Suelen Marconsini Loureiro

Reconhecimento Automático de Padrões de Defeitos em Motobombas utilizando Análise de Sinais de Vibração

Vitória - ES, Brasil

17 de agosto de 2009

Suelen Marconsini Loureiro

Reconhecimento Automático de Padrões de Defeitos em Motobombas utilizando Análise de Sinais de Vibração

Dissertação apresentada ao Programa de Pós-Graduação em Informática da Universidade Federal do Espírito Santo para obtenção do título de Mestre em Informática.

Orientador:
Flávio Miguel Varejão

PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA
DEPARTAMENTO DE INFORMÁTICA
CENTRO TECNOLÓGICO
UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO

Vitória - ES, Brasil

17 de agosto de 2009

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Central da Universidade Federal do Espírito Santo, ES, Brasil)

Loureiro, Suelen Marconsini, 1983-
L892r Reconhecimento automático de padrões de defeitos em motobombas utilizando análise de sinais de vibração / Suelen Marconsini Loureiro. – 2009.
64 f. : il.

Orientador: Flávio Miguel Varejão.
Dissertação (mestrado) – Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Reconhecimento de padrões. 2. Vibração. 3. Processamento de sinais. 4. Classificação. 5. Localização de falhas (Engenharia). 6. Motobombas - Defeitos. I. Varejão, Flávio Miguel. II. Universidade Federal do Espírito Santo. Centro Tecnológico. III. Título.

CDU: 004

Dissertação de Mestrado sob o título *"Reconhecimento Automático de Padrões de Defeitos em Motobombas utilizando Análise de Sinais de Vibração"*, defendida por Suelen Marconsini Loureiro e aprovada em 17 de agosto de 2009, em Vitória, Estado do Espírito Santo, pela banca examinadora constituída pelos professores:

Prof. Dr. Flávio Miguel Varejão
Orientador

Prof. Ph.D. Thomas Walter Rauber
Examinador Interno

Profa. Dra. Flávia Bernardini
Examinador Externo

Agradecimentos

A Deus, pela vida e pelo aprendizado constante que ela me propicia.

À minha mãe, familiares e amigos pelo apoio incondicional.

À minha irmã Michele, pelos auxílios nos acabamentos das figuras.

À minha irmã Cynthia, por me ceder a máquina para trabalho em um momento crucial.

Aos meus colegas acadêmicos, em especial ao Eduardo Mendel e ao Estefhan, pelos esclarecimentos e auxílios prestados.

Ao professor Thomas, por disponibilizar a ferramenta *tooldiag* para realização de testes e extensão.

À Instituição Petrobrás, pelo suporte financeiro ao projeto ADD-RPD.

Por último, mas em especial, à minha Tia Graça, meu orientador Flávio e meu colega acadêmico Idilio Drago, cujo apoio, força, conselhos, compreensão e auxílios foram fundamentais para a conclusão deste trabalho.

Sumário

Lista de Figuras

Lista de Tabelas

Resumo

Abstract

1 Introdução p. 12

2 Detecção de defeitos em motobombas p. 14

2.1 A motobomba e seus defeitos . . . . . p. 14

2.2 Identificação de defeitos por sinais de vibração . . . . . p. 16

2.2.1 Inspeção dos níveis de alarme . . . . . p. 18

2.2.2 Análise da assinatura da vibração . . . . . p. 20

2.3 Assinaturas típicas dos defeitos . . . . . p. 22

2.3.1 Problemas mecânicos . . . . . p. 22

2.3.2 Problemas elétricos . . . . . p. 29

2.3.3 Problemas hidrodinâmicos . . . . . p. 30

3 Detecção automática de defeitos p. 32

3.1 Extração de características . . . . . p. 32

3.1.1 Transformada de Fourier . . . . . p. 32

3.1.2 Análise de Envelope . . . . . p. 33

3.1.3 Medidas de amplitude derivadas do espectro . . . . . p. 35

3.2 Seleção de características . . . . . p. 36
3.2.1 Geração dos conjuntos . . . . . p. 36
3.2.2 Avaliação dos conjuntos . . . . . p. 38
3.2.3 Critério de parada . . . . . p. 39
3.2.4 Validação do resultado . . . . . p. 39
3.3 Algoritmo de classificação . . . . . p. 39
3.3.1 Algoritmo do vizinho mais próximo . . . . . p. 40
3.4 Estimativa de desempenho . . . . . p. 42
3.4.1 Método de estimativa . . . . . p. 42
3.4.2 Métrica de avaliação do desempenho . . . . . p. 43

4 Avaliação experimental p. 47
4.1 Descrição dos dados . . . . . p. 47
4.2 Configuração dos experimentos . . . . . p. 48
4.2.1 Descrição das características . . . . . p. 48
4.3 Resultados obtidos . . . . . p. 50
4.3.1 Distribuições de classes . . . . . p. 50
4.3.2 Análise do desempenho . . . . . p. 51

5 Conclusões e Trabalhos Futuros p. 55

Referências Bibliográficas p. 57

Apêndice A – Conjunto automático de características p. 60

Lista de Figuras

2.1 Conjunto motobomba . . . . . p. 14

2.2 Componentes internos do motor (MARTINELLI; SANTIN, 2006) . . . . . p. 15

2.3 Componentes internos da bomba (SULZER, 2008) . . . . . p. 15

2.4 Pontos de coleta de vibração (MENDEL et al., 2008) . . . . . p. 17

2.5 Níveis simplificados de alarme em velocidade . . . . . p. 20

2.6 Níveis de alarme por bandas para bombas . . . . . p. 21

2.7 Níveis de alarme por bandas para motores . . . . . p. 22

2.8 Assinatura típica de desbalanceamento (TA, 1997) . . . . . p. 23

2.9 Assinaturas típicas de desalinhamento (paralelo à esquerda e angular à direita) (TA, 1997) . . . . . p. 23

2.10 Assinatura típica de eixo empenado (TA, 1997) . . . . . p. 24

2.11 Assinatura típica de folga de base (TA, 1997) . . . . . p. 24

2.12 Assinatura típica de folga de mancal (TA, 1997) . . . . . p. 25

2.13 Rolamento de esferas de contato angular (MCINERNY; DAI, 2003) . . . . . p. 25

2.14 Rolamento de esferas de contato angular - cortes frontal e lateral (LI et al., 2000) . . . . . p. 26

2.15 Freqüências de funcionamento do rolamento (LI et al., 2000) . . . . . p. 26

2.16 Exemplo ilustrativo das freqüências presentes em um sinal vibracional de rolamento defeituoso (MENDEL et al., 2008) . . . . . p. 27

2.17 Assinaturas típicas de defeitos em rolamento (TA, 1997) . . . . . p. 28

2.18 Assinatura típica de problemas no rotor (TA, 1997) . . . . . p. 29

2.19 Assinatura típica de problemas no estator (TA, 1997) . . . . . p. 30

2.20 Assinatura típica de cavitação (TA, 1997) . . . . . p. 31
2.21 Assinatura típica de turbulência (TA, 1997) . . . . . p. 31
3.1 Matriz de confusão . . . . . p. 44
3.2 Espaço ROC . . . . . p. 45

Lista de Tabelas

2.1 Defeitos encontrados em motobombas . . . . . p. 16

2.2 Níveis de alarme para aceleração . . . . . p. 20

4.1 Conjunto manual de características . . . . . p. 53

4.2 Distribuições de classes obtidas nas bases finais dos experimentos . . . . . p. 54

4.3 Resultados da avaliação experimental - ROC AUC . . . . . p. 54

4.4 Resultados da avaliação experimental - Taxa de Acerto . . . . . p. 54

A.1 Conjunto automático de características . . . . . p. 61

A.2 Conjunto automático de características - continuação . . . . . p. 62

A.3 Conjunto automático de características - continuação . . . . . p. 63

A.4 Conjunto automático de características - continuação . . . . . p. 64

Resumo

A manutenção preditiva possui um papel importante na economia e segurança de sistemas petrolíferos. A análise de sinais de vibração obtidos das máquinas envolvidas no processo de extração petrolífera permite a especialistas altamente capacitados caracterizar e monitorar a sua situação. No entanto, o custo e a falta de disponibilidade desses especialistas tornam desejável a existência de sistemas automáticos que apoiem a análise.

Este trabalho descreve um procedimento computacional para reconhecimento de padrões de defeitos em equipamentos do tipo motobomba. O procedimento consiste na aplicação combinada de técnicas previamente selecionadas para cada etapa do processo de reconhecimento dos padrões. Técnicas de processamento de sinais são utilizadas para obter atributos descritivos a partir dos sinais de vibração. Duas abordagens são avaliadas para a seleção de características relevantes: a utilização de heurísticas com base no conhecimento especializado do domínio (abordagem manual) e a aplicação de algoritmos de seleção (abordagem automática). Exemplos reais são submetidos a um algoritmo de aprendizado supervisionado para comparação das abordagens manual e automática de seleção.

Abstract

Predictive maintenance plays an important role for the economy and safety of petroleum systems. Analysis of vibration signals obtained from machines involved in the petroleum extraction process allows subject matter experts to characterize and monitor the situation. However, because of the high cost and the lack of availability of those experts, the existence of automatic systems that support the analysis is desirable.

This work presents an automatic procedure to recognize defect patterns in motorpump equipments. A set of techniques previously selected for each stage of the pattern recognition process is applied in the procedure. Signals processing techniques are used to obtain descriptive features from vibration signals. Two approaches are evaluated for the selection of relevant characteristics: using heuristics based on domain specialized knowledge (manual approach) and application of selection algorithms (automatic approach). Real examples are subjected to a supervised learning algorithm in order to compare the manual and the automatic selection approaches.

1 Introdução

As motobombas utilizadas na extração e exploração de petróleo estão sujeitas a um meio instável de funcionamento, no qual há diversas variáveis em nível crítico, como temperatura, pressão e vazão. Esses fatores, somados à necessidade de trabalho diuturno, tornam os equipamentos muito propensos à ocorrência de falhas. Por isso, é necessária a existência de um processo eficaz de monitoramento dessas máquinas.

O processo de monitoramento pode ser realizado de diversas formas, dentre as quais encontra-se a manutenção preditiva, cujo objetivo é antever a ocorrência de defeitos. A manutenção preditiva possui um papel importante na economia e segurança de sistemas petrolíferos. Ela viabiliza o planejamento das intervenções para reparo e evita paradas inesperadas, reduzindo perdas na produção, além de reduzir custos de manutenção por evitar que as falhas atinjam um nível crítico.

A análise de vibrações é a técnica de manutenção preditiva mais importante, pois é a mais eficaz na detecção dos defeitos mecânicos, defeitos mais comuns em máquinas rotativas (GIRDHAR, 2004). As vibrações das máquinas são afetadas na ocorrência de malfuncionamento, e sua análise permite a especialistas altamente capacitados caracterizar e monitorar a condição dos equipamentos. A utilização de tais especialistas, que são raros e caros, na análise de vibrações é um uso ineficiente e custoso de recursos. Tal fato torna desejável a existência de um método automático de detecção e identificação dos defeitos.

Este trabalho propõe um procedimento computacional baseado na utilização de técnicas de reconhecimento de padrões, aliadas ao processamento de sinais de vibração, para detecção de defeitos em motobombas. As técnicas de processamento de sinais são utilizadas para extrair dos sinais de vibração características discriminativas para diagnóstico dos padrões de defeitos (KAZZAZ; SINGH, 2003).

Há inúmeras possibilidades de extração de características a partir dos sinais de vibração. Duas abordagens são empregadas para definição do espaço de características utilizado. Na primeira, o conjunto é definido manualmente a partir de heurísticas baseadas no conhecimento do

domínio (abordagem manual). Na segunda, um conjunto mais amplo de características é inicialmente extraído e submetido, em seguida, a um algoritmo de seleção (abordagem automática) (LIU; YU, 2002).

Para realizar o reconhecimento automático dos defeitos, os dados extraídos são fornecidos como entrada para um algoritmo de aprendizado supervisionado (MONARD; BARANAUSKAS, 2003). O método de estimativa de erro proposto em Salzberg (1997), que inclui a etapa de ajuste de parâmetros no estimador de validação cruzada (MONARD; BARANAUSKAS, 2003), é adaptado e utilizado para avaliação e comparação das abordagens manual e automática.

O restante deste trabalho está organizado em quatro capítulos. O Capítulo 2 realiza uma revisão do procedimento de análise de sinais de vibração que permite detectar e identificar defeitos em motobombas. Também são descritos o tipo de motobomba e os tipos de defeitos estudados.

O Capítulo 3 propõe um procedimento computacional automático de reconhecimento de padrões de defeitos. São apresentadas as técnicas de processamento de sinal utilizadas para extrair características do sinal vibracional, os algoritmos de seleção automática e aprendizado supervisionado implementados e o procedimento de estimativa de erro utilizado para avaliação experimental do desempenho.

O Capítulo 4 descreve o processo de avaliação experimental realizado para comparação das abordagens manual e automática de seleção de características, englobando a exposição da configuração experimental, a descrição dos dados e a análise e discussão dos resultados obtidos.

Por fim, o Capítulo 5 apresenta conclusões sobre os resultados alcançados com a abordagem proposta e possíveis trabalhos futuros.

2 *Detecção de defeitos em motobombas*

As motobombas, como toda máquina rotativa, possuem elementos internos que estão em constante movimento. Esse movimento gera forças mecânicas que possuem um certo nível de desequilíbrio, produzindo vibrações. Quando a máquina está em boas condições o nível das vibrações é mantido constante. Caso haja alterações na integridade dos componentes o quadro de forças presentes é modificado, afetando, assim, as vibrações geradas. Suas amplitudes começam a manifestar uma tendência crescente, indicando ocorrência de mal funcionamento. Dependendo da origem da condição defeituosa, a vibração apresentará um padrão característico, conhecido como assinatura da vibração. A análise do formato da assinatura permite diagnosticar o defeito que está se manifestando.

2.1 A motobomba e seus defeitos

A motobomba considerada neste trabalho é composta por uma bomba centrífuga horizontal de um estágio (um rotor), acoplada a um motor elétrico AC de indução do tipo gaiola de esquilo. O acoplamento é direto, sem caixa de engrenagem (ver Figura 2.1).

Figura 2.1: Conjunto motobomba

No motor (Figura 2.2), os principais componentes são o estator (item 8 da Figura) e o rotor (item 3). O estator constitui a parte estática do motor, e o rotor a parte móvel. O núcleo de placas do estator (item 2) é responsável por gerar um campo magnético no estator. O campo do estator provoca a indução de outro campo magnético no rotor. A força de atração dos campos do estator e do rotor faz com que surja um torque no eixo do rotor (item 7) e o mesmo gire (PEREIRA, 2004).

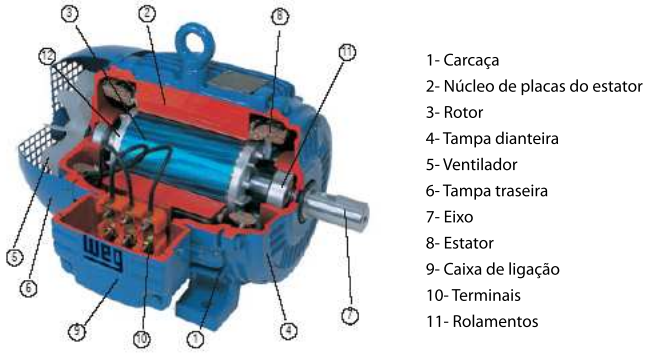

Figura 2.2: Componentes internos do motor (MARTINELLI; SANTIN, 2006)

Na caixa de ligação (item 9 da Figura 2.2) estão localizados os terminais dos enrolamentos de fios (item 10) do estator e do rotor. O ventilador (item 5) é responsável pela refrigeração do motor. A carcaça (item 1), tampa dianteira (item 4), tampa traseira (item 6) e caixa de ligação oferecem suporte e proteção às demais estruturas.

O rotor do motor é responsável pela transmissão da potência mecânica gerada à bomba (PEREIRA, 2004), através do seu eixo, que está acoplado ao eixo da bomba. Os componentes internos da bomba são mostrados na Figura 2.3. O rotor da bomba (item 2 da Figura 2.3) recebe a força do motor, através do seu eixo (item 3), e entra em movimento, gerando a força centrífuga necessária para bombear o líquido. A voluta, ou carcaça (item 1), provê suporte e proteção às estruturas da bomba.

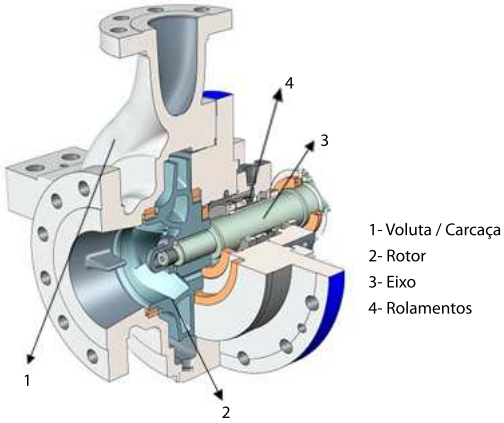

Figura 2.3: Componentes internos da bomba (SULZER, 2008)

Os rolamentos (itens 11 e 4 das Figuras 2.2 e 2.3, respectivamente), tanto no motor quanto na bomba, permitem o movimento entre o eixo e a estrutura de sustentação, diminuindo a fricção entre eles. A estrutura que fornece suporte ao rolamento é denominada mancal. Além dos componentes mostrados nas Figuras 2.2 e 2.3 , tem-se também as bases do motor e da bomba, que são responsáveis pela fixação deles à superfície.

Os defeitos comumente encontrados em motobombas são listados na Tabela 2.1. Eles podem ser separados pelo local de ocorrência e categorizados quanto à sua origem. O local de ocorrência se refere à parte da motobomba em que o defeito está se manifestando, podendo ser no motor, na bomba ou no acoplamento. A origem pode estar relacionada a fenômenos mecânicos, elétricos, hidrodinâmicos ou provenientes do processo de medição da vibração.

Tabela 2.1: Defeitos encontrados em motobombas

Local de ocorrência					
Motor		**Acoplamento**		**Bomba**	
Origem	*Defeitos*	*Origem*	*Defeitos*	*Origem*	*Defeitos*
Mecânica	Desbalanceamento Falhas de rolamentos Folga de base Folga de mancal	**Mecânica**	Desalinhamento Ressonância estrutural	**Mecânica**	Desbalanceamento Falhas de rolamentos Folga de base Folga de mancal Eixo empenado
Elétrica	Problema no rotor Problema no estator	**Medição**	Falha de sensor	**Hidrodinâmica**	Turbulência Cavitação

Os defeitos também apresentam diferentes probabilidades de ocorrência de acordo com a freqüência com que são identificados. Os defeitos de desbalanceamento e desalinhamento cobrem uma porcentagem alta dos problemas encontrados em máquinas rotativas (80%, segundo indicações estatísticas) (GIRDHAR, 2004).

2.2 Identificação de defeitos por sinais de vibração

A detecção de defeitos em motobombas é feita por meio da análise de sinais de vibração. Esses sinais são medidos através de sensores colocados em posições específicas do motor e da bomba. O posicionamento do sensor interfere na qualidade da análise. Quanto mais próximo o sensor estiver do local de ocorrência do defeito melhor será a análise, pois o formato da vibração refletirá com mais precisão o padrão do defeito. Assim diferentes posições são utilizadas para coleta das medições.

Além da posição da coleta, a direção também interfere na vibração medida. A dinâmica de funcionamento das máquinas gera forças e, conseqüentemente, vibrações, em diferentes direções. Três direções podem ser utilizadas para prover um quadro completo da assinatura de vibração da motobomba: vertical (V), horizontal (H) e axial (A). As direções vertical e horizontal são denominadas direções radiais, e permitem identificar componentes de vibrações gerados por forças perpendiculares ao eixo central. Medições tomadas na direção axial possibilitam determinar vibrações ocasionadas por movimentos paralelos ao eixo (MOBLEY, 1999).

A composição de uma posição e uma direção forma um ponto de coleta. Os pontos de

coleta de sinais vibracionais ficam nos mancais das máquinas e suas posições são numeradas de forma crescente do equipamento acionador (motor) para o equipamento acionado (bomba). Esses pontos são mostrados na Figura 2.4.

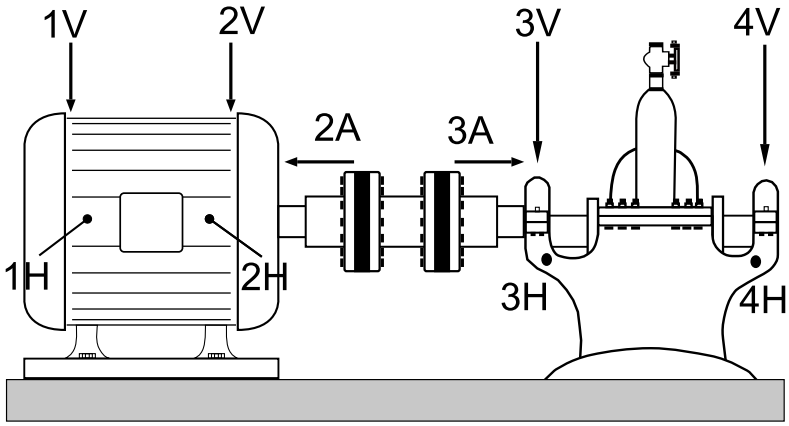

Figura 2.4: Pontos de coleta de vibração (MENDEL et al., 2008)

Todos os pontos podem ser utilizados para detectar defeitos comuns ao motor e à bomba, como desbalanceamento, falhas de rolamento e folgas. Os pontos 1 e 2 são importantes para a detecção de defeitos específicos do motor, como problemas elétricos. Os pontos 3 e 4 são importantes para a detecção de defeitos específicos da bomba, como problemas hidrodinâmicos. Os pontos 2A e 3A são importantes na detecção de desalinhamento.

Para obter medições das vibrações sensores são posicionados nos pontos de coleta apresentados. A leitura destes sensores é uma representação do movimento vibratório detectado, que pode ser conceituado como o movimento periódico de um corpo (no caso de motobombas, partes da máquina) em relação a um referencial. Diferentes medidas podem ser utilizadas a fim de caracterizar este movimento, entre elas velocidade e aceleração.

As medidas de velocidade e aceleração podem ser convertidas entre si por derivação e integração, conforme Equações 2.1 e 2.2 (JOHNSON, 1997).

$$a(t) = \frac{dv(t)}{dt} \tag{2.1}$$

$$v(t) = v(0) + \int_0^t a(\tau) d\tau \tag{2.2}$$

Contudo, a conversão de velocidade para aceleração por derivação não é adequada pois variações bruscas na velocidade podem causar o aparecimento de picos no sinal de aceleração que não refletem a situação real, gerando um sinal ruidoso. Portanto o sensor utilizado para leitura das medições é um acelerômetro. O sinal lido pelo acelerômetro é uma reprodução das

amplitudes instantâneas da aceleração da máquina em cada unidade de tempo. Dado que o sinal de velocidade pode ser gerado a partir do sinal de aceleração por integração, tem-se no acelerômetro um sensor que pode prover informação de aceleração e velocidade.

As unidades das medidas de aceleração e velocidade no SI (Sistema Internacional de Unidades) são, respectivamente, metros por segundo ao quadrado (m/s^2) e metros por segundo (m/s). Na análise vibracional, entretanto, a aceleração é usualmente expressada em comparação com a aceleração da gravidade (JOHNSON, 1997), que é aproximadamente $9.8m/s^2$. Para exprimir a aceleração em termos de gravidade utilizamos uma unidade denotada por g. Desta forma, $1g$ é equivalente a uma vez a aceleração da gravidade. Já para a medida de velocidade, a grandeza que permite expressar valores significativos de vibração é relativa à unidade mm/s.

Há duas fases no processo de análise vibracional: inspeção dos níveis de alarme e análise da assinatura da vibração. Na fase de inspeção dos níveis de alarme é verificada a possibilidade de existência de defeito. A análise da assinatura da vibração objetiva determinar o tipo de defeito que a motobomba possui.

2.2.1 Inspeção dos níveis de alarme

Uma característica do sinal vibracional é o valor eficaz (ou valor global), que é uma medida global da amplitude do sinal. O valor global é calculado com base na definição de RMS (do inglês, *root mean square*). A Equação 2.3 apresenta a formulação do RMS para um sinal discreto no domínio do tempo (LMS, 2000). O valor resultante da equação indica a quantidade de energia presente no sinal como um todo.

$$rms = \sqrt{\frac{1}{N}\sum_{i=0}^{N-1}|y_i|^2} \tag{2.3}$$

O valor do RMS se acentua quando há ocorrência de defeitos na máquina, de forma que ele pode ser utilizado para determinar a situação em que a motobomba se encontra. Isto é feito por comparação com os níveis de alarme. Um nível de alarme é um critério limite para valores de RMS. Ele delimita regiões de valores de RMS que indicam diferentes condições de operação da motobomba. O nível do RMS depende ainda da gravidade do defeito, por isso existem mais de um níveis de alarme, os quais indicam diferentes patamares de severidade.

Os valores que indicam presença significante de energia no sinal variam de acordo com a unidade de medida de vibração. Assim, os níveis de alarmes referentes a velocidade e aceleração são distintos. Os valores que devem ser utilizados como níveis de alarme são especificados

por normas e diferem de acordo com a norma utilizada. Existem diversas normas que tratam diferentes aspectos que influenciam os valores de alarme, por exemplo, o tipo de medida (velocidade ou aceleração) e o tipo de máquina (motor ou bomba) considerada.

Dentre as normas que especificam níveis de alarme para velocidade encontram-se a ISO 2372/VDI 2056 e a API 610. A norma ISO 2372 foi desenvolvida a partir da recomendação germânica VDI 2056. Ela define critérios de alarmes para motores. Os critérios são variáveis de acordo com o tamanho, potência e tipo de fundação da máquina (rígida ou flexível) (RANDALL, 2004). Cada combinação desses parâmetros forma uma classe de equipamento para a qual é definido um conjunto de valores de alarme específico. Esse conjunto consiste de três níveis que delimitam quatro regiões de operação: boa, permissível, tolerável e não-permissível (RILEY et al., 1999).

A norma API 610 (API, 2003) define critérios de alarmes em velocidade para bombas. Segundo esta norma, o critério a ser adotado varia de acordo com a potência e velocidade de rotação da bomba. No entanto, em todos os casos, existe um nível único de alarme, que pode variar entre $3mm/s$ e $4.5mm/s$, para indicar níveis de vibração que são aceitáveis. O valor específico do limite de vibração é definido por uma equação em função dos valores de potência e velocidade (GÜLICH, 2007). Uma forma de interpretar esta equação é a seguinte: o valor da potência da bomba determina a localização dos limites inferior e superior da faixa de valores do alarme na escala da velocidade de rotação. A velocidade define a taxa com que os valores variam dentro da faixa.

Para efeito de simplificação resumiremos as normas em dois níveis de alarme. Quando o RMS está abaixo do primeiro valor a motobomba está em condições normais. É muito importante que o primeiro nível seja detectado, pois ele indica situação de atenção. Se o RMS ultrapassar esse valor, provavelmente a motobomba apresenta defeito e então as técnicas existentes para identificá-lo devem ser empregadas. Quando o RMS ultrapassa o segundo valor o defeito se torna mais grave e a bomba está em situação de perigo, podendo ocorrer falha do equipamento. Simplificando os valores adotados pela norma ISO 2372/VDI 2056 nesses dois níveis para a classe de equipamentos abordada neste trabalho obtemos os valores $3mm/s$ e $7mm/s$. A Figura 2.5 ilustra esses níveis de alarme.

Os limites de vibração adotados para aceleração são apresentados em Almeida (2008). Eles diferem para velocidades de rotação distintas, e para cada velocidade existem dois níveis de alarme (atenção e perigo), em conformidade com a descrição anterior. A Tabela 2.2 mostra os valores de cada nível (em g). Os valores de velocidade de rotação são apresentados em rotações por minuto (RPM).

Figura 2.5: Níveis simplificados de alarme em velocidade

Tabela 2.2: Níveis de alarme para aceleração

Rotação da bomba (*RPM*)	**Alarme 1 - Atenção (*g*)**	**Alarme 2 - Perigo (*g*)**
1200	3	5
1600	4	6
1800	8	10

2.2.2 Análise da assinatura da vibração

Uma medição de vibração fornece informação acerca de vários componentes do motor ou da bomba. Cada componente vibra em uma faixa característica de freqüências, determinada pela geometria da máquina e por sua velocidade de operação. Um defeito em um componente fará a vibração se acentuar na freqüência de vibração daquele componente. O sinal vibracional no domínio do tempo mistura essas freqüências e, portanto, características de diferentes defeitos, o que torna difícil a análise vibracional para identificação do defeito.

Para separar as freqüências individuais é utilizada a análise espectral (GIRDHAR, 2004), com a qual é obtido o sinal no domínio da freqüência. O espectro de freqüência permite detectar a quantidade de vibração em cada freqüência, sendo conhecido como assinatura da vibração. A fase de análise da assinatura da vibração objetiva determinar o tipo de defeito presente na motobomba. Para isso, compara-se o espectro com padrões pré-existentes de assinaturas de máquinas defeituosas.

Os defeitos se manifestam em diferentes faixas de freqüências do espectro. Problemas me-

cânicos geralmente provocam vibrações elevadas em baixas e médias freqüências. Problemas de rolamento e cavitação alteram o nível vibracional em freqüências elevadas.

Como visto na seção 2.2, as unidades de velocidade e aceleração podem ser utilizadas para caracterizar o movimento vibratório. A escolha da unidade a ser analisada está relacionada com a intensidade de vibração produzida naquela unidade. Valores em aceleração são mais significativos em altas freqüências, enquanto que em baixas freqüências vibrações de baixa intensidade são produzidas, sendo velocidade um indicador melhor da severidade da vibração.

Para defeitos que provocam alteração nas baixas e médias freqüências - de 10 a 1000Hz - devem ser analisadas medições em velocidade. Para defeitos que provocam alteração nas altas freqüências - de 1000 a 10000Hz - devem ser analisadas medições em aceleração (GIRDHAR, 2004). A intensidade de vibração também pode variar de acordo com a faixa de freqüências considerada, sendo maior nas freqüências mais baixas. Assim, um determinado nível de vibração pode ser aceitável se for manifestado em freqüências menores, mas em freqüências maiores pode caracterizar defeito.

Para tratar essas variações de intensidade é possível utilizar outra abordagem de inspeção de níveis de alarme, não apresentada na seção 2.2.1, utilizando bandas de freqüências. Nesta abordagem, existem níveis de alarme diferentes de acordo com a faixa de freqüência considerada. O valor do RMS é calculado para diferentes bandas de freqüências e comparado com o nível de alarme da banda em questão para determinar se há possibilidade de ocorrência de defeito. A inspeção de níveis de alarmes por bandas só é realizada para a unidade de velocidade e permite a identificação de defeitos que não geram energia relevante no sinal em nível global, mas em uma determinada faixa de freqüência, além de gerar assinatura típica.

A Figura 2.6 exibe os níveis de alarmes por bandas utilizados para bombas (ALMEIDA, 2008).

Cada faixa de freqüências é calculada com base em uma freqüência máxima ($f_{\max}$), que por sua vez é calculada em função da velocidade de rotação da máquina (Equação 2.4).

$$f_{\max} = \frac{2}{3}\text{rotacao} \tag{2.4}$$

A Figura 2.7 exibe os níveis de alarmes por bandas utilizados para motores (ALMEIDA, 2008).

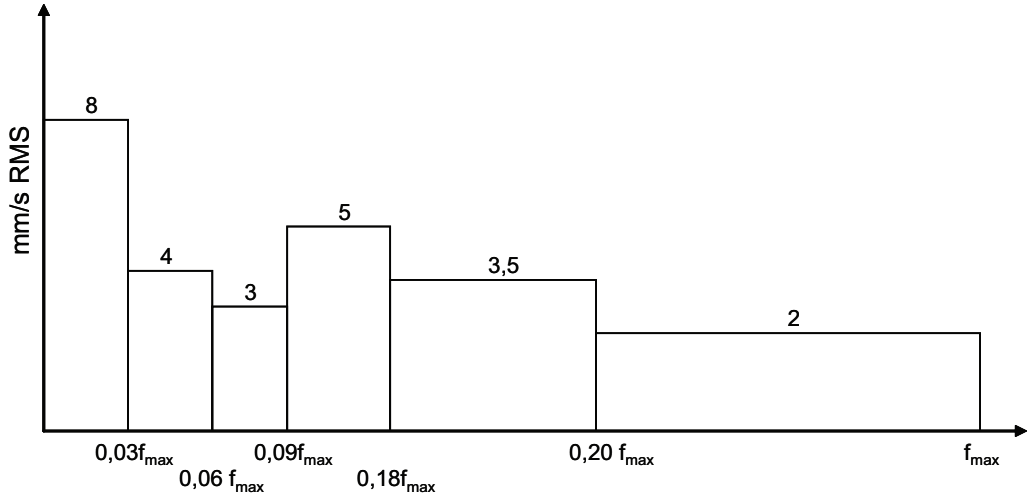

Figura 2.6: Níveis de alarme por bandas para bombas

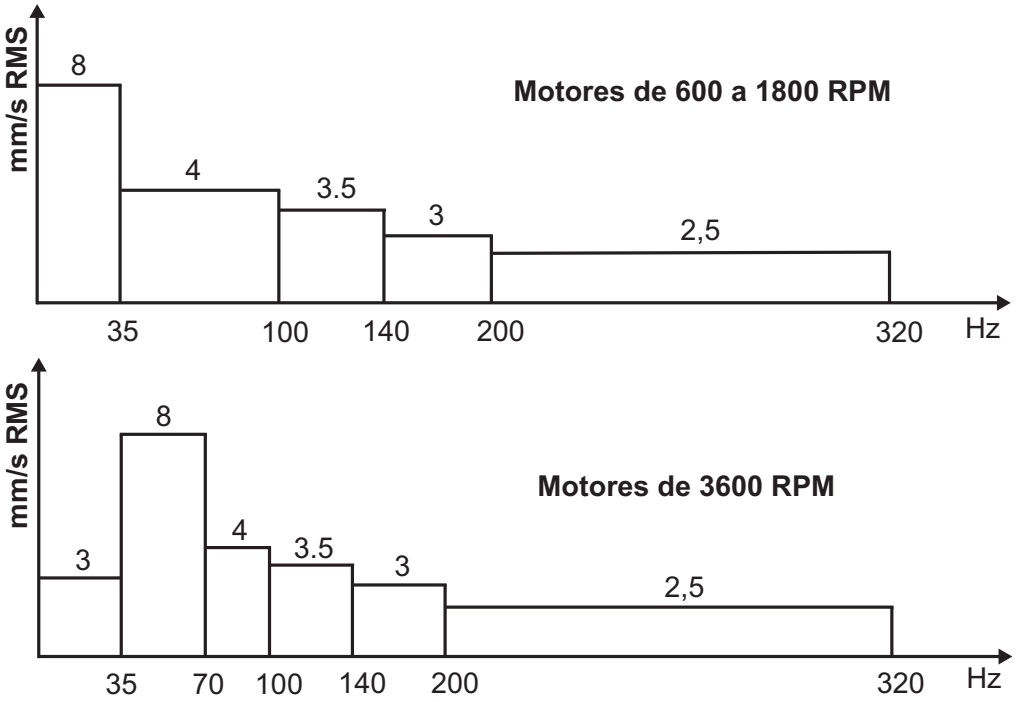

Figura 2.7: Níveis de alarme por bandas para motores

2.3 Assinaturas típicas dos defeitos

TA (1997) descreve os principais defeitos encontrados em motobombas e suas assinaturas típicas. Esta seção apresenta um resumo destes defeitos.

Em muitos casos as freqüências que caracterizam os defeitos são múltiplos da freqüência de rotação do eixo da motobomba. Neste caso será utilizado o termo "*nx* rotação", onde n é o fator que multiplica a freqüência de rotação.

2.3.1 Problemas mecânicos

Problemas mecânicos são normalmente ocasionados por desgaste dos componentes ou problemas no acoplamento entre os diferentes componentes.

Desbalanceamento

As motobombas podem ser desbalanceadas por erosão desigual no rotor ou incrustação de material sobre as pás no rotor.

Nestes casos, a vibração será grande nas direções radiais em 1*x* rotação, tanto no motor (1H, 1V, 2H, 2V), quanto na bomba (3H, 3V, 4H, 4V). A Figura 2.8 mostra a assinatura vibracional característica do defeito de desbalanceamento.

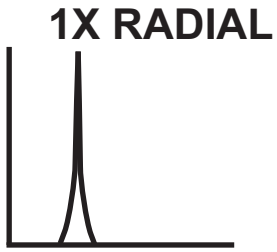

Figura 2.8: Assinatura típica de desbalanceamento (TA, 1997)

Desalinhamento

O desalinhamento pode ser de dois tipos: paralelo ou angular. No desalinhamento paralelo os eixos do motor e da bomba não coincidem e são paralelos. No desalinhamento angular os eixos coincidem, mas não são paralelos, havendo um ângulo entre eles.

Um componente alto de 2*x* rotação na direção radial caracteriza desalinhamento paralelo. Um componente alto de 1*x* rotação na direção axial caracteriza desalinhamento angular.

Os dois tipos de desalinhamento freqüentemente se combinam causando vibrações acentuadas em 1*x* rotação, 2*x* rotação e até 3*x* rotação no espectro, tanto na direção axial quanto radial.

A Figura 2.9 exemplifica sinais característicos de desalinhamento paralelo e desalinhamento angular.

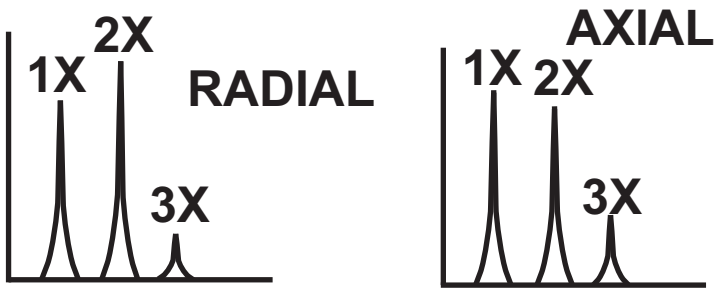

Figura 2.9: Assinaturas típicas de desalinhamento (paralelo à esquerda e angular à direita) (TA, 1997)

Eixo empenado

Ocorre geralmente em função de bombeio de fluidos de alta temperatura.

Aparecem vibrações altas nas direções radiais e axiais em 1x rotação. Cresce também levemente um sinal em 2x rotação. Em resumo, possui características análogas a um desalinhamento angular. A Figura 2.10 exemplifica um sinal característico de eixo empenado.

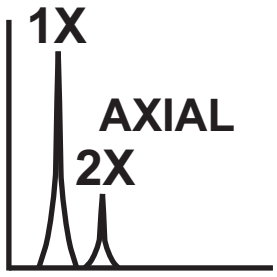

Figura 2.10: Assinatura típica de eixo empenado (TA, 1997)

Folga de base

Folgas de fixação da base causam altas vibrações geralmente na direção vertical em 1x ou 2x rotação dos conjuntos e são acompanhados pelo desbalanceamento e/ou desalinhamento. Quando há folgas excessivas de fixação, pode aparecer um componente subharmônico com freqüência igual a $\frac{1}{2}x$ rotação. A Figura 2.11 exemplifica um sinal característico de folga de base.

Folga de mancais

Vibrações deste tipo possuem características de batimento truncado e, portanto, de efeitos não lineares. São deste grupo as folgas entre bucha e a capa do mancal, entre o anel interno do rolamento e o eixo ou entre o anel externo e a capa do mancal.

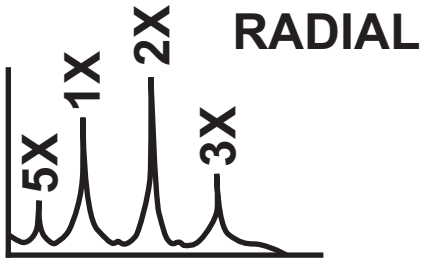

Figura 2.11: Assinatura típica de folga de base (TA, 1997)

Quando há folgas de mancais aparecem vibrações na direção vertical com presença de $\frac{1}{2}x$ rotação e de interhamônicas ($1\frac{1}{2}x$, $2\frac{1}{2}x$, $3\frac{1}{2}x$,...). A Figura 2.12 exemplifica um sinal característico de folga de mancal.

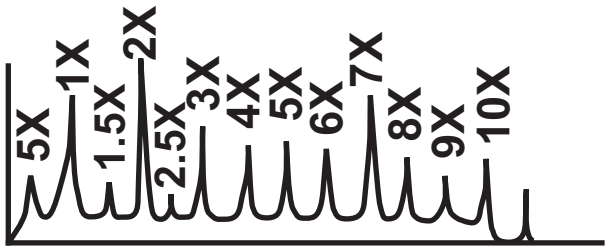

Figura 2.12: Assinatura típica de folga de mancal (TA, 1997)

Defeitos em rolamento

Os principais componentes do rolamento são a pista interna, a pista externa, os elementos rolantes (esferas ou rolos) e a gaiola. A Figura 2.13 mostra um rolamento de esferas de contato angular.

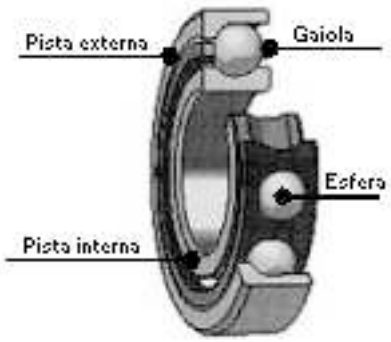

Figura 2.13: Rolamento de esferas de contato angular (MCINERNY; DAI, 2003)

Em rolamentos de esferas de contato angular, o eixo de rotação das esferas forma um ângulo com a transversal das pistas interna e externa, sendo este denominado ângulo de contato.

A Figura 2.14 esquematiza cortes frontal e lateral de um rolamento de esferas de contato angular. Na Figura são ainda destacadas algumas medidas utilizadas no cálculo das freqüências que caracterizam o funcionamento dos rolamentos, sendo D_b - o diâmetro de uma esfera, D_c - o diâmetro da gaiola e θ - o ângulo de contato. As variáveis V_o, V_c e V_i representam, respectivamente, a velocidade com que giram a pista externa, a gaiola e a pista interna.

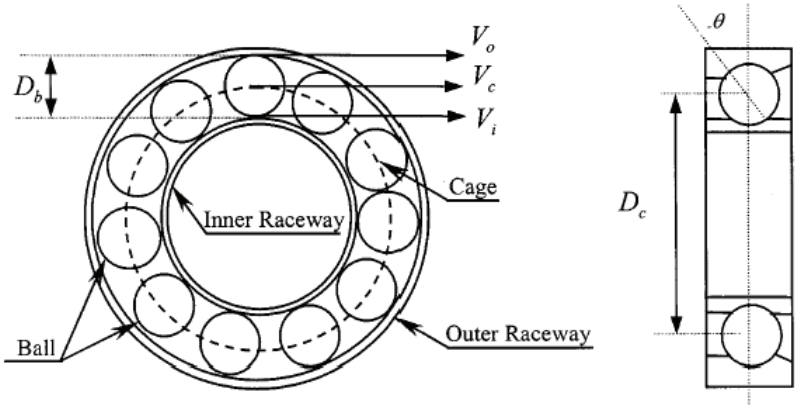

Figura 2.14: Rolamento de esferas de contato angular - cortes frontal e lateral (LI et al., 2000)

São quatro as freqüências características do funcionamento dos rolamentos: freqüência de passagem de elementos rolantes por um ponto da pista interna (F_{BPI} - Ball Pass Inner Race frequency); freqüência de passagem de elementos rolantes por um ponto da pista externa (F_{BPO} - Ball Pass Outer Race frequency); freqüência de giro dos elementos (F_B - Ball Rotational frequency) e freqüência de giro da gaiola ou do conjunto (trem) de elementos rolantes (F_C - Fundamental Cage frequency). Essas freqüências estão ilustradas na Figura 2.15.

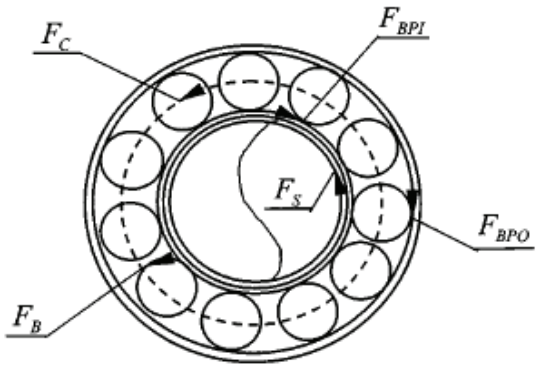

Figura 2.15: Freqüências de funcionamento do rolamento (LI et al., 2000)

Em sistemas motores, a pista externa é fixa, sendo sua freqüência de rotação nula ($F_o = 0$), e a pista interna gira com freqüência F_i igual à freqüência de rotação do eixo motor (F_{SR} - Shaft

Rotation frequency), ou seja, $F_i = F_{SR}$. Nesse caso, as freqüências F_C, F_{BPO}, F_{BPI} e F_B podem ser calculadas pelas Equações 2.5 a 2.8 (LI et al., 2000), respectivamente, onde N_B é o número de esferas do rolamento.

$$F_C = \frac{1}{2} F_{SR} \left(1 - \frac{D_b \cos\theta}{D_c} \right) \tag{2.5}$$

$$F_{BPO} = \frac{N_B}{2} F_{SR} \left(1 - \frac{D_b \cos\theta}{D_c} \right) \tag{2.6}$$

$$F_{BPI} = \frac{N_B}{2} F_{SR} \left(1 + \frac{D_b \cos\theta}{D_c} \right) \tag{2.7}$$

$$F_B = \frac{D_c}{2D_b} F_{SR} \left(1 - \frac{D_b^2 \cos^2\theta}{D_c^2} \right) \tag{2.8}$$

Quando há defeitos nos componentes do rolamento a vibração se acentua nestas freqüências: F_{BPI}, para defeitos na pista interna; F_{BPO}, para defeitos na pista externa; $2xF_B$, para defeitos nos elementos rolantes e F_C, para defeitos na gaiola e em alguns dos elementos rolantes. Os impactos repetitivos gerados pelos defeitos em rolamentos excitam ainda vibrações livres de curta duração (com alto amortecimento) em freqüências naturais elevadas. Assim, aparecem também vibrações mais altas nessa freqüência natural de vibração do rolamento.

As vibrações livres de alta freqüência geradas pelos defeitos de rolamentos possuem intensidade bastante reduzida em comparação com as amplitudes das componentes de baixa freqüência, relacionadas com defeitos de alta energia como: desbalanceamento, desalinhamento, folgas, etc., que podem também estar presentes. Isso dificulta a identificação dos defeitos de rolamento.

Além disso, as vibrações livres de alta freqüência, que se propagam pela caixa dos mancais e estrutura da máquina na forma de ondas de tensão, são moduladas em amplitude pela seqüência de impactos repetitivos e pelo efeito do amortecimento. Assim, três tipos de freqüências (ilustradas na Figura 2.16) podem ser acentuadas na presença de defeitos nos rolamentos: baixas freqüências de alta energia, a freqüência natural do rolamento e as freqüências características apresentadas nas equações 2.5 a 2.8, sendo o último tipo o de maior interesse na detecção de defeitos em rolamentos (MENDEL et al., 2008; MCINERNY; DAI, 2003).

A Figura 2.17 mostra os espectros de freqüência característicos de defeitos de rolamentos em diferentes estágios.

Pela Figura 2.17, observamos que no estágio 1 aparecem vibrações elevadas apenas em freqüências mais baixas de até $5x$ rotação. No estágio 2 começa a se acentuar o componente

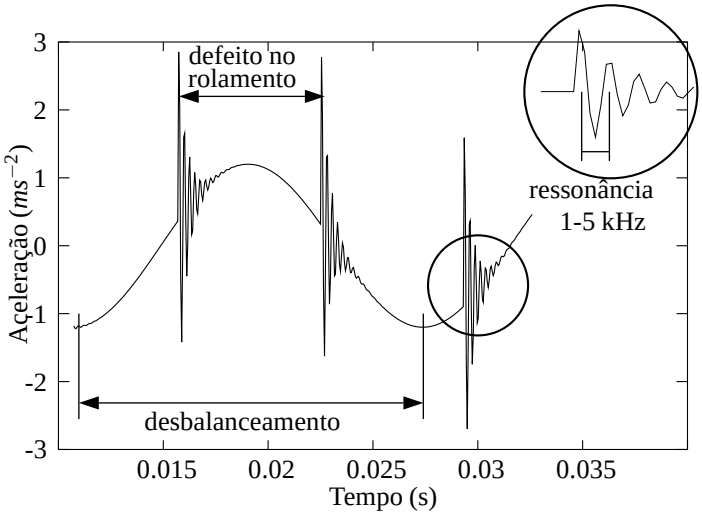

Figura 2.16: Exemplo ilustrativo das freqüências presentes em um sinal vibracional de rolamento defeituoso (MENDEL et al., 2008)

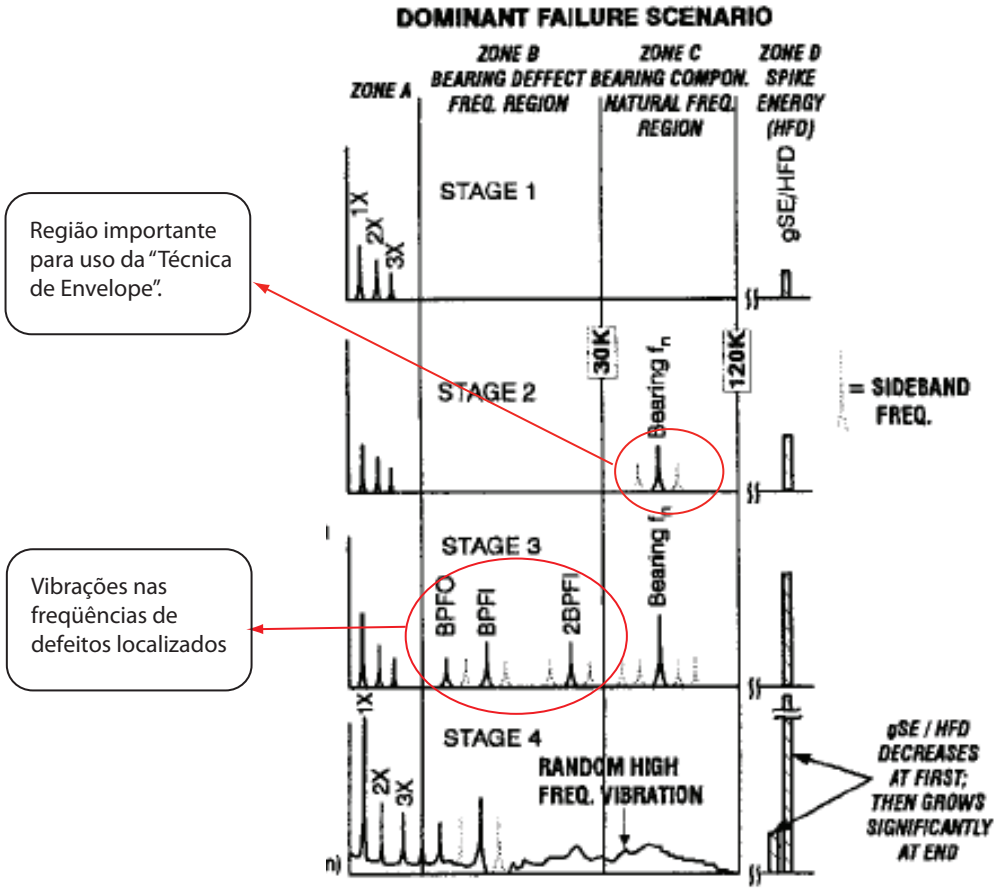

Figura 2.17: Assinaturas típicas de defeitos em rolamento (TA, 1997)

de freqüência natural, com bandas laterais espaçadas nas freqüências dos impactos repetitivos. No estágio 3 os componentes das freqüências características do funcionamento do rolamento já aparecem bastante elevados, e no estágio 4 o estado do rolamento já é bem crítico e aparece uma vibração aleatória em toda a faixa de freqüências mais altas do espectro.

É importante detectar a presença do defeito já no estágio 2. Nesse estágio, porém, as freqüências de interesse aparecem como bandas laterais da freqüência natural do rolamento, devido ao fenômeno de modulação citado anteriormente. Para isolar essas freqüências, é aplicada uma técnica conhecida como análise de envelope, que será explicada no capítulo 3.

2.3.2 Problemas elétricos

A vibração causada por problemas elétricos é normalmente o resultado de forças magnéticas desequilibradas que agem sobre o rotor ou estator. Esse desbalanceamento de forças magnéticas pode ter diversas causas. Abaixo será descrita, para casos específicos, a forma como aparecem as vibrações resultantes das forças magnéticas no rotor e no estator.

Rotor

Problemas de rotor podem ser provocados por barras da gaiola do rotor trincadas ou quebradas; ou ainda curto em lâminas e barras.

Nestes casos, aparece um sinal em 1x rotação, acompanhado por bandas laterais iguais a F_p (freqüência de pólos), que é igual a $2xF_s$ (freqüência de escorregamento). A F_p é determinada por:

$$F_p = 2F_s = n_p \times S, \tag{2.9}$$

onde n_p é o número de pólos e S o escorregamento. Podem aparecer também bandas laterais iguais a F_p nas harmônicas de 2x a 6x rotação.

A Figura 2.18 exemplifica um sinal característico de problemas no rotor.

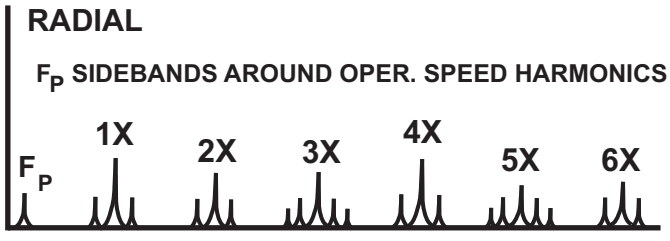

Figura 2.18: Assinatura típica de problemas no rotor (TA, 1997)

Estator

Problemas no estator podem ser provocados por curto-circuito nos enrolamentos ou lâminas do estator; ou ainda por estator não centrado com rotor.

Nestes casos, aparece um sinal igual a $2xF_l$ (freqüência da rede, do inglês *line frequency*) ou 120 Hz.

A Figura 2.19 exemplifica um sinal característico de problemas no estator.

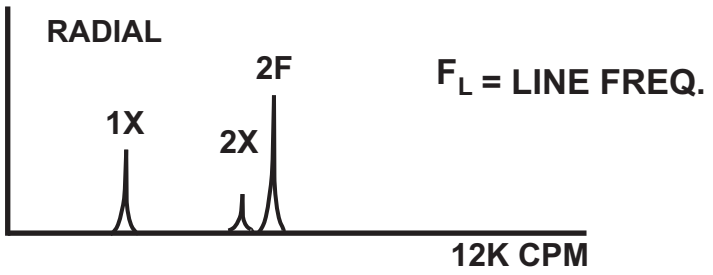

Figura 2.19: Assinatura típica de problemas no estator (TA, 1997)

É importante ressaltar que os sinais mais adequados para o diagnóstico de problemas elétricos são os sinais derivados de medidas elétricas, como corrente e voltagem. A descrição de como esses sinais são afetados na presença de defeitos, entretanto, está fora do escopo deste trabalho, podendo ser encontrada em Tavner et al. (2008).

2.3.3 Problemas hidrodinâmicos

As excitações referentes aos problemas hidrodinâmicos em bombas apresentam usualmente sinal em $1xBPF$ (freqüência de passagem de pás, do inglês *blade pass frequency*), que é determinada pela relação abaixo:

$$BPF = \text{rotacao} \times N_p, \tag{2.10}$$

onde N_p é o número de pás do rotor da bomba.

Além do problema de passagem de pás, existem outros problemas hidrodinâmicos que provocam, além de vibração acentuada em $1xBPF$, excitações em outros níveis de freqüência. Esses problemas (cavitação de turbulência) são descritos a seguir.

Cavitação

A cavitação geralmente ocorre quando a máquina está trabalhando fora de seu ponto de operação (bomba com carga excessiva, por exemplo). No processo de cavitação, as bolhas de vapor do líquido bombeado implodem violentamente criando ondas de pressão que chegam às estruturas gerando vibrações. O rotor da bomba começa a sofrer pequenas erosões.

As implosões são aleatórias e se manifestam nas altas freqüências do espectro, gerando um acréscimo aleatório de energia nas altas freqüências, geralmente sobreposto com harmônicas da *BPF*. Os sinais de defeitos de rolamentos podem ser encobertos pelo sinal de cavitação. A Figura 2.20 exemplifica um sinal característico de cavitação.

Figura 2.20: Assinatura típica de cavitação (TA, 1997)

Turbulência

O fenômeno de turbulência ocorre se estiverem envolvidos altos números de Reynolds. O Reynold (Re) é um número adimensional da fluidodinâmica que especifica se um fluido é ou não turbulento. Tipicamente valores acima de 3000 correspondem a escoamentos turbulentos em dutos fechados.

Tal fenômeno se manifesta na região de baixa freqüência do espectro, na faixa de 0,8 a 33 Hz. A Figura 2.21 exemplifica um sinal característico de turbulência.

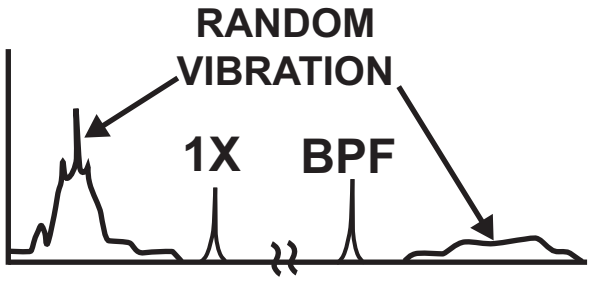

Figura 2.21: Assinatura típica de turbulência (TA, 1997)

3 *Detecção automática de defeitos*

Este trabalho propõe um procedimento automático de reconhecimento de padrões de defeitos em motobombas. O processo engloba quatro fases: extração de características, seleção de características, aprendizado supervisionado para classificação dos padrões (MONARD; BARANAUSKAS, 2003) e estimativa do desempenho de classificação. Este capítulo descreve as técnicas utilizadas em cada uma dessas fases.

3.1 Extração de características

Os sinais de vibração obtidos das motobombas devem ser processados para a obtenção de características discriminativas que descrevam os padrões de defeitos. Esta seção apresenta as técnicas de processamento de sinal utilizadas com esse propósito.

3.1.1 Transformada de Fourier

Cada tipo de defeito afeta as vibrações da máquina em um conjunto de freqüências específico. Por isso, é importante separar a energia de cada componente de freqüência a fim de determinar o tipo de defeito presente. A Transformada de Fourier (BRACEWELL, 1986) realiza essa separação e provê o conjunto de relações de amplitude X freqüência, ou seja, o sinal no domínio da freqüência, que denominamos espectro de freqüência do sinal.

A Transformada de Fourier de um sinal $s(t)$ no domínio do tempo é definida como:

$$\mathscr{F}\{s(t)\} := F(f) = \int_{-\infty}^{\infty} s(t)e^{-i2\pi ft}dt \tag{3.1}$$

,

que é equivalente, utilizando seno e cosseno, a:

$$F(f) = \int_{-\infty}^{\infty} s(t)\cos(-2\pi ft)dt + i\int_{-\infty}^{\infty} s(t)\sin(-2\pi ft)dt \tag{3.2}$$

A transformação baseia-se na idéia de que sinais contínuos e periódicos podem ser vistos como um somatório de funções seno e cosseno. Na transformação, as funções senoidais de mesma freqüência são agregadas para calcular a amplitude total na freqüência. Cada onda senoidal está relacionada também com uma fase, e o espectro de fase X freqüência pode também ser obtido pela utilização da transformada. Neste trabalho, entretanto, é utilizado somente o espectro de amplitude X freqüência, ao qual nos referimos ao utilizar a expressão *espectro de freqüência do sinal*.

3.1.2 Análise de Envelope

A análise de envelope é uma importante técnica de processamento de sinais que auxilia na identificação dos defeitos de rolamento, extraindo freqüências características de falhas a partir do sinal de vibração do rolamento defeituoso. No Capítulo 2 foram introduzidos os tipos de freqüências relacionadas com defeitos em rolamentos e suas relações. Conforme apresentado, no sinal vibracional obtido a partir de um rolamento defeituoso, o componente na freqüência natural do rolamento é modulado em amplitude pelo componente na freqüência característica do defeito. A técnica de análise de envelope permite extrair do sinal original essa freqüência característica, informação indispensável na identificação do defeito de rolamento.

Na modulação em amplitude, diz-se que um sinal de freqüência menor, denominado sinal modulador, modula em amplitude um sinal de freqüência maior, denominado sinal portador. Matematicamente, o sinal resultante é obtido pela multiplicação, no domínio do tempo, do sinal portador pelo sinal modulador. A modulação produz, no domínio da freqüência, um pico na freqüência portadora com bandas laterais com espaçamento igual à freqüência moduladora. Extrair a freqüência do sinal modulador no espectro convencional se torna muito difícil (MCINERNY; DAI, 2003). Os passos da técnica de envelope, por outro lado, permitem obter uma medida direta dessa freqüência e suas harmônicas.

O primeiro passo da técnica é a filtragem do sinal original com um filtro passa-banda, para extrair a região de interesse e eliminar do sinal, no contexto de defeito em rolamento, a influência dos componentes de baixas freqüências associados a defeitos como desbalanceamento e desalinhamento, que possuem alta energia (amplitude).

Em seguida, realiza-se a demodulação do sinal filtrado por meio da aplicação da transformada de Hilbert (BRACEWELL, 1986; CIZEK, 1970). Dado um sinal $h(t)$ no domínio do

tempo, a transformada de Hilbert ($\widetilde{h}(t)$) é obtida pela convolução de $h(t)$ com o sinal $\frac{1}{\pi t}$ (Equação 3.3).

$$\widetilde{h}(t) := \mathscr{H}\{h(t)\} := h(t) * \frac{1}{\pi t} = \frac{1}{\pi}\int_{-\infty}^{\infty} h(t)\frac{d\tau}{t-\tau} \tag{3.3}$$

Dado que a convolução no domínio do tempo é equivalente à multiplicação no domínio da freqüência, a Equação 3.3 equivale, no domínio da freqüência, a:

$$\mathscr{F}\{\widetilde{h}(t)\} = -i \cdot \text{sgn}(\omega) \cdot \mathscr{F}\{h(t)\}, \tag{3.4}$$

onde $\text{sgn}(\omega)$ é a função sinal e $\mathscr{F}$, a transformada de Fourier. Observa-se que a transformada de Hilbert causa uma defasagem de $\pm 90^\circ$ - dependendo do sinal da freqüência - no espectro de freqüência, enquanto as amplitudes mantêm-se inalteradas.

Os sinais $h(t)$ e $\widetilde{h}(t)$ podem ser vistos, respectivamente, como as partes real e imaginária de um sinal complexo $h_a(t)$, denominado sinal analítico (Equação 3.5). O espectro de freqüência do sinal analítico é composto somente por freqüências positivas.

$$h_a(t) := h(t) + i\widetilde{h}(t) \tag{3.5}$$

O envelope do sinal é definido como a amplitude do sinal analítico (Equação 3.6). Mendel et al. (2008) explica com mais detalhes como o envelope pode ser obtido utilizando as relações no domínio da freqüência.

$$\mathscr{E}(t) = \|h_a(t)\| = \sqrt{h^2(t) + \widetilde{h}^2(t)} \tag{3.6}$$

A magnitude da transformada de Fourier do sinal analítico é uma versão (escalada) da magnitude da transformada de Fourier do sinal original, deslocada para as freqüências baixas $\omega - \omega_c$, onde ω_c é a freqüência do sinal portador (freqüência natural do rolamento, no contexto de defeito em rolamento). Dessa forma, o espectro do envelope realça a freqüência do sinal modulador que é, no contexto de defeito em rolamento, o sinal de interesse característico do defeito.

Em resumo, os passos para identificação das freqüências características de defeitos em rolamento, utilizando a técnica de envelope, são:

1. Aplicar a filtragem passa-banda no sinal;

2. Aplicar a transformada de Hilbert;

3. Obter o envelope;

4. Obter o espectro do envelope.

3.1.3 Medidas de amplitude derivadas do espectro

Após a obtenção do espectro de freqüência do sinal, é importante extrair dele características discriminativas dos padrões de defeitos para diagnóstico. Na análise espectral, essas características devem refletir os níveis de amplitude das freqüências afetadas pelos defeitos estudados, determinadas pela assinatura típica de cada defeito.

Kazzaz & Singh (2003) descreve, entre outros métodos de processamento de sinal, técnicas para derivação de medidas de amplitude a partir de sinais de vibração. A derivação mais direta seria retirar do espectro a amplitude do componente de freqüência específico desejado. No entanto, essa abordagem apresenta algumas desvantagens. Freqüentemente o conjunto de freqüências afetadas é diferente, na prática, do conjunto definido pela literatura. Além disso, podem ocorrer variações na velocidade de rotação da máquina, o que provoca um deslocamento, no espectro, dos componentes de freqüência dependentes da velocidade de rotação.

Uma segunda abordagem, a qual denominamos, nesse trabalho, *análise de banda estreita*, leva em consideração a possibilidade de ocorrerem pequenas variações, ou deslocamentos, dos componentes de freqüência do espectro. Na *análise de banda estreita*, pequenas bandas de freqüências em torno da freqüência desejada são tomadas, ao invés de componentes específicos de freqüências. O tamanho das bandas estreitas é determinado por uma porcentagem da freqüência de interesse. A medida derivada da banda pode ser calculada utilizando o valor médio, o valor de pico, ou a energia média (*RMS*) dos componentes da banda.

Outra abordagem apresentada em Kazzaz & Singh (2003) e utilizada neste trabalho é a derivação de medidas de energia de banda. Nessa abordagem, a derivação realizada é o cálculo do valor *RMS* em um intervalo específico de freqüências. O objetivo dessa abordagem é caracterizar defeitos que afetem extensões maiores do espectro.

Uma derivação adicional foi proposta nesse trabalho, para detectar a presença de "ruídos"(acréscimos aleatórios de energia) no espectro, característica da assinatura de defeitos hidrodinâmicos. Nessa derivação, utiliza-se um filtro de mediana, no qual uma janela percorre o intervalo almejado de freqüências e os pontos de cada janela são substituídos pelo valor da mediana das amplitudes na janela. Após a aplicação do filtro, os picos no intervalo são eliminados

e o ruído é evidenciado. A medida final é calculada tomando a média das amplitudes finais do intervalo.

3.2 Seleção de características

O desempenho de um classificador está intimamente relacionado com o conjunto de características utilizado na classificação. Na fase de extração, características iniciais são propostas de acordo com o conhecimento do domínio do problema.

A fase de seleção de características tem como objetivo reduzir a dimensão dos dados (ou o espaço de características), retirando do conjunto inicial gerado informações redundantes, irrelevantes e possíveis ruídos prejudiciais à classificação (LIU; YU, 2002). Porém, isso deve ser feito de forma que seja garantida a capacidade de predição das classes do problema, ou seja, mantendo as características com informação relevante para a classificação.

O processo de seleção de características consiste de quatro passos que, interligados, compõem o algoritmo de seleção: geração dos conjuntos, avaliação dos conjuntos, critério de parada e validação do resultado (LIU; YU, 2002).

O passo de geração dos conjuntos consiste de um processo de busca responsável pela redução da dimensionalidade dos dados. O passo de avaliação do conjunto objetiva verificar a capacidade discriminatória de cada conjunto gerado. O critério de parada define quando o processo de busca será finalizado. A validação do resultado consiste em avaliar o desempenho do classificador gerado com o conjunto de características escolhido. O Algoritmo 1 ilustra, genericamente, o processo completo de seleção.

Algoritmo 1 Seleção de características - algoritmo geral

1: Inicialize o melhor subconjunto S_m
2: **enquanto** (critério de parada não for atingido) **faça**
3: Gere o próximo conjunto a ser avaliado
4: Avalie o conjunto gerado
5: Atualize S_m com o conjunto gerado se este for melhor
6: **fim enquanto**
7: Valide o classificador gerado com S_m

Os passos do processo de seleção de características são explicados nas próximas seções.

3.2.1 Geração dos conjuntos

O processo de geração de conjuntos consiste em um processo de busca que objetiva selecionar, utilizando uma métrica de desempenho (ou critério de avaliação) $J(S_F)$, um subconjunto S_F de características, contido no conjunto originalmente disponível, que apresente o melhor desempenho.

De acordo com Theodoridis & Koutroumbas (2003), existem duas abordagens a seguir: seleção escalar e seleção vetorial.

Na seleção escalar, as características são avaliadas individualmente. As melhores características formam o subconjunto selecionado. Na seleção vetorial, ao invés de tratar as características separadamente, conjuntos (ou vetores) de características são considerados em cada avaliação.

A seleção escalar possui a vantagem de simplicidade computacional, porém não leva em consideração a correlação entre as características. Neste trabalho a abordagem utilizada é a seleção vetorial, descrita a seguir.

Seleção vetorial de características

Dado um conjunto inicial com N características, existem 2^N combinações de subconjuntos disponíveis para avaliação. Avaliar todas as combinações para se obter o subconjunto ótimo (processo conhecido como busca exaustiva) se torna computacionalmente inviável mesmo para valores moderados de N.

Existem ainda outras técnicas de busca ótimas (THEODORIDIS; KOUTROUMBAS, 2003) que não necessitam percorrer todas as combinações, mas estas requerem restrições sobre o critério de avaliação, não satisfeitas pelo critério utilizado neste trabalho.

Os métodos de busca subótimos guiam-se de acordo com alguma heurística, evitando a geração de todos os conjuntos para avaliação. Os algoritmos que utilizam heurísticas produzem resultados rápidos, porém não há garantia de que o resultado ótimo será atingido. Dentre os métodos heurísticos disponíveis, temos a seleção seqüencial incremental (SFS - do inglês, *Sequential Forward Selection*), utilizada neste trabalho.

Seleção seqüencial incremental (SFS)

O processo de SFS (THEODORIDIS; KOUTROUMBAS, 2003) percorre o espaço de busca inserindo, a cada iteração, uma nova característica no conjunto final, a partir do conjunto vazio. O Algoritmo 2 ilustra os passos da seleção seqüencial incremental.

Algoritmo 2 Seleção Seqüencial Incremental

Entrada: conjunto de características originais *FA*

1: Inicialize S_F com o conjunto vazio
2: **enquanto** (critério de parada não for atingido) **faça**
3: Para cada elemento fa de *FA*, avalie o subconjunto formado por $S_F \cup \{fa\}$
4: Retire de *FA* e inclua em S_F o elemento que produziu o melhor resultado.
5: **fim enquanto**
6: Retorne S_F

O algoritmo recebe como entrada o conjunto original de características *FA*. Na linha 1 do algoritmo o conjunto final de características selecionadas, S_F, é inicializado com o conjunto vazio. A seguir são executadas as iterações do algoritmo, até que um critério de parada, conforme será explicado na seção 3.2.3, seja atingido. Em cada iteração, cada característica ainda presente em *FA* é unida ao conjunto S_F para compor um subconjunto de características para avaliação (linha 3), e então os subconjuntos formados são avaliados de acordo com um critério de avaliação. O processo de avaliação será explicado na seção 3.2.2. Na linha 4 do algoritmo, o elemento de *FA* que tiver produzido o melhor resultado é retirado de *FA* e incluído no conjunto de características selecionadas, S_F.

O algoritmo de SFS é computacionalmente viável, sendo sua complexidade quadrática, e é mais robusto do que um método de seleção escalar, pois considera a correlação entre características diferentes. Esses fatores motivaram a sua escolha.

3.2.2 Avaliação dos conjuntos

Para realizar a avaliação dos conjuntos no algoritmo de seleção é utilizado um critério de avaliação. O critério utilizado influencia completamente o resultado final, dado que o desempenho de cada conjunto pode ser diferente para critérios diferentes.

De acordo com Liu & Yu (2002), os critérios são divididos em duas categorias: independentes de aprendizado e dependentes de aprendizado.

Critérios independentes de aprendizado avaliam o desempenho de um subconjunto sem o envolvimento de um algoritmo de aprendizado no processo. Exemplos de critérios deste tipo

são as medidas de distância, de dependência e de informação (LIU; YU, 2002). A idéia básica das medidas de distância é tentar maximizar a separabilidade das classes do problema. Métricas deste tipo podem ser encontradas em Theodoridis & Koutroumbas (2003), Devijver & Kittler (1982).

Critérios dependentes de aprendizado, abordagem utilizada neste trabalho, avaliam o desempenho de um subconjunto por meio de métricas obtidas após aplicação de um algoritmo de aprendizado em exemplos representados pelas características do subconjunto. Em geral, estes critérios são os mais adequados para problemas de classificação. Nesse caso, a métrica mais utilizada é a taxa de acerto, estimada como a razão entre o número de exemplo corretamente classificados sobre o número total de exemplos, conforme Equação 3.7.

$$J(S_F) = \frac{N_c}{N} \tag{3.7}$$

3.2.3 Critério de parada

O critério de parada define uma condição necessária para que o processo de seleção seja finalizado, podendo ser um estado do desempenho do algoritmo tomado como satisfatório ou uma restrição sobre o seu tempo de execução.

Os principais critérios utilizados para finalizar o processo de busca são (LIU; YU, 2002):

- se o número desejado de características foi alcançado;
- se o algoritmo realizou o número máximo de iterações permitidas;
- se durante um número específico de iterações o critério de avaliação não foi melhorado;
- se o valor ótimo para o critério de avaliação foi atingido.

O critério utilizado neste trabalho foi o primeiro critério citado acima.

3.2.4 Validação do resultado

O conjunto de características encontrado no processo de seleção deve ser validado. Para isso, deve-se realizar testes com o conjunto selecionado e com o conjunto original, comparando o desempenho obtido pelos classificadores gerados por cada conjunto, treinados com bases de dados reais ou artificiais (LIU; YU, 2002).

O processo de validação só precisa ser realizado no caso de o critério de avaliação utilizado ser independente de aprendizado. No caso de critérios dependentes de aprendizado, a avaliação do desempenho de classificação obtido com o conjunto selecionado já é realizada durante a busca pelo melhor conjunto.

3.3 Algoritmo de classificação

No problema de classificação, existem dois extremos distintos: o caso em que as funções de densidade de probabilidade dos dados em relação às classes são conhecidas e o caso em que não se conhece a distribuição de probabilidade, mas somente um conjunto de exemplos rotulados.

No primeiro caso, pode ser utilizada a análise de Bayes (DUDA; HART; STORK, 2001) para obter a regra ótima de decisão, com erro teórico mínimo. Na prática, dificilmente a distribuição de probabilidade é conhecida. Neste caso podem ser utilizadas para classificação técnicas não-paramétricas (DUDA; HART; STORK, 2001), que podem ser utilizadas sem a suposição de que a forma das funções de densidade são conhecidas. Entre essas técnicas encontra-se a do vizinho mais próximo.

3.3.1 Algoritmo do vizinho mais próximo

A técnica do vizinho mais próximo (NN - do inglês, *Nearest Neighbor*)(DUDA; HART; STORK, 2001) considera que elementos próximos na região do espaço definido pelo vetor de características pertencem à mesma classe. Tal heurística baseia-se na suposição de que os exemplos conhecidos são independentes e identicamente distribuídos em relação à distribuição original dos dados (COVER; HART, 1967).

Nsta técnica, para realizar a classificação de um exemplo não rotulado, calcula-se a distância (de acordo com alguma métrica preestabelecida) entre o exemplo não rotulado e todos os exemplos de rótulo conhecido. A classe do exemplo rotulado de menor distância é atribuída ao exemplo não rotulado.

Mais formalmente: seja $D^n = \{x_1, \ldots, x_n\}$ um conjunto de n exemplos rotulados e x um exemplo cuja classe é desconhecida. O vizinho mais próximo de x é o exemplo $x' \in D^n$ tal que:

$$\delta(x, x') = \min_{i=\{1,2,\ldots,n\}} \delta(x, x_i) \tag{3.8}$$

onde δ é a métrica de distância utilizada. Atribui-se a x a classe de x'.

Uma das principais vantagens do algoritmo do vizinho mais próximo é a sua simplicidade, dado que o treinamento do classificador consiste em apenas manter os exemplos rotulados conhecidos e, pelo mesmo motivo, é facilmente adaptável para contemplar novos exemplos. Outra característica importante se refere à taxa de erro obtida pelo classificador do vizinho mais próximo. Supondo que o número de exemplos disponíveis seja suficiente para representar o universo real do problema, ela é limitada superiormente pelo dobro da taxa de erro obtida pela utilização do modelo bayesiano (DIETTERICH, 1998; DUDA; HART; STORK, 2001), sendo possível utilizá-la para obter uma estimativa do melhor desempenho teórico atingível.

Breiman et al. (1984) apresenta algumas desvantagens na utilização do algoritmo do vizinho mais próximo, dentre as quais podemos citar: a heurística é sensível à escolha da métrica de distância, cujo desempenho varia de acordo com o problema abordado, e não gera a partir dos dados informações adicionais, com possível capacidade discriminativa. Apesar dessas limitações, e dadas as características de simplicidade e limitação do erro em relação ao erro teórico mínimo, a técnica do vizinho mais próximo se torna uma técnica adequada para exploração inicial do desempenho atingível ao elaborar soluções para um problema específico.

Uma variação do NN é obtida se, ao invés de um vizinho mais próximo, um número $k > 1$ de vizinhos mais próximos forem considerados na definição do rótulo do exemplo desconhecido. Nesta variação, chamada de kNN (do inglês, *k-Nearest Neighbor*), o rótulo do exemplo desconhecido é determinado pelo voto majoritário entre as classes dos k vizinhos tomados. O valor de k utilizado deve ser o menor possível, de forma que não misture exemplos de regiões do espaço de classes distintas, mas suficientemente grande para evitar que poucos exemplos de classificação incorreta interfiram na classificação (DUDA; HART; STORK, 2001).

O algoritmo NN tem como resultado apenas a classe predita para os exemplos desconhecidos. A métrica utilizada nesse trabalho para avaliação do desempenho dos classificadores - explicada na seção 3.4.2, entretanto, necessita que eles produzam um valor numérico que represente o grau com que o exemplo pertence à classe predita. Para atingir esse próposito, foi utilizada uma extensão natural do algoritmo kNN, a qual denominaremos kNN_{DW} (do inglês, *k-Nearest Neighbor with Distance Weighted*) (WETTSCHERECK, 1994).

No algoritmo kNN_{DW}, o voto entre os k vizinhos é ponderado utilizando pesos inversamente proporcionais à suas distâncias. Para um exemplo x de rótulo desconhecido, dados seus vizinhos mais próximos $y_i \in \{y_1, \ldots, y_k\}$, estima-se a probabilidade $\tilde{p}(c|x)$ do exemplo x pertencer à classe c pela fórmula(JIANG; ZHANG; SU, 2005):

$$\tilde{p}(c|x) = \frac{\sum_{i=1}^{k} w_i \delta(c, c(y_i))}{\sum_{i=1}^{k} w_i} \tag{3.9}$$

onde w_i e $c(y_i)$ são, respectivamente, o peso e a classe do vizinho y_i, e δ é a função:

$$\delta(u,v) = \begin{cases} 1, & u = v \\ 0, & u \neq v \end{cases} \tag{3.10}$$

A classe atribuída ao exemplo x é a classe c tal que $\tilde{p}(c|x)$ é máxima. Neste trabalho utilizou-se $w_i = \frac{1}{d^2(x,y_i)}$, onde d é a distância euclidiana.

3.4 Estimativa de desempenho

A estimativa do desempenho de classificadores objetiva medir e avaliar a qualidade dos classificadores construídos. O processo de obtenção da medida de qualidade envolve a utilização de um método de medição e uma métrica. O método de medição, aqui denominado método de estimativa, descreve o processo utilizado para se obter a medida. Já a métrica define o tipo de medida utilizada. Esta seção descreve o método de estimativa e a métrica utilizados neste trabalho.

3.4.1 Método de estimativa

O método de estimativa define a forma como o conjunto de exemplos conhecidos será utilizado para estimar a medida de desempenho, ou seja, como obter do conjunto disponível amostras para treinamento e teste do classificador.

Um estimador comumente utilizado e bem aceito pela comunidade de aprendizado de máquina é o procedimento de validação cruzada (MONARD; BARANAUSKAS, 2003). Neste método, o conjunto de exemplos conhecidos é dividido aleatoriamente em r conjuntos disjuntos, para a realização de r rodadas de treinamento e teste. Em cada rodada, um dos r conjuntos é utilizado para teste e os $r-1$ conjuntos restantes são utilizados para treinamento. O valor do desempenho final obtido é a média dos valores obtidos, para a métrica utilizada, em cada uma das r rodadas.

Geralmente é necessário, durante o treinamento do classificador, realizar ajustes nos parâmetros do modelo utilizado. Os conjuntos finais de teste não devem ser utilizados para o ajuste do modelo, a fim de evitar que ele seja superajustado e, por conseguinte, que a métrica de

desempenho seja superestimada. Uma porção do conjunto de treinamento deve, portanto, ser reservada para testar as configurações de parâmetros exploradas (SALZBERG, 1997).

Salzberg (1997) propõe uma metodologia que inclui a etapa de ajuste de parâmetros no estimador de validação cruzada. Neste trabalho, a etapa de ajuste do modelo consiste na aplicação do algoritmo de seleção de características (SFS), descrito na seção 3.2.1. O Algoritmo 3 resume o processo de estimativa de desempenho implementado, que é uma adaptação da metodologia de Salzberg (1997) para inclusão do processo de seleção de características na etapa de ajuste do modelo.

Algoritmo 3 Estimativa de desempenho com ajuste de parâmetros

Entrada: $S = \{(x_1, \theta_1), \ldots, (x_n, \theta_n)\}$,conjunto de instâncias de treinamento;
$C = \{c_1, \ldots, c_D\}$, conjunto de características a serem exploradas, de dimensão D;
Saída: de_m, o desempenho médio das r execuções da validação cruzada.

1: $Y \leftarrow \{Y_1, Y_2, \ldots, Y_r\}$ *// subconjuntos disjuntos e aleatórios de S para validação cruzada*
2: **para todo** $Y_i \in Y$ **faça**
3: $T \leftarrow Y - \{Y_i\}$ *// conjunto de treinamento da rodada*
4: Aplique no conjunto T o Algoritmo 2(SFS), obtendo o conjunto C_s, com d características selecionadas
5: Treine o classificador utilizando os exemplos de T com as d características selecionadas
6: Atualize de_m de acordo com o desempenho obtido no conjunto de teste Y_i
7: **fim para**
8: **retorne** de_m

O algoritmo SFS implementado utiliza para avaliação dos subconjuntos de características um critério dependente de aprendizado obtido pela aplicação de validação cruzada com 3 conjuntos no conjunto T. O critério de parada adotado foi o alcance de um número máximo de características. A métrica utilizada no Algoritmo 3 para medir o desempenho dos classificadores (inclusive no processo de seleção de características) será explicada na seção 3.4.2.

Os valores dos parâmetros k (número de vizinhos mais próximos) e d (número de características selecionadas) foram definidos experimentalmente, utilizando o método *leave-one-out* de validação em 50% dos exemplos disponíveis, antes da aplicação do Algoritmo 3. O método *leave-one-out* pode ser considerado uma versão da validação cruzada em que o número r de conjuntos é igual ao número de exemplos. A utilização de apenas 50% dos exemplos para a definição dos parâmetros foi escolhida como forma de evitar o superjuste do modelo aos dados disponíveis. Os valores de k e d resultantes da experimentação, e utilizados no Algoritmo 3, são, respectivamente, 9 e 20.

3.4.2 Métrica de avaliação do desempenho

A avaliação de sistemas classificadores é baseada na matriz de confusão gerada pela classificação do conjunto de teste. Geralmente são utilizadas, para avaliação, métricas derivadas da matriz, que resumem seus campos em um único valor, utilizado como índice de desempenho do classificador.

A Figura 3.1 mostra a matriz de confusão para problema de duas classes (todas as descrições realizadas nesta seção são baseadas em problemas desse tipo).

	Classe Predita Negativa	*Classe Predita Positiva*
Classe Real Negativa	**Negativos Verdadeiros (TN)**	**Positivos Falsos (FP)**
Classe Real Positiva	**Negativos Falsos (FN)**	**Positivos Verdadeiros (TP)**

Figura 3.1: Matriz de confusão

As linhas da matriz representam a classificação real dos exemplos e as colunas, as classes preditas pelo modelo de classificação. As células internas da matriz contabilizam o número de exemplos inseridos em cada uma das quatro situações possíveis referentes à relação classe real/classe predita:

- TN (do inglês, *true negatives*): exemplos negativos corretamente classificados;
- FN (do inglês, *false negatives*): exemplos positivos incorretamente classificados como negativos;
- FP (do inglês, *false positives*): exemplos negativos incorretamente classificados como positivos;
- TP (do inglês, *true positives*): exemplos positivos corretamente classificados.

Abaixo são apresentadas as equações de algumas métricas que podem ser obtidas a partir da matriz de confusão (FAWCETT, 2006). Nas equações, P representa o total de exemplos de classe real positiva e N, o total de exemplos de classe real negativa.

$$\text{Taxa de acerto} = \frac{TP+TN}{P+N} \tag{3.11}$$

$$\text{Taxa } tp = \frac{TP}{P} \tag{3.12}$$

$$\text{Taxa } fp = \frac{FP}{N} \tag{3.13}$$

$$\text{Sensitividade} = \text{taxa } tp \tag{3.14}$$

$$\text{Precisao} = \frac{TP}{TP + FP} \tag{3.15}$$

$$\text{Medida-F} = \frac{2}{1/\text{precisao} + 1/\text{sensitividade}} \tag{3.16}$$

As métricas *Taxa de acerto* e *Medida-F*, comumente utilizadas para avaliação do desempenho de sistemas classificadores, são sensíveis a mudanças na distribuição de classes dos exemplos. A *Taxa de acerto* é ainda imprópria para utilização em domínios cujas classes são desbalanceadas (independente de mudanças na distribuição) (PRATI; BATISTA; MONARD, 2008), o que ocorre no domínio de identificação de defeitos em motobombas.

Uma métrica recentemente utilizada em aprendizado de máquina (BRADLEY, 1997), apropriada para domínios de distribuição de classe assimétrica e invariante em relação a mudanças na distribuição, é derivada da análise ROC, cujos conceitos e características (FAWCETT, 2006) serão explicados a seguir.

Análise ROC

Análise ROC (do inglês *Receiver Operating Characteristics*) é um método gráfico que permite avaliar e comparar o desempenho de sistemas classificadores.

No espaço ROC (Figura 3.2), um ponto é um par de valores do tipo (*taxa fp*, *taxa tp*), que representa o desempenho obtido por um classificador discreto (que produz apenas o rótulo da classe estimada, para cada exemplo).

A posição do ponto no espaço ROC permite extrair informações qualitativas sobre o classificador. Por exemplo, os classificadores que obtêm os melhores resultados produzem valores na região noroeste do espaço ROC, onde as taxas de positivos verdadeiros são maiores e as taxas de falsos positivos são menores. Pontos sobre a diagonal principal (onde $taxa\ fp = taxa\ tp$)

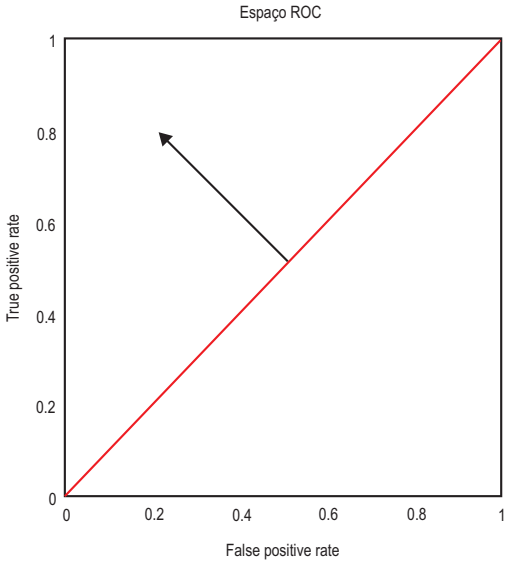

Figura 3.2: Espaço ROC

representam comportamento aleatório. Por exemplo, um ponto (p, p) no gráfico representa um classificador que classifica aleatoriamente um exemplo na classe positiva com probabilidade p.

Curva ROC

Classificadores discretos produzem apenas um ponto no espaço ROC. Entretanto, diversos classificadores, como Naive Bayes e Redes Neurais (DUDA; HART; STORK, 2001), fornecem, para cada exemplo, uma probabilidade, ou simplesmente uma pontuação, que indica o grau com que o exemplo pertence à classe positiva. A atribuição de rótulos aos exemplos resulta da comparação dos valores gerados com um limiar pré-definido.

Cada valor de limiar utilizado produz um classificador discreto e um ponto diferente no espaço ROC. Variando o limiar no conjunto $[-\infty, \infty]$, obtém-se uma curva no espaço ROC.

Para comparar classificadores de forma automática é necessário obter um valor escalar simples que meça o desempenho do classificador. Na análise ROC, a métrica derivada é obtida calculando-se a área abaixo da curva ROC (ROC AUC - *Area under ROC curve*). A ROC AUC representa a probabilidade do classificador atribuir, a uma instância positiva aleatoriamente escolhida, uma pontuação maior do que a uma instância negativa aleatoriamente escolhida.

Como a curva ROC está no espaço $[0,0]x[1,1]$, a ROC AUC terá sempre valores entre 0 e 1. O valor 0.5 representa comportamento aleatório, já que a curva ROC produzida por estes classificadores é a reta $taxa\ fp = taxa\ tp$, que possui área igual a 0.5. Assim, classificadores com informações discriminativas relevantes devem produzir uma ROC AUC maior que 0.5.

4 Avaliação experimental

Este capítulo descreve os experimentos realizados para avaliação da estratégia proposta e os resultados obtidos.

4.1 Descrição dos dados

A base original utilizada para extração dos dados finais para realização dos experimentos contém exemplos reais compostos por 1000 medições adquiridas de motobombas localizadas em plataformas de extração de petróleo. As motobombas possuem o tipo descrito na Seção 2.1.

Cada ponto (dentre 1, 2, 3 e 4) e direção de uma medição (2 radiais e uma axial) podem fornecer 6 sinais de vibração, um para cada combinação de unidade (velocidade, aceleração ou envelope de aceleração) e domínio (tempo ou freqüência). Existe, portanto, um conjunto de 60 sinais de vibração possíveis para cada medição. No entanto, no processo de análise dos especialistas, muitos sinais são descartados, sendo armazenados somente os sinais considerados mais importantes para a detecção dos defeitos. Na maioria dos casos os sinais no domínio do tempo e na unidade de aceleração estão ausentes.

Na base utilizada só estão presentes medições que contêm algum sinal alarmado, ou seja, em todas as medições presentes na base, pelo menos um dos sinais medidos ultrapassou o primeiro nível de algum dos alarmes descritos na seção 2.2.1.

Cada medição pode estar também relacionada a vários defeitos, já que as máquinas são freqüentemente afetadas por mais de um defeito ao mesmo tempo. Além disso, os componentes da máquina, motor e bomba, podem ser afetados por defeitos diferentes. Assim, cada sinal vibracional medido pode estar relacionado a mais de uma classificação de defeito, e sinais diferentes de uma mesma medição podem ter classificações diferentes.

4.2 Configuração dos experimentos

Quatro classes de defeitos foram abordadas na realização dos experimentos: desbalanceamento, desalinhamento, defeitos em rolamentos e defeitos hidrodinâmicos (problema de passagem de pás, turbulência e cavitação). A escolha dos defeitos abordados foi motivada pela maior disponibilidade de dados pertencentes a essas classes de defeitos. Dados presentes na base original, cujas classificações incluem outros tipos de defeitos, foram desconsiderados.

Dado que um mesmo exemplo pode conter mais de uma classificação, utilizou-se a abordagem *um-contra-todos*, na qual um experimento diferente é realizado para cada classe de defeito avaliada. Em cada experimento, existem apenas duas classes: positiva (quando o exemplo possui o defeito em questão) e negativa (quando o exemplo não possui o defeito em questão). Um exemplo que possua desalinhamento e problemas em rolamento, por exemplo, é classificado positivamente nos experimentos que avaliam esses defeitos, e negativamente nos experimentos de desbalanceamento e defeitos hidrodinâmicos.

A definição da estratégia proposta neste trabalho abordou escolhas de técnicas em cada etapa do processo de classificação. Como a definição das características utilizadas para descrever os exemplos tem papel fundamental no desempenho da solução, optou-se por avaliar a utilidade da aplicação de um método automático de seleção de características. Para isso, dois tipos de experimentos foram realizados, para cada classe de defeito: com seleção manual e com seleção automática de características.

4.2.1 Descrição das características

Esta seção descreve os conjuntos de características utilizadas nos experimentos com seleção manual e automática.

Conjunto manual

Os trabalhos na área de detecção de defeitos em máquinas rotativas que utilizam análise espectral para extração das características tipicamente definem o conjunto de características manualmente, utilizando o conhecimento especialista adquirido. Nesses trabalhos, o conjunto final engloba características relativas às amplitudes nas freqüências afetadas por cada tipo de defeito incluído no experimento.

Santiago & Pederiva (2002) utiliza as amplitudes das seis primeiras harmônicas da velocidade de rotação, para identificar defeitos de desbalanceamento, folga mecânica e defeitos

elétricos. Em Zhang, Ganesan & Xistris (1996) são tratados os defeitos de desbalanceamento, desalinhamento e falta de lubrificação em rolamentos de fricção. O conjunto de características utilizado engloba as amplitudes nas duas primeiras harmônicas e em 43% da velocidade de rotação, além do valor pico-a-pico do sinal no domínio do tempo.

Li et al. (2000) abordou os seguintes tipos de defeitos encontrados em rolamentos de elementos rolantes: defeito no elemento rolante, na pista interna e na pista externa. Para compor o conjunto de características, foram utilizadas os somatórios das amplitudes de todos os pontos existentes em uma faixa de 5Hz em torno das freqüências F_C, F_{BPI} e F_{BPO}. Foram incluídas também características no domínio do tempo: amplitude máxima, amplitude média e fator de curtose. Não foram encontrados trabalhos que utilizam medidas derivadas do espectro de freqüência para detectar problemas hidrodinâmicos.

Seguindo uma abordagem semelhante aos trabalhos descritos, foram incluídas, no conjunto manualmente definido de características, as amplitudes obtidas do espectro nas freqüências que são afetadas pelos defeitos de desbalanceamento, desalinhamento, defeitos em rolamento e hidrodinâmicos (TA, 1997). A Tabela 4.1 na página 53 resume o conjunto de características utilizado nos experimentos manuais.

As características das linhas 2 a 10 da Tabela foram incluídas para tratar defeitos de desbalanceamento e desalinhamento; as linhas 11 e 12, turbulência; a linha 13, cavitação; as linhas 14 e 15, todos os defeitos hidrodinâmicos, e as linhas 20 a 23, defeitos em rolamentos. Os valores de *RMS* do sinal completo (linhas 16 a 19) fornecem uma medida da energia global dos sinais de vibração.

Características extraídas do domínio do tempo ou de sinais na unidade de aceleração não foram utilizadas devido à ausência freqüente desses sinais na base de dados disponível para testes. A característica *rms_total_HA* pode ser utilizada porque, sendo uma informação importante para a constatação da presença de alarme, é armazenada na base original de dados. Desta forma, não foi preciso derivá-la do sinal.

Conjunto automático

O conjunto utilizado como entrada para o algoritmo de seleção automática (o qual nos referimos por *conjunto automático*) é uma extensão do conjunto manual, totalizando 84 características.O objetivo almejado na definição do conjunto automático foi cobrir uma extensão maior do espectro, detectando amplitudes de freqüências que estejam deslocadas em relação às freqüências teóricas esperadas.

O conjunto contém um número mais amplo de características do tipo *banda estreita*, englobando um número maior de harmônicas das freqüências base. Foram incluídas, ainda, características representativas de *energias de bandas*, e somatórios de amplitudes de harmônicas de baixas freqüências (considerando também bandas estreitas em torno das harmônicas). O foco principal da cobertura foram as baixas freqüências, visto que nelas há uma sobreposição maior de padrões característicos de diferentes defeitos. O conjunto automático completo é apresentado no Apêndice A.

4.3 Resultados obtidos

Esta seção discute os resultados obtidos na experimentação realizada. Inicialmente são apresentadas as distribuições de classes obtidas após a extração das características, para cada classe de defeitos abordada e, em seguida, os valores de desempenho resultantes da aplicação do Algoritmo 3.

4.3.1 Distribuições de classes

Para os defeitos de desbalanceamento e rolamento, cada medição da base original gerou dois exemplos na base final utilizada para os experimentos: um com as características extraídas a partir do sinal de maior *RMS* entre os pontos 1 e 2 do motor, e um com as características extraídas a partir do sinal de maior *RMS* entre os pontos 3 e 4 da bomba. O exemplo extraído dos pontos do motor foi classificado positivamente se o motor apresentara o defeito em questão e, negativamente, caso contrário; idem para a bomba. Como motor e bomba podem ser afetados por defeitos distintos, as classificações dos exemplos gerados por uma mesma medição podem ser diferentes.

Nos experimentos de desalinhamento e defeitos hidrodinâmicos, cada medição gerou apenas um exemplo na base final. No caso do experimento de desalinhamento, as características dos exemplos foram extraídas a partir do sinal de maior *RMS* entre os pontos 2 e 3 do conjunto motobomba. Cada exemplo foi classificado positivamente se o conjunto apresentara o defeito de desalinhamento e, negativamente, caso contrário. Já no experimento de defeitos hidrodinâmicos, o sinal utilizado para extrair as características dos exemplos gerados foi o de maior *RMS* entre os pontos 3 e 4 da bomba. A classificação de cada exemplo foi considerada positiva se e somente se a bomba apresentara um defeito hidrodinâmico.

Em todos os experimentos, exemplos da base de dados gerada que obtiveram alguma carac-

terística ausente foram descartados. A Tabela 4.2 na página 54 exibe as distribuições de classes obtidas nos quatro experimentos.

4.3.2 Análise do desempenho

As Tabelas 4.3 e 4.4 (página 54) apresentam, respectivamente, os valores das métricas ROC AUC e taxa de acerto resultantes do processo de estimativa de erro, para cada experimento realizado.

Analisando os resultados apresentados nas Tabelas 4.3 e 4.4, podemos constatar algumas indicações interessantes sobre o processo automático de reconhecimento de padrões de defeitos em motobombas desenvolvido, com e sem o procedimento automático de seleção de características, embora não sejam comprovações estatísticas.

Para facilitar a exposição das considerações efetuadas, as análises foram divididas em três categorias: análise comparativa (comparação dos conjuntos manual e automático), análise sobre os resultados do conjunto automático e análises gerais (considerando todos os resultados obtidos).

Análise comparativa

Na maioria dos casos (4 de 4 observando a taxa de acerto e 3 de 4 observando a métrica ROC AUC), a seleção automática foi, na média, melhor do que a seleção manual. Esse resultado é uma indicação de que o método automático de seleção, de fato, auxilia na identificação de atributos descritivos relevantes. A taxa de acerto obtida no experimento de defeitos hidrodinâmicos com seleção manual (54,76%), por exemplo, foi aproximadamente igual à probabilidade a priori da classe *Hidrodinâmico* (54,38%), indicando aleatoriedade nas classificações. Tal fato não ocorreu no experimento em que o conjunto automático foi utilizado, que obteve a taxa de acerto de 66,44%.

Se considerarmos não apenas o valor médio, mas os intervalos do tipo [média $\pm$ desvio padrão], qualquer par de intervalos composto pelos resultados da seleção manual e automática, em um mesmo experimento, se interceptam. Uma possível explicação para essa região de proximidade no desempenho surge a partir da análise do procedimento utilizado para a definição dos conjuntos de características: os dois casos se basearam nas mesmas regras de domínio. Logo, os conjuntos, apesar de quantitativamente diferentes, tendem a ser qualitativamente próximos.

Análise sobre os resultados do conjunto automático

É importante considerar que o processo de estimativa de erro que inclui a seleção automática requer uma fase de ajuste de parâmetros (a seleção em si) dependente do estimador de validação cruzada. Para minimizar o custo computacional do algoritmo, o processo de validação cruzada para ajuste de parâmetros foi executado com apenas 3 conjuntos, o que reduz a quantidade de padrões conhecidos pelo algoritmo de seleção em 33%, desfavorecendo os resultados do conjunto automático. Uma alternativa seria utilizar *leave-one-out* no ajuste das características, porém isso tornaria o algoritmo mais custoso computacionalmente.

Análises gerais

Observando a Tabela de resultados com a métrica ROC AUC (Tabela 4.3), percebe-se que os intervalos do tipo [média $\pm$ desvio padrão], com exceção do experimento de defeitos hidrodinâmicos com seleção manual, superaram o valor 0.5, indicando que, em geral, não houve aleatoriedade nas classificações.

Os experimentos de defeitos hidrodinâmicos apresentaram os piores resultados. Três hipóteses foram formuladas para explicar esse fato:

1. As informações derivadas do espectro não representam adequadamente os padrões destes tipos de defeitos;
2. O sinal de vibração pode não ser o mais adequado para representar os padrões destes defeitos, e outros tipos de sinais devem ser utilizados, como medidas de pressão.
3. O algoritmo de aprendizado utilizado pode não ser adequado para discriminar esse tipo de defeito.

Por fim, as taxas de acerto obtidas não alcançaram a taxa de acerto esperada na análise feita por um especialista, que é de 95% (ALMEIDA, 2008). Isso indica que a análise do especialista é mais precisa. Essa taxa, no entanto, é subjetiva, e podemos considerar a possibilidade de que ela seja superestimada. Além disso, o método automático de detecção provê um ganho em relação à capacidade elevada de processamento. Na prática, os dois tipos de análise podem ser combinados de forma a aproveitar as vantagens de cada um.

Tabela 4.1: Conjunto manual de características

Nome abreviado	**Descrição**	**Direção**	**Unidade**
pico_10%_1xrot_HV	Amplitude máxima da banda estreita centrada em 1*x* rotação, com largura igual a 10% da freqüência central.	Horizontal	Velocidade
pico_10%_2xrot_HV	Idem acima com freqüência central igual a 2*x* rotação.	Horizontal	Velocidade
pico_10%_3xrot_HV	Idem acima com freqüência central igual a 3*x* rotação.	Horizontal	Velocidade
pico_10%_1xrot_VV	Amplitude máxima da banda estreita centrada em 1*x* rotação, com largura igual a 10% da freqüência central.	Vertical	Velocidade
pico_10%_2xrot_VV	Idem acima com freqüência central igual a 2*x* rotação.	Vertical	Velocidade
pico_10%_3xrot_VV	Idem acima com freqüência central igual a 3*x* rotação.	Vertical	Velocidade
pico_10%_1xrot_XV	Amplitude máxima da banda estreita centrada em 1*x* rotação, com largura igual a 10% da freqüência central.	Axial	Velocidade
pico_10%_2xrot_XV	Idem acima com freqüência central igual a 2*x* rotação.	Axial	Velocidade
pico_10%_3xrot_XV	Idem acima com freqüência central igual a 3*x* rotação.	Axial	Velocidade
ruido_0x_1x_rot_HV	Energia do ruído da banda de freqüência entre 0 e 1*x* rotação.	Horizontal	Velocidade
ruido_0x_1x_rot_VV	Idem acima.	Vertical	Velocidade
ruido_5x_65x_rot_HV	Energia do ruído da banda de freqüência entre 5*x* e 65*x* rotação.	Horizontal	Velocidade
pico_10%_bpf_HV	Amplitude máxima da banda estreita centrada na BPF, com largura igual a 10% da freqüência central.	Horizontal	Velocidade
pico_10%_bpf_VV	Idem acima.	Vertical	Velocidade
rms_total_HV	*RMS* do sinal completo.	Horizontal	Velocidade
rms_total_VV	*RMS* do sinal completo.	Vertical	Velocidade
rms_total_XV	*RMS* do sinal completo.	Axial	Velocidade
rms_total_HA	*RMS* do sinal completo.	Horizontal	Aceleração
pico_10%_bpfi_HE	Amplitude máxima da banda estreita centrada na $BPFI$, com largura igual a 10% da freqüência central.	Horizontal	Envelope de Aceleração
pico_10%_bpfo_HE	Idem acima com freqüência central $BPFO$.	Horizontal	Envelope de Aceleração
pico_10%_2xbsf_HE	Idem acima com freqüência central $2xBSF$.	Horizontal	Envelope de Aceleração
pico_10%_ftf_HE	Idem acima com freqüência central FTF.	Horizontal	Envelope de Aceleração

Tabela 4.2: Distribuições de classes obtidas nas bases finais dos experimentos

Defeito	N^o **exemplos positivos**	N^o **exemplos negativos**	**Total**
Desbalanceamento	172 (21.69%)	621 (78.31%)	793
Desalinhamento	256 (61.10%)	163 (38.90%)	419
Rolamento	161 (20.30%)	632 (79.70%)	793
Hidrodinâmico	242 (54.38%)	203 (45.62%)	445

Tabela 4.3: Resultados da avaliação experimental - ROC AUC

	Seleção Manual		**Seleção Automática**	
Defeito	Média	Desvio Padrão	Média	Desvio Padrão
Desbalanceamento	0,9127519	0,059227	0,940268	0,034491
Desalinhamento	0,870261	0,072354	0,857511	0,085623
Rolamento	0,780307	0,092687	0,886223	0,074044
Hidrodinâmico	0,632900	0,148588	0,720136	0,086618

Tabela 4.4: Resultados da avaliação experimental - Taxa de Acerto

	Seleção Manual		**Seleção Automática**	
Defeito	Média	Desvio Padrão	Média	Desvio Padrão
Desbalanceamento	0,881429	0,060672	0,901451	0,050055
Desalinhamento	0,757610	0,073991	0,807512	0,090302
Rolamento	0,820901	0,044262	0,854940	0,052539
Hidrodinâmico	0,547588	0,112507	0,664379	0,079283

5 *Conclusões e Trabalhos Futuros*

Este trabalho apresentou um estudo experimental de uma metodologia proposta para reconhecimento automático de padrões de defeitos em motobombas. Dentre as técnicas utilizadas em cada etapa do processo de reconhecimento, optou-se por avaliar a utilização de um método automático de seleção de características.

A configuração experimental realizada abordou testes com conjuntos de características manualmente e automaticamente selecionados, para quatro classes de defeitos: desbalanceamento, desalinhamento, defeitos em rolamento e defeitos hidrodinâmicos. Os conjuntos de características utilizados incluíram principalmente medidas de amplitude derivadas do sinal de vibração no domínio da freqüência, na tentativa de reproduzir os padrões encontrados nas assinaturas típicas dos defeitos.

Os resultados obtidos nos experimentos com o conjunto automático de características foram, em geral, melhores do que os resultados obtidos com o conjunto manual, fornecendo uma indicação de que o método automático de seleção pode auxiliar na identificação de atributos descritivos relevantes.

Os valores de ROC AUC resultantes indicaram que, na maioria dos experimentos, não houve aleatoriedade nas classificações. No entanto, isso ocorreu para o experimento de defeitos hidrodinâmicos, que apresentou os piores resultados. Esse fato nos permite conjecturar que a variável de vibração pode não ser adequada na identificação desse tipo de defeito.

Foi possível concluir, ainda, a partir dos resultados, que a análise do especialista é mais precisa do que o processo automático de diagnóstico proposto. Porém, isso não elimina o seu valor, devido ao ganho em relação à capacidade de processamento. Na prática, o processo automático pode ser utilizado, não para substituir o trabalho do especialista, mas para oferecer suporte a ele.

As técnicas apresentadas na estratégia proposta permitiram uma avaliação inicial do desempenho atingível pelo diagnóstico automático de defeitos em motobombas. Entretanto, existe um conjunto amplo de técnicas que podem ser exploradas, em cada etapa do processo de reconhe-

cimento de padrões.

Outros experimentos devem ser realizados para avaliar o desempenho do reconhecimento de padrões das classes de defeitos descritas que não foram abordadas neste trabalho. As características descritivas dos padrões de defeitos podem ser obtidas a partir de diferentes tipos de variáveis. Medidas de pressão e temperatura, por exemplo, poderiam ser utilizadas para descrever defeitos hidrodinâmicos (BEEBE, 2004), e medidas de corrente elétrica e voltagem, para descrever defeitos elétricos (TAVNER et al., 2008).

Na fase de extração de características outras técnicas de processamento de sinal podem ser empregadas. Outros tipos de medidas podem ser derivadas a partir do espectro de freqüência. Em Kazzaz & Singh (2003), por exemplo, pode ser encontrada um tipo de medida derivada denominada *máscara do espectro*, que realiza uma transformação no espectro para eliminar os efeitos de pequenos deslocamentos das freqüências encontradas em relação às freqüências teóricas. Existe também a possibilidade de explorar padrões de sinais em outros domínios, utilizando, por exemplo, a transformada Wavelet (YPMA et al., 1997).

Outros métodos podem ser também explorados para definição automática do conjunto de características e na fase de classificação. Técnicas de redução de dimensionalidade podem ser analisadas como alternativa para a utilização de técnicas de seleção. Uma técnica de redução comumente utilizada é a Análise de Componentes Principais (THEODORIDIS; KOUTROUMBAS, 2003). Para o aprendizado automático de padrões, algoritmos mais robustos estão disponíveis, por exemplo, redes neurais e máquinas de vetores de suporte (THEODORIDIS; KOUTROUMBAS, 2003).

Por fim, uma extensão natural do presente trabalho seria a avaliação de métodos de combinação das classificações resultantes do aprendizado de cada tipo de defeito em uma classificação multi-rótulo única. Uma descrição de métodos de classificação multi-rótulo pode ser encontrada em Tsoumakas & Katakis (2007).

Referências Bibliográficas

ALMEIDA, M. T. Análise de Vibrações I - Medidas e Diagnósticos. Treinamento MTA engenharia. 2008.

AMERICAN PETROLEUM INSTITUTE. *API Standard 610*: Centrifugal pumps for petroleum, petrochemical and natural gas industry. 9. ed. Washington, DC, 2003.

BEEBE, R. *Predictive Maintenance of Pumps using Condition Monitoring*. Oxford: Elsevier Science, 2004. ISBN 9781856174084.

BRACEWELL, R. N. *The Fourier Transform and Its Applications*. 2nd. ed. [S.l.]: McGraw-Hill, 1986.

BRADLEY, A. P. The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, v. 30, n. 7, p. 1145–1159, 1997.

BREIMAN, L. et al. *Classification and Regression Trees*. New York: Chapman & Hall, 1984. ISBN 0412048418.

CIZEK, V. Discrete Hilbert Transform. *IEEE Transactions on Audio and Electroacustics*, AU-18, n. 4, p. 340–343, 1970.

COVER, T.; HART, P. E. Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*, v. 13, n. 1, p. 21–27, 1967.

DEVIJVER, P. A.; KITTLER, J. *Pattern Recognition: A Statistical Approach*. London: Prentice Hall, 1982.

DIETTERICH, T. G. Machine-Learning Research: Four Current Directions. *The AI Magazine*, v. 18, n. 4, p. 97–136, 1998.

DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*. 2. ed. New York: John Wiley and Sons, 2001.

FAWCETT, T. An introduction to ROC analysis. *Patter Recognition Letters*, v. 27, n. 8, p. 861–874, 2006.

GIRDHAR, P. *Practical Machinery Vibration Analysis and Predictive Maintenance*. Oxford: Newnes, 2004.

GÜLICH, J. F. *Centrifugal Pumps*. Berlin: Springer, 2007.

JIANG, L.; ZHANG, H.; SU, J. Learning k-nearest neighbor naive bayes for ranking. *Lecture Notes in Computer Science*, Springer, v. 3584, p. 175, 2005.

JOHNSON, C. D. Mechanical Sensors. In: ____. *Process Control Instrumentation Technology*. 5. ed. New Jersey: Prentice Hall, 1997. cap. 5.

KAZZAZ, S. A. S.; SINGH, G. K. Experimental investigations on induction machine condition monitoring and fault diagnosis using digital signal processing techniques. *Electric Power Systems Research*, Elsevier, v. 65, n. 3, p. 197–221, 2003.

LI, B. et al. Neural-Network-Based Motor Rolling Bearing Fault Diagnosis . *IEEE Transactions on Industrial Electronics*, v. 47, n. 5, 2000.

LIU, H.; YU, L. *Feature Selection for Data Mining*: Research technical report. Arizona State University, 2002.

LMS INTERNATIONAL. *The LMS Theory and Background Book*. Leuven, Belgium, 2000.

MARTINELLI, F. C.; SANTIN, M. A. *Desenvolvimento de um Dispositivo de Medição de Diâmetro Interno de Carcaças de Motores Elétricos*. Florianópolis, 2006. Trabalho apresentado à ABCM para participação no Prêmio ABCM-Yehan Numata.

MCINERNY, S. A.; DAI, Y. Basic Vibration Signal Processing for Bearing Fault Detection. *IEEE Transactions on Education*, v. 46, n. 1, 2003.

MENDEL, E. et al. Automatic Bearing Fault Pattern Recognition using Vibration Signal Analysis. In: IEEE INTERNATIONAL SYMPOSIUM ON INDUSTRIAL ELECTRONICS ISIE, 2008, Cambridge, U.K. *Proc. of IEEE International Symposium on Industrial Electronics ISIE*. [S.l.], 2008.

MOBLEY, R. K. *Vibration Fundamentals*. Woburn: Butterworth-Heinemann, 1999.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre Aprendizado de Máquina. In: ____. *Sistemas inteligentes: fundamentos e aplicações*. 1. ed. Barueri-SP: Manole, 2003. v. 1, cap. 4, p. 89–114.

PEREIRA, L. A. *Introdução à Máquina de Indução*. Porto Alegre, 2004. Apostila da disciplina de eletrotécnica oferecida pelo Departamento de Engenharia Elétrica da PUCRS.

PRATI, R.; BATISTA, G.; MONARD, M. Curvas ROC para avaliação de classificadores. *Revista IEEE América Latina*, v. 6, n. 2, p. 215–222, 2008.

RANDALL, R. B. State of the Art in Monitoring Rotating Machinery - Part 1. *Sound and Vibration*, v. 38, p. 10–17, 2004.

RILEY, C. M. et al. Stator Current Harmonics and Their Causal Vibrations: A Preliminary Investigation of Sensorless Vibration Monitoring Applications. *Industry Applications, IEEE Transactions on*, v. 35, n. 1, p. 94–99, 1999.

SALZBERG, S. On Comparing Classifiers: Pitfalls to Avoid and a Recommended Approach. *Data Mining and Knowledge Discovery*, Kluwer Academic Publishers, Boston, v. 1, p. 317–327, 1997.

SANTIAGO, D.; PEDERIVA, R. Comparison of optimization techniques of neural networks training for faults diagnostic of rotating machinery. *Mecânica Computacional*, XXI, p. 1912–1921, 2002.

SULZER PUMPS. *Photo Gallery*. 2008. Disponível em: <http://www.sulzerpumps.com/DesktopDefault.aspx/tabid-640/>. Acesso em: 21 de maio de 2008.

TAVNER, P. et al. *Condition Monitoring of Rotating Electrical Machines*. 2. ed. Stevenage: IET Power and Energy, 2008. ISBN 9780863417412.

TECHNICAL ASSOCIATES OF CHARLOTTE, PC. Illustrated Vibration Diagnostic Chart. 1997.

THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recongnition*. 2. ed. San Diego: Academic Press, 2003.

TSOUMAKAS, G.; KATAKIS, I. Multi-Label Classification: An Overview. *International Journal of Data Warehousing and Mining*, v. 2007, p. 1–13, 2007.

WETTSCHERECK, D. *A study of distance-based machine learning algorithms*. Tese (Doutorado) — Oregon State University, 1994.

YPMA, A. et al. Recognition of bearing failures using wavelets and neural networks. In: TFTS, 1997, University of Warwick, Coventry (UK). *Proc. of TFTS*. [S.l.], 1997. p. 69–72.

ZHANG, S.; GANESAN, R.; XISTRIS, G. D. Self-organising neural networks for automated machinery monitoring systems. *Mechanical Systems and Signal Processing*, Elsevier, v. 10, n. 5, p. 517–532, 1996.

APÊNDICE A – Conjunto automático de características

Este apêndice apresenta o conjunto completo de características utilizado como entrada para o procedimento automático de seleção (Tabelas A.1, A.2, A.3 e A.4).

Tabela A.1: Conjunto automático de características

Nome abreviado	**Descrição**	**Direção**	**Unidade**
pico_10%_0.5xrot_HV	Amplitude máxima da banda estreita centrada em 0.5*x* rotação, com largura igual a 10% da freqüência central.	Horizontal	Velocidade
pico_10%_1xrot_HV	Idem acima com freqüência central igual a 1*x* rotação.	Horizontal	Velocidade
pico_10%_1.5xrot_HV	Idem acima com freqüência central igual a 1.5*x* rotação.	Horizontal	Velocidade
pico_10%_2xrot_HV	Idem acima com freqüência central igual a 2*x* rotação.	Horizontal	Velocidade
pico_10%_2.5xrot_HV	Idem acima com freqüência central igual a 2.5*x* rotação.	Horizontal	Velocidade
pico_10%_3xrot_HV	Idem acima com freqüência central igual a 3*x* rotação.	Horizontal	Velocidade
pico_10%_3.5xrot_HV	Idem acima com freqüência central igual a 3.5*x* rotação.	Horizontal	Velocidade
pico_10%_4xrot_HV	Idem acima com freqüência central igual a 4*x* rotação.	Horizontal	Velocidade
pico_10%_4.5xrot_HV	Idem acima com freqüência central igual a 4.5*x* rotação.	Horizontal	Velocidade
pico_10%_5xrot_HV	Idem acima com freqüência central igual a 5*x* rotação.	Horizontal	Velocidade
pico_10%_5.5xrot_HV	Idem acima com freqüência central igual a 5.5*x* rotação.	Horizontal	Velocidade
pico_10%_0.5xrot_VV	Amplitude máxima da banda estreita centrada em 0.5*x* rotação, com largura igual a 10% da freqüência central.	Vertical	Velocidade
pico_10%_1xrot_VV	Idem acima com freqüência central igual a 1*x* rotação.	Vertical	Velocidade
pico_10%_1.5xrot_VV	Idem acima com freqüência central igual a 1.5*x* rotação.	Vertical	Velocidade
pico_10%_2xrot_VV	Idem acima com freqüência central igual a 2*x* rotação.	Vertical	Velocidade
pico_10%_2.5xrot_VV	Idem acima com freqüência central igual a 2.5*x* rotação.	Vertical	Velocidade
pico_10%_3xrot_VV	Idem acima com freqüência central igual a 3*x* rotação.	Vertical	Velocidade
pico_10%_3.5xrot_VV	Idem acima com freqüência central igual a 3.5*x* rotação.	Vertical	Velocidade
pico_10%_4xrot_VV	Idem acima com freqüência central igual a 4*x* rotação.	Vertical	Velocidade
pico_10%_4.5xrot_VV	Idem acima com freqüência central igual a 4.5*x* rotação.	Vertical	Velocidade
pico_10%_5xrot_VV	Idem acima com freqüência central igual a 5*x* rotação.	Vertical	Velocidade

Tabela A.2: Conjunto automático de características - continuação

Nome abreviado	**Descrição**	**Direção**	**Unidade**
pico_10%_5.5xrot_VV	Idem acima com freqüência central igual a 5.5*x* rotação.	Vertical	Velocidade
pico_10%_0.5xrot_XV	Amplitude máxima da banda estreita centrada em 0.5*x* rotação, com largura igual a 10% da freqüência central.	Axial	Velocidade
pico_10%_1xrot_XV	Idem acima com freqüência central igual a 1*x* rotação.	Axial	Velocidade
pico_10%_1.5xrot_XV	Idem acima com freqüência central igual a 1.5*x* rotação.	Axial	Velocidade
pico_10%_2xrot_XV	Idem acima com freqüência central igual a 2*x* rotação.	Axial	Velocidade
pico_10%_2.5xrot_XV	Idem acima com freqüência central igual a 2.5*x* rotação.	Axial	Velocidade
pico_10%_3xrot_XV	Idem acima com freqüência central igual a 3*x* rotação.	Axial	Velocidade
pico_10%_3.5xrot_XV	Idem acima com freqüência central igual a 3.5*x* rotação.	Axial	Velocidade
pico_10%_4xrot_XV	Idem acima com freqüência central igual a 4*x* rotação.	Axial	Velocidade
pico_10%_4.5xrot_XV	Idem acima com freqüência central igual a 4.5*x* rotação.	Axial	Velocidade
pico_10%_5xrot_XV	Idem acima com freqüência central igual a 5*x* rotação.	Axial	Velocidade
pico_10%_5.5xrot_XV	Idem acima com freqüência central igual a 5.5*x* rotação.	Axial	Velocidade
rms_0.2x_0.8x_HV	*RMS* da banda de freqüências entre 0.2*x* e 0.8*x* rotação.	Horizontal	Velocidade
rms_0.2x_0.8x_VV	Idem acima	Vertical	Velocidade
rms_0.2x_0.8x_XV	Idem acima	Axial	Velocidade
rms_1.2x_1.8x_HV	*RMS* da banda de freqüências entre 1.2*x* e 1.8*x* rotação.	Horizontal	Velocidade
rms_1.2x_1.8x_VV	Idem acima	Vertical	Velocidade
rms_1.2x_1.8x_XV	Idem acima	Axial	Velocidade
rms_2.2x_2.8x_HV	*RMS* da banda de freqüências entre 2.2*x* e 2.8*x* rotação.	Horizontal	Velocidade
rms_2.2x_2.8x_VV	Idem acima	Vertical	Velocidade
rms_2.2x_2.8x_XV	Idem acima	Axial	Velocidade
rms_3.2x_3.8x_HV	*RMS* da banda de freqüências entre 3.2*x* e 3.8*x* rotação.	Horizontal	Velocidade
rms_3.2x_3.8x_VV	Idem acima	Vertical	Velocidade
rms_3.2x_3.8x_XV	Idem acima	Axial	Velocidade

Tabela A.3: Conjunto automático de características - continuação

Nome abreviado	**Descrição**	**Direção**	**Unidade**
rms_4.2x_4.8x_HV	*RMS* da banda de freqüências entre 4.2*x* e 4.8*x* rotação.	Horizontal	Velocidade
rms_4.2x_4.8x_VV	Idem acima	Vertical	Velocidade
rms_4.2x_4.8x_XV	Idem acima	Axial	Velocidade
rms_5.2x_5.8x_HV	*RMS* da banda de freqüências entre 5.2*x* e 5.8*x* rotação.	Horizontal	Velocidade
rms_5.2x_5.8x_VV	Idem acima	Vertical	Velocidade
rms_5.2x_5.8x_XV	Idem acima	Axial	Velocidade
ruido_0x_1x_rot_HV	Energia do ruído da banda de frequência entre 0 e 1*x* rotação.	Horizontal	Velocidade
ruido_0x_1x_rot_VV	Idem acima.	Vertical	Velocidade
ruido_0x_2x_rot_HV	Energia do ruído da banda de frequência entre 0 e 2*x* rotação.	Horizontal	Velocidade
ruido_0x_2x_rot_VV	Idem acima.	Vertical	Velocidade
ruido_0x_3x_rot_HV	Energia do ruído da banda de frequência entre 0 e 3*x* rotação.	Horizontal	Velocidade
ruido_0x_3x_rot_VV	Idem acima.	Vertical	Velocidade
ruido_5x_65x_rot_HV	Energia do ruído da banda de frequência entre 5*x* e 65*x* rotação.	Horizontal	Velocidade
pico_10%_bpf_HV	Amplitude máxima da banda estreita centrada na BPF, com largura igual a 10% da freqüência central.	Horizontal	Velocidade
pico_10%_bpf_VV	Idem acima.	Vertical	Velocidade
pico_10%_2xbpf_HV	Amplitude máxima da banda estreita centrada na $2xBPF$, com largura igual a 10% da freqüência central.	Horizontal	Velocidade
pico_10%_2xbpf_VV	Idem acima.	Vertical	Velocidade
rms_total_HV	*RMS* do sinal completo.	Horizontal	Velocidade
rms_total_VV	*RMS* do sinal completo.	Vertical	Velocidade
rms_total_XV	*RMS* do sinal completo.	Axial	Velocidade
rms_total_HA	*RMS* do sinal completo.	Horizontal	Aceleração
pico_10%_bpfi_HE	Amplitude máxima da banda estreita centrada na $BPFI$, com largura igual a 10% da freqüência central.	Horizontal	Envelope de Aceleração
pico_10%_bpfo_HE	Idem acima com freqüência central $BPFO$.	Horizontal	Envelope de Aceleração
pico_10%_bsf_HE	Idem acima com freqüência central BSF.	Horizontal	Envelope de Aceleração
pico_10%_ftf_HE	Idem acima com freqüência central FTF.	Horizontal	Envelope de Aceleração

Tabela A.4: Conjunto automático de características - continuação

Nome abreviado	**Descrição**	**Direção**	**Unidade**
pico_10%_2xbpfi_HE	Amplitude máxima da banda estreita centrada em $2xBPFI$, com largura igual a 10% da freqüência central.	Horizontal	Envelope de Aceleração
pico_10%_2xbpfo_HE	Idem acima com freqüência central $2xBPFO$.	Horizontal	Envelope de Aceleração
pico_10%_2xbsf_HE	Idem acima com freqüência central $2xBSF$.	Horizontal	Envelope de Aceleração
pico_10%_2xftf_HE	Idem acima com freqüência central $2xFTF$.	Horizontal	Envelope de Aceleração
pico_10%_3xbpfi_HE	Amplitude máxima da banda estreita centrada em $3xBPFI$, com largura igual a 10% da freqüência central.	Horizontal	Envelope de Aceleração
pico_10%_3xbpfo_HE	Idem acima com freqüência central $3xBPFO$.	Horizontal	Envelope de Aceleração
pico_10%_3xbsf_HE	Idem acima com freqüência central $3xBSF$.	Horizontal	Envelope de Aceleração
pico_10%_3xftf_HE	Idem acima com freqüência central $3xFTF$.	Horizontal	Envelope de Aceleração
soma_1a5xrot_HV	Soma das harmônicas $1x$,$2x$,$3x$,$4x$ e $5x$ rotação (considerando para cada harmônica o valor de pico de uma banda estreita de largura igual a 10% da freqüência central).	Horizontal	Velocidade
soma_1a5xrot_VV	Idem acima.	Vertical	Velocidade
soma_1a5xrot_XV	Idem acima.	Axial	Velocidade
soma_0.5a5.5xrot_HV	Soma das interharmônicas 0.5,$1.5x$,$2.5x$,$3.5x$,$4.5x$ e $5.5x$ rotação (considerando para cada interharmônica o valor de pico de uma banda estreita de largura igual a 10% da freqüência central).	Horizontal	Velocidade
soma_0.5a5.5xrot_VV	Idem acima.	Vertical	Velocidade
soma_0.5a5.5xrot_XV	Idem acima.	Axial	Velocidade