitorados terem rolamentos do mesmo tipo.

As funções de pertinência do sistema de inferência fuzzy, com respectivos valores limites, para o parâmetro de entrada RMS_1 , estão mostradas na Figura 6.3.

Na Figura 6.4 são mostrados os gráficos "Boxplot" do RMS_6 , nível de energia na banda de frequência de 1600 a 1700 Hz (Banda 5) para as quatro classes de sinais, "ok", com problemas de instrumentação, de sensores trocados e com máquina desligada.



Limites do Conjunto Alto: [2 8 40 40]

Limites do Conjunto Baixo: [-40 -40 2 8]

Figura 6.3. Funções de pertinência trapezoidais para o parâmetro de entrada RMS_1 , para o mancal 2




Figura 6.4. Gráficos "Boxplot" do RMS_6 para as quatro categorias de sinal, do mancal 2

Pode-se verificar na Figura 6.4 que os níveis do parâmetro RMS_6 para sinal com sensores trocados estão acima dos de sinal "ok". Tal fato era de se esperar, uma vez que a Banda 5 é de baixa energia vibratória para o mancal 2 e alta para o 6. Mesmo com intervalos estreitos entre as duas categorias, o parâmetro mostrou-se capaz de indicar problemas de sinal com sensores trocados. Como este é o objetivo do parâmetro, a regra fuzzy foi definida para conjuntos de níveis alto e baixo, considerando-se que se o nível de energia do sinal for alto, o mesmo pode ser de sensores trocados.

As funções de pertinência do sistema de inferência fuzzy, com respectivos valores limites, para o parâmetro de entrada RMS_6 , estão mostradas na Figura 6.5.




Figura 6.5. Funções de pertinência gaussianas de dois lados para o parâmetro de entrada RMS_6 , para o mancal 2

Os gráficos "Boxplot" do RMS_{18} , nível de energia normalizado em relação ao nível global, na banda de frequência de 2300 a 2600 Hz (Banda 6) para os quatro tipos de sinais, "ok", com problemas de instrumentação, de sensores trocados e com máquina desligada, estão mostrados na Figura 6.6.





Figura 6.6. Gráficos "Boxplot" do RMS_{18} para as quatro categorias de sinal, do mancal 2

Observa-se na Figura 6.6 que os níveis do parâmetro RMS_{18} para sinal "ok" estão acima dos de sinal com sensores trocados. Estes níveis são justificados devido à Banda 6 ser de baixa energia vibratória para o mancal 6 e alta para o 2. Portanto, o parâmetro atinge as expectativas de ser um bom indicativo de sinal com sensores trocados. A regra fuzzy para o

RMS_{18} foi efetuada, também para conjuntos de níveis alto e baixo, considerando-se que se o nível de energia do sinal for baixo, há possibilidade do mesmo ser de sensores trocados.

As funções de pertinência do sistema de inferência fuzzy, com respectivos valores limites, para o parâmetro de entrada RMS_{18} , estão mostradas na Figura 6.7.



Limites do Conjunto Alto: [2.5 -4.9 20 20]

Limites do Conjunto Baixo: [40 -40 5 -8]

Figura 6.7. Funções de pertinência gaussianas de dois lados para o parâmetro de entrada RMS_{18} , para o mancal 2

Com relação aos parâmetros RMS_{19} e RMS_{21} , seus gráficos "Boxplot" são representados pelas Figuras 6.8 e 6.9, respectivamente. Vale lembrar, que o primeiro trata-se do nível de energia na banda de frequência de 3300 a 4000 Hz e o segundo, o nível de energia dos harmônicos de 37.4 Hz, ambos normalizados em relação ao nível global do sinal.




Figura 6.8. Gráficos "Boxplot" do RMS_{19} para as quatro categorias de sinal, do mancal 2




Figura 6.9. Gráficos “Boxplot” do RMS_{21} para as quatro categorias de sinal, do mancal 2

Pode-se notar nas Figuras 6.8 e 6.9 que os níveis de ambos os parâmetros, para sinal com problemas de instrumentação estão aproximadamente 11 e 9 dB abaixo dos de sinal com máquina desligada, respectivamente. Tal fato, valida a proposta de que estes parâmetros são aptos a diferenciar sinal com problemas de instrumentação de sinais com a máquina desligada. Propôs-se uma regra fuzzy para os RMS_{19} e RMS_{21} de que níveis classificados como baixos fossem classificados como sinal com problemas de instrumentação.

As funções de pertinência do sistema de inferência fuzzy, com respectivos valores limites, para os parâmetros de entrada RMS_{19} e RMS_{21} , estão mostradas nas Figuras 6.10 e 6.11.





Figura 6.10. Funções de pertinência gaussianas de dois lados para o parâmetro de entrada RMS_{19} , para o mancal 2



Limites do Conjunto Alto: [3 -16 40 40]

Limites do Conjunto Médio: [2.4 -22.5 2.4 -20.4]

Limites do Conjunto Baixo: [40 -40 3 -32]

Figura 6.11. Funções de pertinência gaussianas de dois lados para o parâmetro de entrada RMS_{21} , para o mancal 2

As regras utilizadas no Sistema de Inferência Fuzzy para o mancal 2 estão mostradas a seguir:

1. **Se** (RMS_1 é alto) **e** (RMS_6 é baixo) **e** (RMS_{18} é alto) **e** (RMS_{19} é alto) **e** (RMS_{21} é alto) **Então** (Sinal é "ok");
2. **Se** (RMS_1 é baixo) **e** (RMS_{19} é médio) **e** (RMS_{21} é médio) **Então** (Sinal é "Máquina Desligada");
3. **Se** (RMS_1 é alto) **e** (RMS_6 é alto) **e** (RMS_{18} é baixo) **e** (RMS_{19} é alto) **e** (RMS_{21} é alto) **Então** (Sinal é "Sensor Trocado");
4. **Se** (RMS_{19} é baixo) **e** (RMS_{21} é baixo) **Então** (Sinal é "Problemas de Instrumentação")

Foram desenvolvidas apenas quatro regras, em vez de se realizarem todas as possíveis combinações dos parâmetros, devido ao fato de se ter escolhido os parâmetros mais adequados para cada situação, com respectivos valores limites de seus níveis, tornando-se desnecessária a utilização de todas as combinações.

Do treinamento da Rede Neural Probabilística e do desenvolvimento da lógica fuzzy, obtiveram-se os resultados apresentados na Tabela 6.2.

Tabela 6.2. Resultados obtidos via Rede PNN e Lógica Fuzzy para o mancal 2

Tipo de Sinal	Número de Testes	Número de Erros da Lógica Fuzzy	Número de Erros da PNN
"ok"	6	1	0
Problemas de Instrumentação	5	0	0
Sensores Trocados	5	0	1
Máquina Desligada	6	0	0

De acordo com a Tabela 6.2, ambas as ferramentas de classificação da integridade do sinal mostram-se eficientes em suas funções e, comparando-se os resultados obtidos utilizando-se a rede PNN com os via sistema de inferência fuzzy, pode-se verificar que não há diferenças discrepantes.

6.1.2. Mancal 6

Da análise de sensibilidade dos 22 parâmetros estimados para as quatro classes de sinal, problemas de instrumentação, sensores trocados de posição, máquina desligada e evento externo ao sinal dos elementos da bancada, comparadas com sinal "ok", obtiveram-se as razões entre t_0 e t_x , apresentadas na Tabela 6.3.

Tabela 6.3. Razões entre t_0 e t_x

Parâmetros	Problemas de Instrumentação	Sensor Trocado	Máquina Desligada	Evento Aleatório	
Global	RMS ₁	5,8	0,6	9,8	0,0
Banda 566 – 640 Hz	RMS ₂	0,5	0,0	15,6	0,2
Banda 7055 – 7376 Hz	RMS ₃	5,8	0,2	16,4	0,1
Banda 10 – 60 Hz	RMS ₄	6,4	1,3	5,5	0,1
Banda 800 – 900 Hz	RMS ₅	3,5	1,6	23,0	0,1
Banda 1600 – 1700 Hz	RMS ₆	6,0	1,5	24,1	0,2
Banda 2300 – 2600 Hz	RMS ₇	6,1	0,7	10,1	0,0
Banda 3300 – 4000 Hz	RMS ₈	7,6	0,7	21,5	0,0
Harmônicos 56.3 Hz	RMS ₉	2,0	0,3	19,4	0,1
Harmônicos 60 Hz	RMS ₁₀	3,7	1,1	11,1	0,3
Harmônicos 33.8 Hz	RMS ₁₁	2,1	0,3	9,1	0,1
Harmônicos 37.4 Hz	RMS ₁₂	2,8	0,4	17,5	0,0
RMS ₂ normalizado	RMS ₁₃	3,8	3,0	3,9	0,3
RMS ₃ normalizado	RMS ₁₄	6,8	1,1	4,0	0,1
RMS ₄ normalizado	RMS ₁₅	5,6	2,0	3,6	0,2
RMS ₅ normalizado	RMS ₁₆	5,8	4,2	8,4	0,1
RMS ₆ normalizado	RMS ₁₇	7,1	4,0	9,0	0,1
RMS ₇ normalizado	RMS ₁₈	6,9	5,9	1,0	0,0
RMS ₈ normalizado	RMS ₁₉	7,6	1,0	7,1	0,0
RMS ₁₁ normalizado	RMS ₂₀	8,2	1,5	2,4	0,1
RMS ₁₂ normalizado	RMS ₂₁	8,5	1,1	8,6	0,1
Relação Sinal/Ruído	RSR	0,3	1,3	4,4	0,3

Os valores da Tabela 6.3 que estão em negrito, são referentes aos parâmetros que tiveram razões entre t_0 e t_x maiores ou iguais a 1.5. Como já observado e previsto para o mancal 2, os parâmetros de sinais com eventos aleatórios aplicados à bancada não apresentaram diferenças com relação ao sinal "ok".

Os cinco parâmetros selecionados, via análise de gráficos Boxplot, como melhores indicativos da qualidade do sinal adquirido, foram os RMS_1 , RMS_{16} , RMS_{18} , RMS_{19} e RMS_{21} .

Na Figura 6.12 são mostrados os gráficos "Boxplot" do nível de energia global do sinal (RMS_1) para as quatro classes de sinais, "ok", com problemas de instrumentação, de sensores trocados e com máquina desligada.





Figura 6.12. Gráficos "Boxplot" do RMS_1 para as quatro categorias de sinal, do mancal 6

Observa-se na Figura 6.12 que o nível de energia do sinal "ok", de sensores trocados e com problemas de instrumentação estão aproximadamente 10 dB, 11 dB e 18 dB, respectivamente, acima do nível do sinal com a máquina desligada. Como já observado para o mancal 2, pode-se considerar o parâmetro RMS_1 sensível a sinal com máquina desligada.

As funções de pertinência do sistema de inferência fuzzy, com respectivos valores limites, para o parâmetro de entrada RMS_1 , estão mostradas na Figura 6.13.



Limites do Conjunto Alto: [6 9 40 40]

Limites do Conjunto Baixo: [-40 -40 6 9]

Figura 6.13. Funções de pertinência trapezoidais para o parâmetro de entrada RMS_1 , para o mancal 6

Nas Figuras 6.14 e 6.15 são mostrados os gráficos "Boxplot" do RMS_{16} e RMS_{18} , os quais são os níveis de energia normalizados em relação ao nível global do sinal, nas bandas de freqüências de 800 a 900 Hz (Banda 4) e de 2300 a 2600 Hz (Banda 6), respectivamente.




Figura 6.14. Gráficos "Boxplot" do RMS_{16} para as quatro categorias de sinal, do mancal 6




Figura 6.15. Gráficos "Boxplot" do RMS_{18} para as quatro categorias de sinal, do mancal 6

Pode-se verificar nas Figuras 6.14 e 6.15 que os níveis do parâmetro RMS_{16} e do RMS_{18} , para sinal com sensores trocados estão abaixo para o primeiro e acima, para o segundo, dos de sinal "ok". Tal fato era de se esperar, uma vez que a Banda 4 é de alta energia vibratória para o mancal 2 e alta para o 6 e na Banda 6, ocorre o contrário. Tais fatos tornam estes parâmetros aptos a diferenciar sinal "ok" de sensores trocados. As regras fuzzy aplicadas para o mancal 2 também podem ser utilizadas no mancal 6.

As funções de pertinência do sistema de inferência fuzzy, com respectivos valores limites, para os parâmetros de entrada RMS_{16} e RMS_{18} , estão mostradas nas Figuras 6.16 e 6.17, respectivamente.





Figura 6.16. Funções de pertinência gaussianas de dois lados para o parâmetro de entrada RMS_{16} , para o mancal 6



Limites do Conjunto Alto: [3 -4.9 10 0]

Limites do Conjunto Baixo: [40 -40 4.5 -8.1]

Figura 6.17. Funções de pertinência gaussianas de dois lados para o parâmetro de entrada $RMS_{10,6}$, para o mancal 6

As Figuras 6.18 e 6.19 representam os gráficos "Boxplot" do RMS_{19} e RMS_{21} , respectivamente.

Tanto o nível de energia na banda de frequência de 3300 a 4000 Hz quanto o nível de energia dos harmônicos de 37.4 Hz estão para sinal com máquina desligada estão aproximadamente 8 e 5 dB acima dos com problemas de instrumentação, respectivamente. Tais parâmetros são, portanto, capazes de distinguir sinal com problemas de instrumentação de sinal com a máquina desligada.




Figura 6.18. Gráficos "Boxplot" do RMS_{19} para as quatro categorias de sinal, do mancal 6





Figura 6.19. Gráficos "Boxplot" do RMS_{21} para as quatro categorias de sinal, do mancal 6

Vale ressaltar que as mesmas regras fuzzy, para esses parâmetros, utilizadas no mancal 2 foram aplicadas no mancal 6, porém com valores de níveis diferentes.


As funções de pertinência do sistema de inferência fuzzy, com respectivos valores limites, para os parâmetros de entrada RMS_{19} e RMS_{21} , estão mostradas nas Figuras 6.20 e 6.21, respectivamente.



Limites do Conjunto Alto: [3 -14.4 10 0]

Limites do Conjunto Baixo: [40 -40 12 -31.3]

Figura 6.20. Funções de pertinência gaussianas de dois lados para o parâmetro de entrada RMS_{19} , para o mancal 6



Limites do Conjunto Alto: [3 -16 10 -10]

Limites do Conjunto Médio: [5 -22.6 5 -20.7]

Limites do Conjunto Baixo: [40 -40 5 -32.1]

Figura 6.21. Funções de pertinência gaussianas de dois lados para o parâmetro de entrada RMS_{21} , para o mancal 6

As regras utilizadas no Sistema de Inferência Fuzzy para o mancal 6 estão mostradas a seguir:

1. **Se** (RMS_1 é alto) e (RMS_{16} é alto) e (RMS_{18} é baixo) e (RMS_{19} é alto) e (RMS_{21} é alto) **Então** (Sinal é "ok");
2. **Se** (RMS_1 é baixo) e (RMS_{19} é alto) e (RMS_{21} é médio) **Então** (Sinal é "Máquina Desligada");
3. **Se** (RMS_1 é alto) e (RMS_{16} é baixo) e (RMS_{18} é alto) e (RMS_{19} é alto) e (RMS_{21} é alto) **Então** (Sinal é "Sensor Trocado");
4. **Se** (RMS_{19} é baixo) e (RMS_{21} é baixo) **Então** (Sinal é "Problemas de Instrumentação")

Na Tabela 6.4 são apresentados os resultados obtidos do treinamento da Rede Neural Probabilística e do desenvolvimento da lógica fuzzy.

Tabela 6.4. Resultados obtidos via Rede PNN e Lógica Fuzzy para o mancal 6

Tipo de Sinal	Número de Testes	Número de Erros da Lógica Fuzzy	Número de Erros da PNN
"ok"	6	0	0
Problemas de Instrumentação	5	0	0
Sensores Trocados	5	0	0
Máquina Desligada	5	0	0

Segundo os resultados observados na Tabela 6.3, tanto a rede neural quanto a lógica fuzzy apresentaram 100 % de acerto, não apresentando diferenças entre si, quanto às suas capacidades de classificação de sinais coletados.

6.2. Parâmetros indicativos de falhas em rolamentos

Durante o período de funcionamento da bancada experimental, verificou-se que a gaiola do rolamento do mancal 2 foi deteriorada. Os resultados apresentados a seguir baseiam-se na evolução dos níveis para esse mancal. Na Figura 6.22 estão mostradas as amplitudes de aceleração (m/s^2) em função do tempo, para o rolamento do mancal 2, considerado em boas condições e após a falha na gaiola.




Figura 6.22. Amplitudes de aceleração no tempo, para o rolamento do mancal 2, considerado em boas condições e após a gaiola ser deteriorada.

Pode-se verificar na Figura 6.22 que amplitudes do sinal do rolamento com a gaiola deteriorada são cerca de 3 vezes as amplitudes do sinal para o mesmo rolamento considerado em boas condições.

Os espectros dos sinais para o rolamento bom e após a falha estão mostrados na Figura 6.23.




Figura 6.23. Espectros dos sinais para o rolamento bom e após a falha

Observa-se na Figura 6.23 que os níveis de energia para o sinal do rolamento após a falha na gaiola, aumentaram significativamente, porém, não foi possível visualizar o aumento de energia na frequência característica de falha na gaiola.

As curvas dos valores normalizados dos Parâmetros indicados de 1 (RMS), 2 (Pico) e 3 (Curtose) estão mostradas na Figura 6.24. Sabe-se que a falha na gaiola ocorreu no 9º dia de aquisição dos dados, quando foi realizado o 20º ensaio (Figura 5.14 do capítulo anterior). Pode-se, portanto, verificar na Figura 6.24 que os três parâmetros mostraram-se sensíveis à falha na gaiola, onde por volta do ensaio número 20 as curvas apresentaram aumentos bruscos e decresceram abruptamente após a gaiola ter se soltado por inteiro até os sinais se normalizassem novamente. Dos três, as curvas do Pico e da Curtose apresentaram um melhor comportamento, podendo ser considerados bons indicativos do defeito de gaiola.

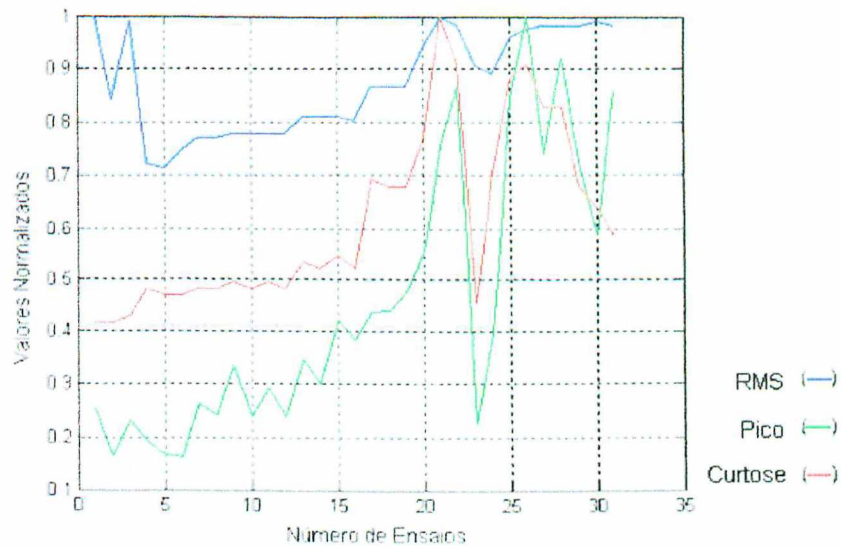


Figura 6.24. Curvas dos valores normalizados dos Parâmetros indicados de 1, 2 e 3.

Na Figura 6.25 estão mostradas as curvas dos Parâmetros 4 (Fator de Crista), 5 (Envelope – 10 a 100 Hz) e 6 (Envelope – 50 a 1000 Hz) as quais apresentaram alterações significativas nas baixas frequências (Envelopes de 10 a 100 Hz e de 50 a 1000 Hz), porém não se mostraram significativamente sensíveis à falha da gaiola.




Figura 6.25. Curvas dos valores normalizados dos Parâmetros indicados de 4, 5 e 6.

As curvas dos Parâmetros 7 (Envelope – 500 a 8000 Hz), 8 (Momento de sexta ordem) e 9 (Fator K) encontram-se na Figuras 6.26. Com relação à falha da gaiola, observa-se que os

três parâmetros são sensíveis, com maiores destaques para o Envelope de 500 a 8000 Hz e o Fator K.




Figura 6.26. Curvas dos valores normalizados dos Parâmetros indicados de 7, 8 e 9.

Dos nove parâmetros estimados para se detectar falhas em rolamentos, ocorridas para o mancal 2, os que apresentaram maior eficácia para detecção da falha na gaiola (níveis aumentaram abruptamente no ensaio em que ocorreu a falha), o Pico, a Curtose, o valor médio dos máximos picos do envelope de aceleração na faixa de frequência de 500 a 8000 Hz e o Fator K.

Na Figura 6.27 estão mostrados os espectros dos envelopes de aceleração na faixa de frequência de 500 a 8000 Hz, para o rolamento antes e após a falha, e, a Figura 6.28 representa um detalhamento da Figura 6.27, nas baixas frequências, para se melhor visualizar a frequência de defeito da gaiola.

Pode-se observar nas figuras que os níveis de energia para o rolamento bom estão cerca de 8 dB abaixo dos níveis para rolamento após a falha, sendo que as componentes da frequência de defeito da gaiola, de suas harmônicas e sub-harmônicas estão bem caracterizadas na Figura 6.28 (um aumento de aproximadamente 17 dB nos níveis de energia para estas frequências).




Figura 6.26. Espectros dos envelopes de aceleração na faixa de frequência de 500 a 8000 Hz, para o rolamento antes e após a falha.




Figura 6.27. Detalhamento da Figura 6.6 nas baixas frequências.

Capítulo VII

Conclusões

É imprescindível uma análise de sensibilidade para se determinar os melhores parâmetros indicativos da integridade de sinais adquiridos de um sistema. Para este procedimento, o Teste de Hipótese Nula e a análise estatística via gráficos Boxplot se mostraram expressivamente eficazes.

A comparação de médias entre duas categorias de sinais teve utilidade para uma primeira seleção de parâmetros, quantificando o quão distintas são as classes. Já os gráficos Boxplot, os quais foram muito utilizados no trabalho, tiveram demasiado destaque numa escolha mais apurada dos parâmetros, uma vez que ilustram explicitamente o comportamento estatístico dos dados, fornecendo grande quantidade de informações ao analista.

Como era de se esperar, os parâmetros de sinais com eventos aleatórios aplicados à bancada não se mostraram sensíveis, comprovando que qualquer incidente eventual ocorrido no sistema não interfere na qualidade do sinal coletado.

Inferiu-se que os parâmetros relacionados com ruído de rede de alimentação, tais como o nível de energia dos harmônicos de 60 Hz (RMS_{10}) e a relação sinal ruído (RSR) para ambos os mancais, não se mostraram muito eficientes na identificação de sinais com problemas de instrumentação, possivelmente, devido à frequência de rotação da bancada ser próxima a 60 Hz e harmônicos.

O nível de energia global do sinal (RMS_1) teve destaque no monitoramento do sinal de máquina desligada comparado com sinal "ok", para os dois mancais 2 e 6.

A maioria dos parâmetros não se mostrou apta a diferenciar sinal "ok" de sensores trocados, devido à bancada experimental ser simétrica e os mancais monitorados terem rolamentos do mesmo tipo. Porém, os parâmetros estimados especificamente para esta função, apresentaram significativa habilidade, uma vez que representam características distintas de cada um dos dois mancais (região de baixa energia vibratória para um e alta para outro).

Os mais sensível para o mancal 2 foi o nível de energia na banda de frequência de 1600 a 1700 Hz (Banda 5) - RMS_6 , e para o mancal 6, o nível de energia normalizado em relação ao nível global do sinal, na banda de frequência de 800 a 900 Hz (Banda 4) - RMS_{16} . O nível de energia normalizado em relação ao nível global, na banda de frequência de 2300 a 2600 Hz (Banda 6) foi evidenciado para ambos os mancais.

Os dois parâmetros que se mostraram excelentes ferramentas para discriminar os sinais com problemas de instrumentação dos com a máquina desligada, para os dois mancais monitorados, foram o nível de energia na banda de frequência de 3300 a 4000 Hz (RMS_{19}) e o nível de energia dos harmônicos de 37.4 Hz (RMS_{21}), ambos normalizados em relação ao nível global do sinal. Tais parâmetros atingiram o objetivo de que os níveis decresceriam quando houvesse problemas de instrumentação.

As funções gaussianas de dois lados utilizadas no desenvolvimento dos conjuntos fuzzy, apresentaram melhor desempenho do que as trapezoidais para os casos em que os dados apresentaram dispersões significativas. Isso foi observado quando utilizada a função de pertinência trapezoidal para um conjunto de dados com maiores desvios, verificando-se que os valores dos graus de pertinência dos parâmetros a serem testados anulavam as regras fuzzy, uma vez que existem limites onde as curvas atingem o valor zero, e o parâmetro não apresenta probabilidade alguma de pertencer a um determinado conjunto. Isso se deve ao fato de quando utilizado o conectivo "AND" na regra, uma operação de multiplicação é realizada, portanto, basta um parâmetro apresentar grau de pertinência igual a zero que a regra torna-se nula. Já utilizando uma função gaussiana verificou-se a não ocorrência da anulação das regras, pois embora tendendo a zero, a curva não atinge este valor, isso possibilita que o dado testado pertença, a um conjunto mesmo com uma pequena probabilidade.

Os resultados obtidos via Rede PNN comparados com os adquiridos via lógica fuzzy, não apresentaram diferenças significativas entre si, mesmo porque ambas as ferramentas mostraram-se eficientes na classificação de sinais monitorados em tempo real.

A principal diferença observada no desenvolvimento da rede neural e da lógica fuzzy é que devido à interação entre o analista e o sistema de inferência fuzzy, erros de classificação são perceptíveis e possivelmente retificados. No caso da rede, essas objeções são filtradas de forma a se obter bons ou maus resultados.

Dos nove parâmetros estimados com propósito de se realizar manutenção preditiva em rolamentos, os que apresentaram maior eficácia para detecção da falha na gaiola (níveis aumentaram abruptamente no ensaio em que ocorreu a falha), o Pico, a Curtose, o valor médio dos máximos picos do envelope de aceleração na faixa de frequência de 500 a 8000 Hz e o Fator K.

7.1. Trabalhos Futuros

Propõe-se para trabalhos futuros, a utilização de redes neurais com aprendizado por reforço, para monitorar a qualidade de sinais de vibrações. A proposta tem como objetivo a montagem de sistemas especialistas para aplicações gerais.

Sugere-se que para a avaliação do desempenho da metodologia proposta neste trabalho, a mesma seja aplicada numa planta industrial.

Referências Bibliográficas

Barkov, A. V., Barkova, N. A. and Mitchell, J. S. ,1995, "Assessing the Condition and Lifetime of Rolling Element Bearings from a Single Measurement", proceedings of the 19th annual meeting of the Vibration Institute. Disponível em: <http://www.vibrotek.com/articles/>.

Angelo, M.; "Vibration Monitoring of Machine", Technical Review, BRUEL & KJAER, Dinamarca, 1987.

Azovtsev Yu.A., Barkov A.V., Yudin I.A., 1994, "Automatic Diagnostics of Rolling Element Bearings Using Enveloping Methods," Proceedings of the Vibration Institute 18th Annual Meeting, pp. 249-258.

Bandyopadhyay, A., Shyamal Kr. D. M. and Barnali, P., 1999, "Real- Time Condition Monitoring System Using Vibration Analysis for Turbine Bearing", disponível em: <http://www.erdical.org/html/downloads.htm>.

Barreto, R. A., 2003, "Definição de Parâmetros de Vibração e Ruído para Aceitação de Câmbios Automotivos em Linhas de Montagem", 134 f. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis-PR.

Bezerra, R. A., Santiago, D. F. A., Pederiva, R., 2004, "Utilização de Redes Neurais na Identificação de Falhas em Rolamentos a partir de Parâmetros Estatística", 2004.

Bezerra, R., A., 2004 , "Detecção de Falhas em Rolamentos por Análise de Vibração". Tese de Doutorado, Campinas, Universidade Estadual de Campinas.

Bo Li, Chow, M. and Tipsuwan and Hung, J. C., 2000, "Neural-Network-Based Motor Rolling Bearing Fault Diagnosis", IEEE Transactionson Industrial Eletronics, Vol. 47, No. 5, pp. 1060-1069.

Braga, A. P., Carvalho, A. P. L. F. e Ludermir, T. B., 1998, "Fundamentos de Redes Neurais Artificiais", 11a Escola de Computação da UFRJ, 223 pg.

Braun, S., 1986, "Mechanical Signature Analysis – Theory and Aplications", Ed. Academic Press, London.

Brito, N., Pederiva, R. e Garcia, E. M., 2002, "Desenvolvimento de um Sistema Especialista para Diagnóstico de Problemas em Motores Elétricos", Anais do CONEM 2002, João Pessoa-PB.

Bruel & Kjaer, 1982, "Medição de Vibração", São Paulo.

Büchner, P. C., 2001 "Análise de Mancais de Rolamentos através dos Sinais de Vibrações, Usando Método da Curtose e do Envelope". Dissertação de Mestrado, Pontifícia Universidade Católica do Paraná, Curitiba-PR.

Cempel, C., 1989, "Passive Diagnostics and Reliability Experiment: Application in Machine Condition Monitoring", Journal of Vibration, Acoustics, Stress, and Reliability in Design, vol. 111, p. 83.

Cohen, L., 1995, "Time-Frequency Analysis", Ed. Englewood Cliffs, Prentice Hall.

Crupi, V, Guglielmino, E. and Milazzo, G., 2004, "Neural-Network-Based System for Novel Fault Detection in Rotating Machinery", Journal of Vibration and Control, V. 10 (8), pp. 1137 – 1151.

Cunha, M. S., 2004, "Monitoramento de Vibração "On-Line" Através da Utilização de Instrumentação Virtual", Anais do II ENAM – Belém, PA, Brasil.

Diamont, W. J., 1989, "Practical Experiment Designs for Engineers and Scientists", Van Nostrand Reinhold, New York.

Duarte, M. A. V., 1998, "Manutenção Preditiva via Monitoramento de Vibrações", Ed. Universidade Federal de Uberlândia-MG, Brasil, 200 p.

Duarte, M. A. V., Simões, S. C. Jr., 2002, "Uso da TDA – Média no Domínio do Tempo como Ferramenta de Identificação de Falhas em Câmbios Automotivos". Anais do CONEM 2002, João Pessoa-PB.

Duarte, M. A.V., Meola, T., Machado, A. R. e Costa, E. S., 2004, "Monitoramento do desgaste de ferramentas durante o processo de furação via medições de pressão sonora", Anais do III Congresso Nacional de Engenharia Mecânica, Belém-PA.

Feres, P. F., "Monitoramento Contínuo Remoto Baseado em Internet", Anais do 7º COTEQ, setembro de 2003. Anais em CD.

Ferreira, A. L. G., Paranhos, J. P. de S., 2004, "Controle em Tempo Real por Lógica Fuzzy", Projeto Final de Curso, Associação Educacional Dom Bosco, disponível em: <http://www.aedb.br/faculdades/eng/disciplinas/ano6/>

Hansen, L., 1998, "A Elaboração de Níveis de Alarmes Globais, de Bandas de Frequências e Máscaras Espectrais de Bandas Estreitas à base de Tratamento Estatístico para modernos programas de Manutenção Preditiva por Análise de Vibrações", Disponível em: planeta.terra.com.br/servicos/vibra/vibra/tecem.htm.

Hopfield, J. J., 1982, "Neural Networks and Physical Systems with Emergent Collective Computational Abilities", *Proceedings of the National Academy of Science*, 2554-2558.

Kohonen, T., 1984, "Self-Organization and Associative Memory", Springer-Verlag, Berlin.

Lee, C. C., 1990, "Fuzzy Logic in Control System: Fuzzy Logic Controller – part i & ii", *IEEE Transactions on Systems, Men and Cybernetics*, Vol. 20, N. 2, pp. 404-435.

Mancuzo, M., Duarte, M. A. V., Ribeiro, C. R., 1999, "Detecção Automática de Falhas em Motores de Combustão Interna Utilizando Rede Neural", Anais do COBEM 1999, Águas de Lindóia.

Martin H. R. e Honarvar, F., 1984, "Application of Statistical Moments to Bearing Failure Detection". *Applied Acoustics*, v. 44, pp.67-77, Great Britain

Master, T., 1993, "Advanced Algorithms for Neural Networks", John Wiley & Sons, New York.

McCulloch, W. and Walter Pitts, W., 1943, "A Logical Calculus of Ideas Immanent in Nervous Activity", *Bulletin of Mathematical Biophysics*.

Meisel, W., 1972, "Computer-Oriented-Approaches to Pattern Recognition". Academic Press, New York.

Meola, T., Barreto, R. e Duarte, M. A. V., 2003, "Controle de Rumoriedade em Câmbios", SAE Brasil – Seminário de Transmissões e Powetrain, Campinas, SP.

- Meola, T., Duarte, M. A. V. and Assumpção, F., 2005, "On Line Monitoring Of Reliability Of Signals to be Used to Control Purposes", submetido ao 18th COBEM, Ouro Preto, MG.
- Meola, T., Duarte, M. A. V., Nunes, M. A. de A., 2004, "Definição de Sintomas para Ensaios de Manobrabilidade em Câmbios Automotivos. Anais do CONEM 2004, Belém-PA.
- Moura, H. G., Duarte, M. A. V., Ferraresi, V. A.M. e Cordeira, H., 2002, "Interpretação Matemática da Variação Luminosa no Processo de Soldagem MIGMAG Pulsado para Classificação do Destacamento através de uma Rede Neural Artificial", Anais do CONEM 2002, João Pessoa-PB.
- Nepomuceno, L. X., 1989, "Técnicas de Manutenção Preditiva", Ed. Edgard Blucher, Vol.1, São Paulo, Brasil,.
- Parzen, E., 1962, "On Estimation of a Probability Density Function and Mode", Annals of Mathematical Statistics, V. 33, pp. 1065-1076.
- Pereira, A. L. P., Barbosa, J., 2004, "Identificando Estágios de", Revolutions da SKF Condition Monitoring, Vo. 7, No.3, disponível em: www.vibra.dynamiczone.com
- Pinto, L. A. V., 2004, "Análise de Vibração de Máquinas em Navios e Plataformas Offshore", Anais do 20º Congresso Nacional de Transportes Marítimos, Construção Naval e Offshore, COPPE / UFRJ.
- Randall, R. B., Tech, B. A., "Frequency Analysis, 3^{ed}, Bruel & Kjaer, 1987.
- Sandri, S.; Corrêa, C., 1999, "Lógica Nebulosa", INPE, disponível em: <http://www.ele.ita.br/cnm/minicursos-5ern/log-neb.pdf>.
- Santiago, D. F. A., Brito, J. N. e Pederiva, R., 2002, "Diagnóstico de Falhas em Máquinas Rotativas Utilizando Redes Neurais", Anais do CONEM 2002, João Pessoa-PB.
- Sick, B., 2002, "On-line and Indirect Wear Monitoring in Turning with Artificial Neural Networks: A Review of More than a Decade of Research", Mechanical Systems and Signal Processing, v.16, n.4, p.487-546.

Specht, D., 1990, "Probabilistic Neural Network", *Neural Network*, V. 3, pp. 109-118.

Tandon, N. and Choudhury, A., "A Review of Vibration and Acoustic Measurement Methods for the Detection of Defects in Rolling Element Bearings", *Tribology International*. Vol. 32, pp. 469-480, 1999.

Tebchirani, T. L., 2003, "Manutenção Classe Mundial – Manutenção Preditiva por Análise de Vibrações", *disciplina Projetos V, CEFET – PR*. 40 páginas.

Teixeira, R. L., 2001, "Uma Metodologia de Projeto de Controladores Híbridos Inteligentes com Aplicações no Controle Ativo de Vibrações Mecânicas", *Dissertação de Mestrado, Universidade Federal de Uberlândia, Uberlândia, MG*.


Vicente, S. A. S., Fujimoto, R. Y. e Padovese, L. R., 2001, "Rolling Bearing Fault Diagnostic System Using Fuzzy Logic", *IEEE International Fuzzy SYSTEMS conference*.

Vicente, S. A. S., Padovese, 2004, "Comparison Among Different Metrics in Probabilistic Neural Network for Diagnostic of Rolling Bearings Faults", *Anais do III Congresso Nacional de Engenharia Mecânica, Belém-PA*.


Zadeh, L. A.; Jamshidi, Md. e Tilli, A., 1997, "Applications of Fuzzy Logic: Towards High Machine Intelligence Quotient Systems". *Environmental and Intelligent Manufacturing Series, Prentice Hall*.

Anexo I


Desenhos de detalhes da bancada experimental





Desenho de Conjunto da Bancada Experimental




Dimensões do Suporte da Bancada







Dimensões dos Mancais de Rolamento



3 PEÇAS



Dimensões do Suporte dos Mancais de Rolamento

