



Universidade Federal
do Rio de Janeiro

Escola Politécnica

CLASSIFICAÇÃO AUTOMÁTICA DE DEFEITOS EM MÁQUINAS ROTATIVAS

Rafael Zambrano López

Projeto de Graduação apresentado ao Curso de Engenharia Eletrônica e de Computação da Escola Politécnica, Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Engenheiro.

Orientadores:

Sergio Lima Netto

Amaro Azevedo de Lima

Rio de Janeiro
Dezembro de 2014

CLASSIFICAÇÃO AUTOMÁTICA DE DEFEITOS EM
MÁQUINAS ROTATIVAS

Rafael Zambrano López

PROJETO DE GRADUAÇÃO SUBMETIDO AO CORPO DOCENTE DO CURSO DE ENGENHARIA ELETRÔNICA E DE COMPUTAÇÃO DA ESCOLA POLITÉCNICA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE ENGENHEIRO ELETRÔNICO E DE COMPUTAÇÃO

Autor:

Rafael Zambrano López

Orientador:

Prof. Sergio Lima Netto, Ph. D.

Orientador:

Prof. Amaro Azevedo de Lima, Ph. D.

Examinador:

Prof. Eduardo Antônio Barros da Silva, Ph. D.

Examinador:

Prof. Thiago de Moura Prego, D. Sc.

Rio de Janeiro
Dezembro de 2014

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

Escola Politécnica - Departamento de Eletrônica e de Computação

Centro de Tecnologia, bloco H, sala H-217, Cidade Universitária

Rio de Janeiro - RJ CEP 21949-900

Este exemplar é de propriedade da Universidade Federal do Rio de Janeiro, que poderá incluí-lo em base de dados, armazenar em computador, microfilmear ou adotar qualquer forma de arquivamento.

É permitida a menção, reprodução parcial ou integral e a transmissão entre bibliotecas deste trabalho, sem modificação de seu texto, em qualquer meio que esteja ou venha a ser fixado, para pesquisa acadêmica, comentários e citações, desde que sem finalidade comercial e que seja feita a referência bibliográfica completa.

Os conceitos expressos neste trabalho são de responsabilidade do autor.

DEDICATÓRIA

À Clarice.

AGRADECIMENTOS

Primeiramente, ao professor Sergio Lima Netto, pela orientação e oferecimento deste projeto, por ter me ajudado no processo de intercâmbio acadêmico e pelos sábios conselhos, que me fazem melhorar como estudante e engenheiro.

Ao professor Amaro A. Lima, pela coorientação do projeto e pelos seus trabalhos anteriores nesta área, que serviram de base para a elaboração deste trabalho.

A minha família, pela compreensão, carinho e ajuda constante.

À Clarice, pela ajuda, amor e paciência na elaboração deste projeto, e a sua família pela acolhida e carinho.

Ao meu amigo Luiz Tavares, pela sua ajuda altruísta com tantas e tantas dúvidas ao longo dos últimos anos.

Aos meus amigos da Universidade Politécnica de Madrid: Borja, Alberto, Luis, Rosan e Felipe, por todos estes anos de feliz sofrimento.

Ao professor Thiago Prego, assim como meus colegas Vitor e Denys, fundamentais na execução da parte prática deste trabalho.

Ao Ulisses A. Monteiro e o equipe do LEDAV, pela disposição, paciência e ajuda durante o processo de gravação.

Ao meu amigo Iker, por seu apoio e sabedoria compartilhada (em espanhol).

À Elena Vallejo e Marina Souza, pela ajuda nos desenhos.

À banca examinadora, pelo convite aceito para avaliação deste trabalho.

RESUMO

Atualmente, devido a uma economia de mercado globalizada, as necessidades de redução dos custos de produção nas indústrias e o aumento da competitividade tornam o processo produtivo cada vez mais importante. Dessa forma, a importância do setor de manutenção das máquinas industriais cresce de forma progressiva, o que favorece o surgimento de técnicas cada vez mais eficientes, principalmente técnicas preditivas, que utilizam sistemas de monitoração contínua dos equipamentos.

Em relação as máquinas rotativas, é possível desenvolver uma série de metodologias de diagnóstico de defeitos, uma vez que as falhas mais comuns são: desbalanceamento de massa, desalinhamento de eixos e falhas em mancais rolamentos. A análise de vibração é um dos métodos mais eficientes na identificação desses defeitos. Quando é realizada no domínio da frequência, há a possibilidade de localizar o componente da máquina que pode estar apresentando a falha.

Nesse contexto, este trabalho tem como objetivo desenvolver um sistema de auxílio à monitoração e diagnóstico das máquinas rotativas, baseado na classificação automática de defeitos através da análise de vibrações.

Foram medidos sinais de vibração em uma máquina rotativa experimental, alterando as condições de funcionamento da máquina para induzir os defeitos de desbalanceamento, desalinhamento e falhas em mancais. Técnicas de processamento de sinais foram adotadas para obter as características descritivas a partir dos sinais de vibração. Tais características foram utilizadas como parâmetros de entrada para diversos algoritmos de classificação, a fim de identificar as classes de falha.

Os algoritmos de classificação utilizados foram Regressão Logística, Máquinas de Vetores de Suporte (SVM), Redes Neurais Artificiais (RNAs) e *Random Forest*. Este último alcançou os resultados mais satisfatórios, chegando a classificar a totalidade das falhas. Os outros algoritmos atingiram taxas de acerto superiores a 90%.

Palavras-Chave: máquinas rotativas, manutenção preditiva, análise de vibrações, classificação automática.

ABSTRACT

Nowadays due to the globalized market economy, a need in the industry for production costs reduction, and an increasing competitiveness, the production process is considered as one of the more important inside a company. Thus, the importance in the sector of the industrial machinery maintenance is continuously growing, which leads to the arousal of more efficient maintenance techniques, mainly predictive techniques that use continuous equipment-monitoring systems.

Focusing on the rotary machinery, it is possible to develop a series of defect diagnosis methodologies, taking into account that the most common defects are: mass unbalance, axes misalignment and bearing failures. The vibration analysis is one of the most efficient ways of detecting these defects. When it is used, it is possible to locate the component of the machinery that might be malfunctioning.

In this context, this work has as the main objective to develop monitoring and diagnosis system for the rotary machinery, based on the automatic classification of defects through vibration analysis.

An experimental rotary machine was used for measuring vibration signals while changing the different functioning conditions of the machine, introducing the unbalance, misalignment and rolling element bearing failures. Signal processing techniques were adopted in order to obtain the different descriptive and qualitative characteristics of the vibration signals, and those characteristics were used as input parameters in different classification algorithms, in order to identify the type of failure inside the rotating machine.

Four classification algorithms were used: Logistic Regression, Support Vector Machines (SVM), Artificial Neural Networks (ANNs) and Random Forest. The latter reached the most satisfactory results, coming to classify all the failures. The other algorithms achieved performance rates above 90 %.

Key-words: rotating machines, predictive maintenance, vibration analysis, automatic classification.

SIGLAS

ABVT - *Alignment/Balance Vibration Trainer*

BD - Diâmetro do elemento rolante

BSF - Frequência do elemento rolante

BPFI - Frequência da pista interna do rolamento

BPFO - Frequência da pista externa do rolamento

CPM - Ciclos por minuto

CV - Cavalo-vapor

DC - Corrente contínua

FFT - Transformada Rápida de Fourier

FTF - Frequência da gaiola

HRTF - Detecção de Envelope do Sinal de Ressonância de Alta Frequência

ISO - Organização Internacional para Padronização

LEDAV - Laboratório de Ensaios Dinâmicos e Análise de Vibrações

MLP - Perceptron multi-camada

NI - *National Instruments*

PD - Diâmetro primitivo do rolamento

RMS - Valor quadrático médio

RNA - Rede Neural Artificial

RPM - Rotações por minuto

STFT - Transformada de Fourier de Curto Tempo

SVM - Máquinas de Vetores de Suporte

WVD - Distribuição de Wigner-Ville

Sumário

1	Introdução	1
1.1	Tema	1
1.2	Delimitação	1
1.3	Justificativa	2
1.4	Objetivos	2
1.4.1	Objetivo geral	2
1.4.2	Objetivos específicos	2
1.5	Metodologia	3
1.6	Estrutura do trabalho	3
2	Defeitos em máquinas rotativas	5
2.1	Máquinas elétricas rotativas	5
2.1.1	Acoplamentos	6
2.1.2	Mancais	7
2.1.2.1	Mancais de deslizamento	7
2.1.2.2	Mancais de rolamento	8
2.2	Manutenção preditiva	9
2.3	Vibrações e acelerômetros	12
2.3.1	O que é vibração?	12
2.3.2	Acelerômetro piezoelétrico	12
2.4	Defeitos mecânicos mais comuns em máquinas rotativas	14
2.4.1	Desbalanceamento de rotores	15
2.4.1.1	Características do desbalanceamento de rotores	15
2.4.1.2	Tipos de desbalanceamento de rotores	17
2.4.2	Desalinhamento de eixos	18
2.4.2.1	Tipos de desalinhamento	19
2.4.2.2	Consequências do desalinhamento	20

2.4.3	Defeitos em mancais de rolamento	20
2.5	Técnicas de análise de sinais para identificação de defeitos	21
2.5.1	Técnicas no domínio do tempo	21
2.5.2	Técnicas no domínio da frequência: Análise espectral	21
2.5.2.1	Identificação do defeito de desbalanceamento	22
2.5.2.2	Identificação do defeito de desalinhamento	23
2.5.2.3	Identificação de falhas em mancais de rolamento	24
2.5.3	Técnicas no domínio tempo-frequência	26
3	Processo de gravação	28
3.1	Descrição da bancada experimental	28
3.2	Sistema de aquisição de dados	29
3.2.1	Sensores de vibração	30
3.2.1.1	Características dos acelerômetros piezoelétricos uti- lizados	30
3.2.1.2	Posicionamento dos acelerômetros na bancada	31
3.2.2	Placas de aquisição de sinais	33
3.2.3	Tacômetro analógico	34
3.2.4	Microfone	35
3.2.5	Cabos e conectores	36
3.2.6	<i>Softwares</i> utilizados na aquisição	37
3.2.7	Conexões do sistema	38
3.3	Indução de defeitos na bancada	40
3.3.1	Desbalanceamento de massa	40
3.3.2	Desalinhamento de eixo	42
3.3.2.1	Desalinhamento paralelo horizontal	43
3.3.2.2	Desalinhamento paralelo vertical	44
3.3.3	Defeitos nos mancais de rolamento	45
3.4	Medições e análise dos sinais de vibração	47
3.4.1	Estratégias de teste para inspeções de vibração	47
3.4.2	<i>Setup</i> de medição	47
3.4.3	Estimação da frequência de rotação	48
3.4.4	Medições de sinais normais (sem defeito)	49

3.4.5	Medições de desbalanceamento	49
3.4.6	Medições de desalinhamento	52
3.4.7	Medições de mancais defeituosos	54
3.4.8	Análise dos sinais coletados	55
3.5	Resumo da base de dados	57
4	Classificação automática de defeitos	58
4.1	Reconhecimento de padrões	58
4.2	Extração das características	59
4.3	Métodos de classificação	62
4.4	Algoritmos de aprendizado supervisionado	63
4.4.1	Regressão Logística (<i>Logistic Regression</i>)	64
4.4.2	Máquinas de Vetor de Suporte (<i>Support Vector Machines</i>) - SVM	66
4.5	Redes neurais artificiais	68
4.5.1	Perceptron de múltiplas camadas	69
4.5.2	Treinamento e aprendizado das redes neurais	70
4.5.3	<i>Overfitting</i> e generalização nas RNAs	71
4.6	Classificador <i>Random Forest</i>	73
5	Análise dos resultados experimentais	76
5.1	Algoritmo de extração das características	76
5.2	Classificação mediante RNAs	78
5.2.1	Utilização das características de três sinais de vibração	79
5.2.2	Aumento dos exemplos de treinamento da classe Normal	80
5.2.3	Utilização das características de todos os sinais de vibração	83
5.3	Classificação mediante Regressão Logística	85
5.4	Classificação mediante SVM	86
5.5	Classificação mediante <i>Random Forest</i>	87
5.6	Comparação dos algoritmos utilizados	88
6	Conclusões e sugestões para trabalhos futuros	90
6.1	Conclusões	90
6.2	Sugestões para trabalhos futuros	91

Bibliografia	93
A Projeto Labview	98
B Especificações dos equipamentos	100

Lista de Figuras

2.1	Motor de indução trifásico, em corte para mostrar suas partes internas	6
2.2	Acoplamentos (a) rígido e (b) flexível	7
2.3	Estrutura de um mancal de deslizamento	8
2.4	Estrutura de um mancal de rolamento	8
2.5	Curva de tendência na manutenção preditiva	11
2.6	Princípio do acelerômetro piezoelétrico	13
2.7	Alinhamento dos eixos de vibração	14
2.8	Discrepância entre o eixo de simetria e o eixo de rotação	15
2.9	Força centrífuga no rotor	16
2.10	Excitação nos mancais devido a ação da força de desbalanceamento .	16
2.11	Rotor com desbalanceamento estático	17
2.12	Rotor com desbalanceamento acoplado	17
2.13	Rotor com desbalanceamento quase-estático	18
2.14	Rotor com desbalanceamento dinâmico	18
2.15	Sistema perfeitamente alinhado	19
2.16	Tipos de desalinhamento	19
2.17	Separação dos elementos de um mancal de rolamento	20
2.18	Comparação de espectros com e sem desbalanceamento	22
2.19	Espectro típico do desalinhamento angular e paralelo	24
2.20	Esquema da técnica HFRT	26
3.1	Componentes do simulador <i>SpectraQuest Alignment/Balance Vibration Trainer</i> (ABVT)	29
3.2	Acelerômetro industrial IMI Sensors, modelo 601A01	30
3.3	Acelerômetro triaxial IMI Sensors, modelo 604B31	31
3.4	Configurações corretas e incorretas na colocação dos acelerômetros . .	31
3.5	Esquema dos planos de medição	32

3.6	Montagem dos acelerômetros no mancal (a) interior e (b) exterior . . .	33
3.7	Placa de aquisição dos sinais. Módulo NI 9234	33
3.8	Chassi NI cDAQ 9178	34
3.9	tacômetro analógico: Monarch Instrument MT-190	34
3.10	Microfone Shure SM81 e interface Alesis iO4	35
3.11	Logotipos do (a) LabVIEW e (b) DIAdem	37
3.12	Diagrama das conexões no processo de gravação	38
3.13	Conexões dos equipamentos	39
3.14	Configurações do rotor (a) center-hung e (b) over-hung	40
3.15	Rotor com a massa desbalanceadora	41
3.16	Diferentes massas desbalanceadoras	41
3.17	Desalinhamento paralelo induzido	42
3.18	Parafusos de desalinhamento vertical e horizontal	42
3.19	Medição do desalinhamento com ajuda do paquímetro	43
3.20	Calços empregados para o desalinhamento paralelo vertical	44
3.21	Indução de desalinhamento paralelo vertical	44
3.22	Configurações de mancal defeituoso (a) invertido e (b) não invertido .	46
3.23	Desmontagem do eixo para a inserção do mancal invertido	46
3.24	Sinal do tacômetro no domínio do tempo e da frequência	48
3.25	Exemplo de estimação da frequência fundamental de rotação	49
3.26	Comparação dos sinais com e sem desbalanceamento na posição radial	51
3.27	Comparação entre as posições axial e radial no desbalanceamento . .	52
3.28	Espectro de um sinal sem e com desbalanceamento	54
3.29	Sinais defeituosos removidos da base de dados	56
4.1	Sistema de reconhecimento de padrões	62
4.2	Processo de aprendizado supervisionado	63
4.3	Função sigmóide	64
4.4	Exemplos de Regressão Logística: (a) linear; (b) polinômica	66
4.5	Hiperplano separador em SVM	67
4.6	Mapeamento de \mathbb{R}^2 a \mathbb{R}^3 mediante a função <i>kernel</i>	67
4.7	Modelo artificial do neurônio biológico	69
4.8	Perceptron de múltiplas camadas	70

4.9	Erros de treinamento e validação estáveis	72
4.10	Erro de validação não estável	73
4.11	Criação de um árvore de decisão	74
5.1	Estimação da frequência de rotação	77
5.2	Topología da RNA no primeiro experimento	79
5.3	Taxa de acerto x Neurônios da camada oculta	80
5.4	Exemplo quantitativo do ruído adicionado na ampliação dos sinais da classe Normal	82
5.5	Comparação entre um sinal (a) sem alterar e um sinal (b) com ruído branco gaussiano adicionado	82
5.6	Taxa de acerto x Neurônios da camada oculta	85
5.7	Taxa de acerto x Número de árvores de decisão utilizando <i>Random Forest</i>	87
A.1	Diagrama de bloco do módulo de aquisição e visualização de sinais . .	99

Lista de Tabelas

2.1	Tipo de desalinhamento x Características espectrais	23
3.1	Especificações mecânicas da bancada experimental	29
3.2	Cabos e conectores utilizados no processo de gravação	36
3.3	Sinais gravados para cada desbalanceamento introduzido	50
3.4	Sinais gravados para cada desalinhamento horizontal induzido	53
3.5	Sinais gravados para cada desalinhamento vertical induzido	53
3.6	Número de medições com o mancal defeituoso não invertido	54
3.7	Número de medições com o mancal defeituoso invertido	55
3.8	Desagregação dos sinais gravados	57
4.1	Condições das classes definidas	60
4.2	Conjunto de características	60
5.1	Desempenho do classificador baseado em RNA utilizando as características de 3 acelerômetros	79
5.2	Desempenho do classificador baseado em RNA ampliando os sinais normais	81
5.3	Desempenho do classificador baseado em RNA ampliando os sinais normais x8	83
5.4	Desempenho do classificador baseado em RNA utilizando os seis acelerômetros	84
5.5	Desempenho do classificador baseado em Regressão Logística	86
5.6	Desempenho do classificador baseado em SVM	86

Capítulo 1

Introdução

Neste capítulo apresenta-se a introdução, os objetivos, as delimitações, a justificativa, a relevância, o interesse e a viabilidade do tema.

1.1 Tema

Este projeto propõe um procedimento baseado na utilização de técnicas de reconhecimento de padrões, aliadas ao processamento de sinais de vibração, para detecção de defeitos em máquinas rotativas. O trabalho descreve, principalmente, dois grandes processos: o processo de gravação de sinais de vibração para a obtenção de sinais procedentes de uma máquina experimental com defeitos induzidos; e o processo de classificação automática das falhas.

Após as medições, foram utilizadas técnicas de processamento de sinais para extrair características discriminativas dos sinais de vibração, diagnosticando os padrões de defeitos por meio de diversos classificadores, os quais foram: Regressão Logística, Máquinas de Vetores de Suporte, Redes Neurais Artificiais e *Random Forest*.

1.2 Delimitação

O cenário organizacional sofreu muitas mudanças nos últimos anos. A concorrência entre as empresas é cada vez mais forte e o mercado tem exigido qualidade e agilidade nos processos. Em empresas com grandes volumes de produção e grande número de máquinas e equipamentos, é importante que a manutenção alcance as altas exigências de disponibilidade requeridas. Para atingir este objetivo, são utilizadas uma série de técnicas como a termografia, análise de vibração, etc., mostrando

a condição das máquinas e equipamentos em função dos sintomas que eles emitem no exterior, evitando assim falhas inesperadas. No entanto, muitas falhas têm um caráter aleatório, pelo qual deve-se realizar um acompanhamento e uma análise rigorosa para prever o momento da substituição ou reparação, antes da falha, para aproveitar ao máximo a vida útil do produto ou sistema.

1.3 Justificativa

A manutenção industrial é considerada função estratégica de competitividade e pode influenciar, significativamente, o lucro de empresas. É necessário, portanto, que as máquinas estejam em condições operacionais o maior tempo possível. O tempo de reparo e o custo de intervenções das máquinas podem ser reduzidos significativamente através do correto diagnóstico de falhas. Desta forma, as empresas podem adequar sua forma de atuação a fim de se manterem competitivas em seus mercados.

Os métodos propostos neste trabalho permitem uma monitoração muito eficaz de qualquer máquina sensível aos defeitos de desbalanceamento do rotor e desalinhamento do eixo, que são as falhas mais comuns em equipamentos rotativos.

1.4 Objetivos

1.4.1 Objetivo geral

Este trabalho tem o objetivo de criar uma base de dados de sinais de vibração em uma máquina rotativa experimental para, posteriormente, realizar uma classificação automática dos defeitos induzidos na máquina, através de diversos algoritmos de classificação, que serão comparados entre si.

1.4.2 Objetivos específicos

Os objetivos específicos são:

- Estudar os defeitos mecânicos mais comuns em máquinas rotativas e seus efeitos de vibração.

- Estudar as técnicas de análise de sinais utilizadas para o tratamento de dados e diagnóstico de defeitos.
- Aprender a metodologia de criação de uma base de dados de sinais de vibração (condições de teste e operação, indução de defeitos, localização dos sensores, etc).
- Estudar os algoritmos de classificação mais utilizados na atualidade para a implantação de sistemas de diagnóstico de defeitos mecânicos em máquinas rotativas.

1.5 Metodologia

A metodologia utilizada para a elaboração deste trabalho foi, primeiramente, estudar os defeitos mecânicos mais frequentes das máquinas rotativas e as técnicas de análise de sinais de vibração utilizadas para identificação destes defeitos.

Depois, foi criado um projeto no *software* Labview, gerando as rotinas para aquisição, visualização dos sinais e estimação da frequência de rotação da máquina.

A atividade seguinte correspondeu à indução de defeitos e medições na bancada experimental. Estes defeitos foram: desbalanceamento de massa, desalinhamento de eixo e defeitos nos elementos dos mancais de rolamento. Uma base de dados foi coletada e, posteriormente, processada, para extrair as características discriminativas dos sinais de vibração.

A última etapa foi a utilização de diversos classificadores e a comparação do seu desempenho no diagnóstico de defeitos.

1.6 Estrutura do trabalho

Este trabalho foi dividido em seis capítulos. O capítulo 2 apresenta os conceitos de máquinas rotativas e a identificação dos seus principais defeitos, através da análise da vibração na manutenção preditiva.

O capítulo 3 é referente ao processo de gravação. Será descrita a bancada experimental, na qual foram induzidos defeitos mecânicos e realizadas as medições de vibração, mostrando os resultados das medições e as suas respectivas apreciações.

No capítulo 4 será apresentado o processo de extração das características dos sinais de vibração, assim como um resumo dos principais algoritmos de classificação.

No capítulo 5 são mostrados os resultados obtidos na classificação mediante os diferentes algoritmos, realizando uma comparação qualitativa e quantitativa entre os mesmos.

Finalmente, o capítulo 6 apresenta as considerações finais, em que são resumidos os resultados obtidos e sugerem-se temas para futuros trabalhos nesta área.

Capítulo 2

Defeitos em máquinas rotativas

Neste capítulo serão apresentados os conceitos de máquinas rotativas e a identificação dos seus principais defeitos, através da análise da vibração na manutenção preditiva. Serão descritos os principais componentes das máquinas; o acelerômetro como sensor utilizado nas medições; as características e consequências dos defeitos de desbalanceamento do rotor, desalinhamento de eixos e falhas em mancais de rolamento; e a possibilidade da sua detecção por meio da técnica de análise no domínio da frequência.

2.1 Máquinas elétricas rotativas

As máquinas elétricas rotativas são equipamentos destinados a converter energia mecânica em energia elétrica, ou vice-versa. No primeiro caso, se denominam geradores elétricos e, no segundo, são chamados de motores elétricos.

As máquinas elétricas são projetadas e construídas de modo que realizam com a máxima eficiência o processo de conversão de energia. Elas possuem basicamente duas partes: uma fixa chamada de estator e uma móvel, montada sobre um eixo, localizada no interior do estator de forma a permitir sua rotação, conhecida como rotor. A figura 2.1 mostra as partes citadas num motor de indução trifásico.




Figura 2.1: Motor de indução trifásico, em corte para mostrar suas partes internas [1].

Nas aplicações industriais, em geral, os equipamentos rotativos são constituídos por um conjunto de duas máquinas: uma acionadora e outra acionada. Os principais acionadores são os motores elétricos e as turbinas a vapor. As máquinas acionadas mais importantes são: bombas, compressores, sopradores, ventiladores, misturadores, picadores, entre outros. Em alguns casos se utilizam redutores ou multiplicadores de velocidade entre o acionador e o acionado [2].

Além dos componentes citados anteriormente, se apresentam mais dois elementos comumente utilizados em máquinas rotativas: acoplamentos e mancais.

2.1.1 Acoplamentos

O acoplamento é responsável pela ligação entre eixos de equipamentos acionadores e acionados e tem como função principal transmitir energia. Dividem-se em duas categorias: rígidos e flexíveis.

Os acoplamentos rígidos promovem a ligação entre os eixos do equipamento acionador e acionado de modo que pode ser considerado um único eixo. Com acoplamentos flexíveis, ambos eixos continuam com liberdade de movimento, com exceção do movimento de rotação, que é sincronizado.

A figura 2.2 mostra um acoplamento rígido e um flexível.




Figura 2.2: Acoplamentos (a) rígido e (b) flexível.

2.1.2 Mancais

Os mancais têm a função de sustentação do eixo de máquinas, permitindo liberdade de rotação. De acordo com a solicitação de esforços, os mancais podem ser de deslizamento ou de rolamento.

2.1.2.1 Mancais de deslizamento

Normalmente, os mancais de deslizamento são constituídos por uma bucha fixada num suporte. Esses mancais são usados em máquinas pesadas ou em equipamentos de baixa rotação, já que a baixa velocidade evita o superaquecimento dos componentes expostos ao atrito. A utilização de buchas e de lubrificantes possibilita a redução desse atrito e melhora a rotação do eixo [3]. As buchas, compostas por materiais macios, como o bronze e ligas de metais leves, são, em geral, corpos cilíndricos ocos que envolvem os eixos, permitindo-lhes uma melhor rotação. A figura 2.3 mostra a estrutura geral de um mancal de deslizamento.





Figura 2.3: Estrutura de um mancal de deslizamento.

2.1.2.2 Mancais de rolamento

Este tipo de mancal é o mais adequado para maiores velocidades de rotação. Os rolamentos limitam, o máximo possível, as perdas de energia em consequência do atrito. Geralmente, são constituídos por dois anéis concêntricos, entre os quais são inseridos elementos rolantes como esferas, roletes e agulhas. A figura 2.4 mostra a estrutura de um mancal de rolamento.



(a)

Figura 2.4: Estrutura de um mancal de rolamento.

2.2 Manutenção preditiva

As máquinas rotativas constituem uma classe de máquinas muito utilizadas na indústria. A operação contínua e segura dessas máquinas é equivalente ao sucesso de muitas plantas industriais. Dessa forma, a busca pela operação eficiente ajuda a evitar paradas não programadas que, geralmente, implicam em conflitos produtivos e financeiros.

Nos últimos anos, transformações intensas têm ocorrido nos mercados, que vêm sendo estigmatizados por conceitos como: globalização, redução de custos e melhoria da qualidade de serviços. Atualmente, a gestão da manutenção se encontra integrada com os objetivos estratégicos da empresa, tendo a produção como enfoque principal [4].

Por definição, manutenção é “o ato ou efeito de manter” ou “o dispêndio com a conservação de alguma coisa”. Há diversas estratégias para o gerenciamento da manutenção que dependem da importância dos equipamentos na linha de produção e dos custos envolvidos, tanto na execução dos serviços de manutenção, como na substituição dos equipamentos. Para uma compreensão mais clara, a seguir estão definidos os tipos de manutenção:

- Manutenção Corretiva é a utilização do equipamento até a incapacidade de funcionamento do mesmo, podendo ocorrer através do colapso de um componente. É um tipo de manutenção completamente inadequado para máquinas cujas interrupções estão associadas a grandes prejuízos.

- Manutenção Preventiva consiste na programação de intervenções nas máquinas a partir da estimativa de um período médio de ocorrência de falhas. Este método pode resultar na substituição de componentes que ainda estejam em bom estado.

- Manutenção Preditiva parte da premissa do conhecimento sobre o estado da máquina através de medições periódicas de um ou mais parâmetros significativos. Dessa forma, se evitam paradas inesperadas e substituições de peças desnecessárias. É o tipo de manutenção que aumenta a disponibilidade da máquina.

Existem algumas divergências conceituais na definição de cada um dos tipos citados, entretanto pode-se dizer de uma maneira geral, que a manutenção preditiva é a que atualmente possui maior enfoque [5].

O objetivo da manutenção preditiva não é eliminar os níveis de manutenção preventiva ou corretiva, mas minimizá-los de forma prática, técnica e objetiva, por meio do acompanhamento e/ou monitoração de parâmetros. Isto se dá com uso de instrumentação adequada, detectando os problemas ainda numa fase incipiente, para prever qual é a vida útil remanescente e programar os reparos necessários, antes que a falha cause uma interrupção do funcionamento da máquina. Este tipo de manutenção baseia-se, de forma geral, na monitoração e diagnóstico de máquinas ou componentes através do uso de sensores, podendo medir diversas grandezas: temperatura, vibração, pressão, tensão, corrente, entre outras. Os sensores geram sinais que são traduzidos em dados, os quais, uma vez tratados de forma adequada, se tornam informações. Tais informações possibilitam a tomada de decisões coerentes pelos respectivos responsáveis, sendo assim, parte fundamental do sistema de produção.

Uma metodologia de manutenção preditiva muito utilizada no monitoramento da condição dessas máquinas é a análise vibracional das mesmas. Este fato se deve ao grande número de máquinas rotativas e aos elevados índices de retorno que este tipo de monitoração alcança [6]. Quando a análise vibracional é realizada no domínio da frequência, há a possibilidade de identificar o componente da máquina que pode estar apresentando problema. Diversas falhas fazem surgir componentes de frequências características no espectro da amplitude da vibração.

A preferência pelo uso de análises de vibrações ao longo dos estudos proporciona, hoje, um vasto histórico de padrões de funcionamento de máquinas e componentes em múltiplas condições de operação, possibilitando o estudo de problemas específicos [7].

A figura 2.5 mostra um exemplo de análise no domínio da frequência, onde é relacionada cada componente espectral com diversos elementos da máquina. O

gráfico inferior da figura, traçado com os valores das medições na manutenção, é chamado de curva de tendência. A análise das medidas periódicas permite conhecer o estado operativo da máquina, estabelecer tendências e tomar as ações necessárias quando o nível considerado como normal for ultrapassado, dentro de um tempo de aviso (*warning time*).




Figura 2.5: Curva de tendência na manutenção preditiva.

Os estudos mais detalhados mostram que a manutenção preditiva apresenta resultados tão bons que hoje é considerada uma atividade produtiva e a principal técnica para levantamentos de parâmetros na ação de manutenção nos equipamentos [4]. A aplicação sistemática de programas de monitoração de vibrações em máquinas rotativas pode resultar, em grandes plantas, um retorno de dez a cinquenta vezes o montante investido no primeiro ano de operação [5].

2.3 Vibrações e acelerômetros

A vibração normalmente ocorre devido aos efeitos dinâmicos de tolerâncias da fabricação, folgas, contatos, atrito entre peças de uma máquina. As vibrações podem excitar as frequências naturais das peças que compõem o sistema, fazendo com que sejam amplificadas podendo até danificar o conjunto estruturalmente.

Nos últimos quinze anos foi criada uma nova tecnologia na medição de vibração, permitindo avaliar máquinas que funcionam em alta velocidade e num elevado ritmo de demanda. Utilizando acelerômetros piezoelétricos, com a finalidade de converter o movimento vibratório em sinais elétricos, o processo de medição e análise é habilmente realizado graças à versatilidade de aparelhos eletrônicos [8].

2.3.1 O que é vibração?

Diz-se que um corpo vibra quando descreve um movimento oscilatório em relação a um corpo de referência. O número de ciclos do movimento em um segundo é chamado de frequência, medido em hertz (Hz). O movimento pode consistir num único componente com uma única frequência, como ocorre com o diapasão, ou em vários componentes que ocorrem em diversas frequências, como no caso de um sistema de engrenagens.

Na prática, os sinais de vibração consistem geralmente em inúmeras frequências, que ocorrem simultaneamente. De imediato, não se pode observá-las analisando as respostas de amplitude com relação ao tempo, nem determinar quantos componentes de vibração há e onde eles ocorrem. Com a utilização da técnica de análise de frequência, pode ser construído um espectrograma, ou seja, um histograma que relaciona a amplitude do sinal com a sua respectiva frequência. Quando são analisadas as vibrações de um sistema, normalmente encontram-se um grande número de frequências periódicas, as quais estão diretamente relacionadas aos movimentos das diversas peças do sistema.

2.3.2 Acelerômetro piezoelétrico

O transdutor normalmente utilizado na captação de uma vibração é o acelerômetro piezoelétrico, que possui boa linearidade e uma faixa dinâmica maior em comparação

a outros acelerômetros. Os acelerômetros piezoelétricos não possuem partes móveis e geram um sinal proporcional à aceleração, que pode ser integrado, obtendo-se a velocidade e o deslocamento do sinal [8], [9]. A essência desse tipo de acelerômetro é o material piezoelétrico, usualmente uma cerâmica ferro-elétrica polarizada artificialmente. Quando mecanicamente tensionada, proporcionalmente à força aplicada, gera uma carga elétrica que polariza suas faces.

A figura 2.6 ilustra de forma esquemática o funcionamento desse tipo de acelerômetro. Uma caixa metálica contém uma massa, também metálica, colocada sobre uma lâmina do material piezoelétrico. Esta, por sua vez, está fixada ao fundo da caixa. Se a caixa estiver em repouso, o material piezoelétrico suporta o peso da massa e sofre uma compressão que resulta em uma voltagem nos terminais vistos à direita (+ e -).

Se a caixa for acelerada para cima, a compressão do material piezoelétrico aumenta e a voltagem de saída se eleva proporcionalmente à aceleração. Se a aceleração for para baixo, como mostra a figura, a compressão do material é aliviada e a voltagem de saída é diminuída. Desse modo, obtém-se uma voltagem nos terminais que deve ser proporcional à aceleração da caixa.




Figura 2.6: Princípio do acelerômetro piezoelétrico.

Em geral, a voltagem na saída de um acelerômetro desse tipo é pequena. Mas, com a sensibilidade da eletrônica atual, essas voltagens são suficientes para resultar em medidas confiáveis da aceleração.

No monitoramento das máquinas através da análise vibracional, consideram-se três eixos de vibração: axial, radial e tangencial. Axial é a direção paralela ao eixo do rotor, radial é a direção desde o transdutor até o centro do eixo, e tangencial é a direção tangente ao eixo (90 graus em relação à radial), como é mostrado na figura 2.7.




Figura 2.7: Alinhamento dos eixos de vibração.

2.4 Defeitos mecânicos mais comuns em máquinas rotativas

Uma fonte comum de vibrações em máquinas rotativas é o desbalanceamento de massa, gerado por configurações assimétricas, falta de homogeneidade dos materiais, tolerâncias dimensionais, desvios de forma, imperfeições de matéria-prima e de montagem. Qualquer uma destas causas ou uma combinação delas acabará com a condição de perfeita distribuição de massa em torno do eixo de rotação do rotor [10].

Outra origem comum de vibrações é o desalinhamento de eixos. Dependendo da sua robustez, estes podem sofrer empenos (distorções), atritos com peças estacionárias e fraturas por fadiga quando ficam submetidos às cargas elevadas provenientes do desalinhamento. Em engrenagens, o desalinhamento pode causar ruídos por mal engrenamento e desgastes prematuros nos dentes.

Os rolamentos, que são componentes presentes na maioria dos equipamentos rotativos, apresentam um grande índice de falhas e, muitas vezes, prematuras. As causas mais comuns dos defeitos em rolamentos são: seleção incorreta; sobrecarga; defeito de fabricação; desalinhamento; montagem incorreta; estocagem inadequada; lubrificação excessiva ou insuficiente; falha de vedação e descargas elétricas através dos mancais.

Outros defeitos menos comuns nas máquinas rotativas são instabilidade, roçamento, ressonâncias, folgas mecânicas, falhas em correias de acionamento, componentes frouxos, problemas com engrenagens, problemas aerodinâmicos e problemas em equipamentos elétricos [11], [12].

2.4.1 Desbalanceamento de rotores

2.4.1.1 Características do desbalanceamento de rotores

O desbalanceamento constitui uma das fontes mais comuns nos problemas de vibração em máquinas [10]. É um defeito gerado pela distribuição irregular de massa em torno do eixo de rotação de um rotor, ou seja, o eixo principal de inércia (eixo de simetria), não coincide com o eixo de rotação, como pode ser visto na figura 2.8.




Figura 2.8: Discrepância entre o eixo de simetria e o eixo de rotação.

O excesso de massa em um lado do rotor faz com que a força centrífuga atuante sobre este lado mais pesado supere a força centrífuga atuante sobre o lado oposto, forçando, então, o lado mais leve na direção do lado mais pesado, sendo a força resultante a causadora da vibração. A magnitude desta força depende da velocidade de rotação da máquina e da excentricidade do centro de gravidade do rotor:

$$F_{cent} = m \cdot \epsilon \cdot \omega, \quad (2.1)$$

onde m é a massa desbalanceadora, ϵ é a excentricidade ou a distância do centro de gravidade da massa ao eixo de giro do rotor e ω a velocidade angular da máquina.




Figura 2.9: Força centrífuga no rotor.

Havendo um desbalanceamento no conjunto rotativo de uma máquina, seu centro de gravidade geralmente se desloca em relação ao centro geométrico do rotor, favorecendo o surgimento de forças e momentos, que serão suportados pelos mancais, induzindo vibrações mecânicas nos mesmos [13]. Esse processo é visualizado na figura 2.10, em que F é a força dada pela equação 2.1, G o centro de gravidade do sistema e a e b as distâncias dos mancais até o centro de gravidade.




Figura 2.10: Excitação nos mancais devido a ação da força de desbalanceamento.

2.4.1.2 Tipos de desbalanceamento de rotores

A norma ISO 1925 [14] classifica o desbalanceamento em função da distribuição de massas desbalanceadoras em quatro tipos de desbalanceamento.

Desbalanceamento estático

O desbalanceamento estático é a forma mais simples de desbalanceamento, sendo a condição na qual o eixo principal de inércia está posicionado paralelamente ao eixo geométrico do rotor, como mostra a figura 2.11.




Figura 2.11: Rotor com desbalanceamento estático.

Desbalanceamento acoplado

Desbalanceamento acoplado é a condição na qual o eixo principal de inércia corta o eixo de rotação no centro de gravidade. O desbalanceamento acoplado é, assim, uma condição criada por uma massa desbalanceadora em cada extremidade do rotor, em lados opostos em relação a sua linha de centro, como pode ser observado na figura 2.12.




Figura 2.12: Rotor com desbalanceamento acoplado.

Desbalanceamento quase-estático

O desbalanceamento quase-estático é uma combinação dos desbalanceamentos anteriores, onde o eixo principal de inércia intercepta o eixo de rotação em um ponto não coincidente com seu centro de gravidade. A figura 2.13 mostra um rotor com este tipo de desbalanceamento.




Figura 2.13: Rotor com desbalanceamento quase-estático.

Desbalanceamento dinâmico

O desbalanceamento dinâmico ocorre quando o eixo principal de inércia não encontra o eixo de rotação. Este tipo de desbalanceamento é o mais frequente [10], e somente pode ser determinado completamente sob rotação [13]. A figura 2.14 mostra um rotor com este tipo de desbalanceamento.




Figura 2.14: Rotor com desbalanceamento dinâmico.

2.4.2 Desalinhamento de eixos

O desalinhamento é a condição em que os eixos da máquina motriz e da máquina motora não estão localizados na mesma linha de centro. O alinhamento entre eixos

de equipamentos é muito importante para a obtenção de altos valores de tempo médio entre falhas e, conseqüentemente, baixos custos de manutenção. [2]

Considera-se que um conjunto de máquinas acionador-acionado está alinhado quando o desvio de concentricidade dos eixos, em todo o seu comprimento e com uma revolução completa, está com valores de desvio dentro dos limites de tolerância. Denomina-se um dos eixos como “acionador” e o outro como “acionado”. A figura 2.15 ilustra um sistema perfeitamente alinhado, o qual deve ser considerado nos planos horizontal e vertical.




Figura 2.15: Sistema perfeitamente alinhado.

2.4.2.1 Tipos de desalinhamento

Um desalinhamento de eixos pode ser puramente paralelo, puramente angular, ou a mistura dos dois tipos, seja no plano horizontal ou no vertical. A figura 2.16 mostra os três tipos de desalinhamento.

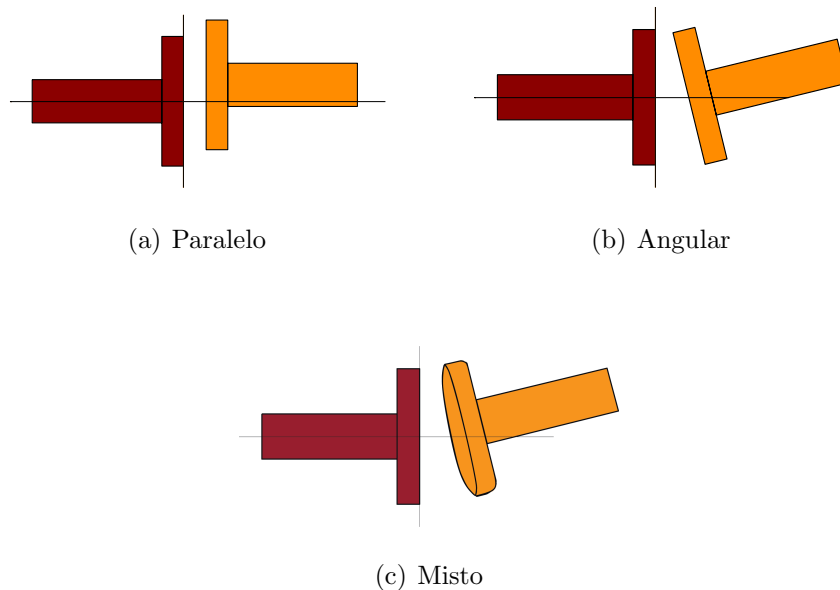


Figura 2.16: Tipos de desalinhamento.

2.4.2.2 Consequências do desalinhamento

Eixos mal alinhados são responsáveis por muitos problemas em máquinas e equipamentos. O desalinhamento provoca forças de reações nos mancais, eixos e acoplamentos, causando um aumento de consumo de energia pelo componente acionador [15] e vibrações indesejadas [2]. Pode ocorrer também um aumento de temperatura nos mancais e no acoplamento da máquina [15].

2.4.3 Defeitos em mancais de rolamento

Mancais são considerados componentes mecânicos críticos. Estudos indicam que cerca de 40% de todas as falhas em máquinas se devem a problemas nestes elementos [11], podendo levar a falhas catastróficas em muitos tipos de máquinas rotativas [16]. Os defeitos nos mancais de rolamentos podem ocorrer nos seus diferentes componentes. Geralmente, estes defeitos evoluem com certa lentidão e emitem sinais com bastante antecedência da falha final, que pode ocorrer por travamento ou ruptura dos componentes. Defeitos típicos que evoluem dessa forma são: riscos nas pistas, roletes ou esferas, trincas, corrosão, erosão e contaminação. O processo de degradação de um rolamento pode se iniciar na pista externa ou interna, num dos elementos rolantes (rolos ou esferas) ou na gaiola, alastrando-se depois para os demais componentes [10]. A figura 2.17 apresenta a separação dos elementos de um mancal de rolamento, indicando os lugares típicos dos defeitos.

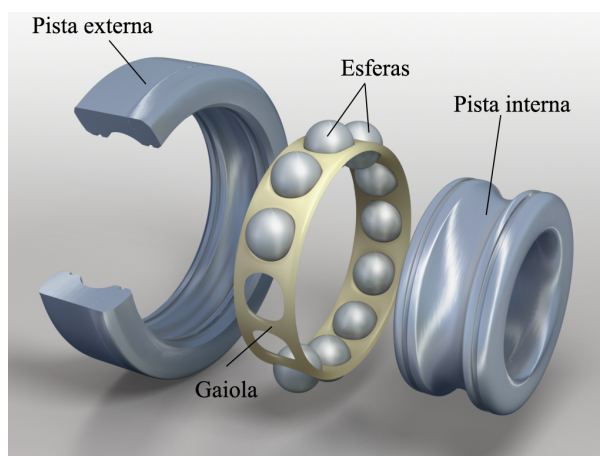


Figura 2.17: Separação dos elementos de um mancal de rolamento, indicando os lugares típicos dos defeitos [17].

2.5 Técnicas de análise de sinais para identificação de defeitos

A medição e análise de sinais de vibração possibilitam a identificação de falhas nos estágios iniciais, antes da quebra do equipamento. Diferentes técnicas de análise de sinal são utilizadas na detecção e diagnóstico de falhas, classificadas em três domínios: tempo, frequência e tempo-frequência.

2.5.1 Técnicas no domínio do tempo

São as mais antigas e simples técnicas de acompanhamento de máquinas [11], [16]. Estas técnicas indicam apenas a condição do equipamento, isto é, elas não informam o tipo de defeito ou qual componente mecânico apresenta falha. Portanto, constituem-se em um primeiro passo para o monitoramento de máquinas através da análise de vibrações. A força desta técnica está na sua simplicidade. Ela requer uma instrumentação simples, contudo uma alta demanda de pessoal técnico [11]. As principais técnicas no domínio do tempo são: nível global, fator de crista e curtose, cujos procedimentos ficam fora do alcance deste projeto.

2.5.2 Técnicas no domínio da frequência: Análise espectral

A análise espectral é uma técnica que consiste em analisar o sinal de vibração a partir do espectro de frequência. Esta técnica possui a vantagem de poder detectar a localização dos principais defeitos em máquinas rotativas. Os parâmetros fundamentais da análise espectral são a amplitude e a frequência, visto que a amplitude do sinal indica a gravidade do problema e a frequência indica o componente ou o tipo de defeito [10].

O processo da análise espectral se inicia com a aquisição do sinal de vibração por intermédio de um acelerômetro. Este sinal, no domínio do tempo, será transformado para o domínio da frequência através do procedimento da Transformada Rápida de Fourier (FFT). Já no domínio da frequência, analisa-se o sinal procurando pelos picos mais protuberantes que podem constituir um indicativo de falha de um elemento

da máquina em particular. As frequências dependentes da rotação de trabalho, chamados de harmônicos, são expressas de forma relativa e não absoluta como 1x (uma vez a rotação da máquina), 2x, 3x, etc.

A continuação, explicam-se as diferentes características espectrais dos defeitos estudados anteriormente.

2.5.2.1 Identificação do defeito de desbalanceamento

O defeito de desbalanceamento pode ser identificado através da análise espectral e caracteriza-se por ocorrer na frequência de rotação da máquina, onde se detecta uma alta amplitude. Nas direções radiais a sensibilidade é maior em relação à direção axial, devido ao fato da força centrífuga, gerada pelo desbalanceamento, ocorrer na posição radial. Se o sinal referente à posição radial apresentar maior amplitude em relação à posição axial, na frequência de rotação da máquina, o defeito é desbalanceamento. A figura 2.18 mostra dois espectros sobrepostos com a finalidade de apreciar visualmente o efeito de desbalanceamento na frequência.

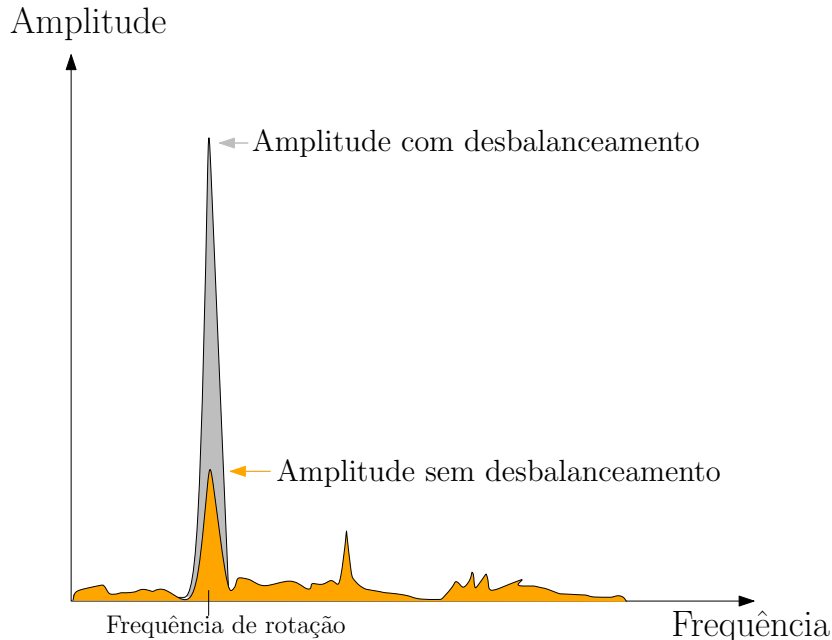


Figura 2.18: Comparação de espectros com e sem desbalanceamento.

Como a amplitude de vibração é diretamente proporcional ao grau de desbalanceamento, se dobrar o valor da massa desbalanceadora, automaticamente também

dobra a amplitude de vibração. Esse fato é importante, pois permite que a atividade de balanceamento de rotores seja possível, a partir de instrumento de vibração [4].

2.5.2.2 Identificação do defeito de desalinhamento

Segundo [2], [5], [10], o espectro de um sinal com desalinhamento, apresenta as seguintes características:

- O desalinhamento, tal qual o desbalanceamento, causa uma vibração predominante na frequência de rotação do equipamento. No entanto, se o desalinhamento for severo surgem também nas frequências $2x$ e $3x$.
- A amplitude é proporcional à quantidade de desalinhamento.
- O desalinhamento angular submete os eixos à vibração axial nas frequências $1x$, $2x$ e $3x$. O desalinhamento paralelo produz uma vibração radial nas frequências $1x$ e $2x$. E o desalinhamento misto, além da vibração predominante acontecer na direção axial em $1x$ rotação, ocorre uma vibração significativa em $2x$ rotação nesta direção. Estas características de vibração são gerais, podendo variar em função do tipo e rigidez do acoplamento entre eixos utilizado, da velocidade de rotação e características da máquina [6].

A tabela 2.1 mostra um resumo das características anteriores.

Tabela 2.1: Tipo de desalinhamento x Características espectrais.

Desalinhamento	Frequência predominante	Direção
Angular	$1x$ $2x$ $3x$ rotação	Axial
Paralelo	$1x$ $2x$ rotação	Radial
Misto	$1x$ $2x$ rotação	Axial

A figura 2.19 mostra a forma dos espectros teóricos no caso de desalinhamento angular e paralelo.

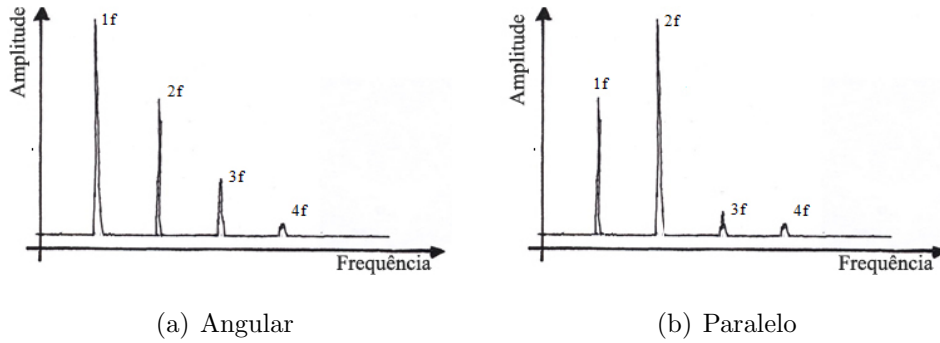


Figura 2.19: Espectro típico do desalinhamento angular e paralelo.

2.5.2.3 Identificação de falhas em mancais de rolamento

Os defeitos em rolamentos podem ser identificados pela presença de frequências características. Ao contrário da maioria das frequências de vibração geradas por componentes mecânicos, essas frequências são verdadeiramente frequências de defeito. Para determiná-las, é necessário conhecer as dimensões internas nos rolamentos, que são:

- β = ângulo de contato do elemento rolante com a gaiola
- BD = Diâmetro do elemento rolante
- PD = Diâmetro primitivo do rolamento

Na maioria dos casos a pista externa é fixa e a pista interna gira junto com o eixo de rotação da máquina. Quando isto acontece, as frequências podem ser calculadas através das seguintes equações:

- Frequência da pista externa do rolamento (BPFO):

$$f_{BPFO} = \frac{n}{2} f_r \left(1 - \frac{BD}{PD} \cos \beta\right) \quad (2.2)$$

- Frequência da pista interna do rolamento (BPFI):

$$f_{BPFI} = \frac{n}{2} f_r \left(1 + \frac{BD}{PD} \cos \beta\right) \quad (2.3)$$

- Frequência do elemento rolante (BSF):

$$f_{BSF} = \frac{PD}{BD} f_r \left[1 - \left(\frac{BD}{PD} \cos \beta\right)^2\right] \quad (2.4)$$

- Frequência da gaiola (FTF):

$$f_{FTF} = \frac{1}{2}f_r \left(1 - \frac{BD}{PD} \cos\beta\right) \quad (2.5)$$

sendo f_r a frequência de rotação [Hz] e n o número de elementos rolantes.

Normalmente, é difícil obter picos significativos nas frequências características de falhas a partir da análise do espectro gerado pela FFT. Isto acontece devido à presença de ruído ou vibrações oriundas de outras fontes [16]. Em seguida, descrevem-se brevemente mais duas técnicas de análise no domínio da frequência muito utilizadas na detecção de defeitos em rolamentos. Estas técnicas não foram utilizadas na parte experimental deste trabalho.

Cepstrum

Cepstrum é a transformada inversa de Fourier do logaritmo do espectro de potência. Esta técnica identifica e mostra famílias de picos, com igual espaçamento, presentes no espectro de frequência de um sinal. Ela é útil para identificar famílias harmônicas presentes no sinal, devido, por exemplo, a bandas laterais moduladas na frequência de rotação do mancal [16].

Detecção de Envelope do Sinal de Ressonância de Alta Frequência (HFRT)

Esta técnica extrai as frequências características de falha, que podem não estar presentes no espectro direto do sinal de vibração do mancal defeituoso [16].

Cada vez que uma falha localizada é atingida por um elemento rolante, um pulso de curta duração é gerado. Esse pulso excita as ressonâncias periodicamente nas frequências características relacionadas à localização da falha. As ressonâncias são, então, moduladas em amplitude na frequência característica de falha. Pela demodulação de uma dessas ressonâncias, um sinal indicativo da condição do mancal pode ser recuperado.

O processo de demodulação elimina as componentes de alta energia (associadas a desbalanceamento, desalinhamento, folgas, etc.) e permite maior precisão e antecedência na detecção de falhas nos defeitos nos rolamentos.

Na prática, o sinal é filtrado por um filtro passa-banda em torno de uma das frequências de ressonância, eliminando, assim, a maior parte do ruído. O envelope do sinal pode ser obtido através de um aparelho analógico, denominado “detetor de envelope”, ou de forma digital, através da Transformada de Hilbert. Finalmente, o espectro do sinal de envelope é, então, calculado através da FFT para extrair as frequências de falha características do mancal. A figura 2.20 mostra o esquema desta técnica.

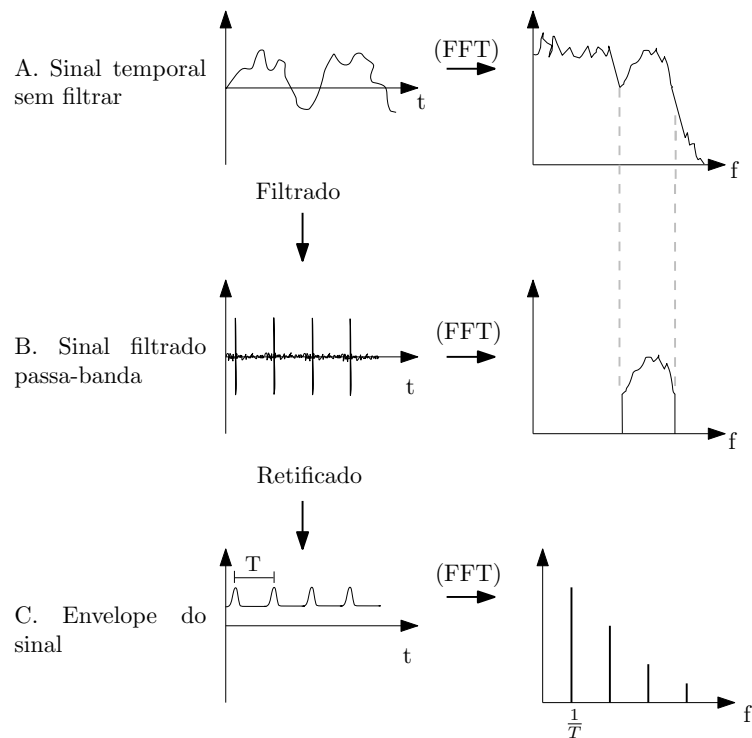


Figura 2.20: Esquema da técnica HFRT.

2.5.3 Técnicas no domínio tempo-frequência

A transformada de Fourier apresenta um problema muito importante: a sua incapacidade de analisar sinais não estacionários no tempo [18]. Normalmente a componente não estacionária do sinal (como, por exemplo, devido ao deslizamento dos elementos rolantes) contém informações relevantes sobre as falhas e, portanto, é

importante analisar esse tipo de sinal. Esse motivo levou ao desenvolvimento de técnicas de processamento de sinais que realizam um mapeamento de um sinal unidimensional numa função bidimensional no tempo e na frequência e, desta forma, fornecer uma representação tempo-frequência do sinal [16].

Algumas técnicas com esta característica são a Distribuição de Wigner-Ville (WVD), a Transformada de Fourier de Curto Tempo (STFT) e a Transformada Wavelet, muito utilizada na identificação de falhas em mancais de rolamento [16]. Estas técnicas não foram utilizadas na parte experimental deste trabalho.

Capítulo 3

Processo de gravação

No capítulo anterior foram apresentados os defeitos mais característicos nas máquinas rotativas: desbalanceamento, desalinhamento e falhas em mancais de rolamento. Este capítulo é referente a implementação prática numa bancada experimental, concebida para simulação e estudo desses defeitos. Será detalhado o sistema de aquisição dos sinais de vibração e áudio, os equipamentos *hardware* e *software* utilizados, o procedimento de indução dos defeitos e a análise dos sinais coletados nas diferentes medições.

Os sinais foram adquiridos utilizando toda a faixa de velocidades de rotação da máquina experimental: de 700 a 3600 RPM com passo de 60 RPM, gerando uma base de dados composta por 1951 medições.

3.1 Descrição da bancada experimental

A bancada experimental utilizada neste projeto é o *Alignment/Balance Vibration Trainer* (ABVT), comercializado pela *Spectra Quest Inc.* Esta ferramenta foi projetada para estudar o comportamento dinâmico de rotores apoiados em mancais de rolamento e/ou deslizamento, permitindo o treinamento em análise de vibração e a simulação de problemas de desbalanceamento, desalinhamento e defeitos em mancais de rolamentos, entre outros. A figura 3.1 mostra a estrutura do simulador, na qual pode observar-se o motor como máquina acionadora, unido ao eixo por meio do acoplamento; dois mancais de rolamentos sustentado o eixo; e os rotores com furos rosqueados para a introdução do desbalanceamento.




Figura 3.1: *SpectraQuest Alignment/Balance Vibration Trainer (ABVT)* [19].

As principais especificações mecânicas da bancada experimental são mostradas na tabela 3.1.

Tabela 3.1: Especificações mecânicas da bancada experimental.

Motor	1/4 CV DC
Faixa de velocidade	700-3600 RPM
Massa do sistema	22 kg
Eixo	Diâmetro: 16 mm Comprimento: 520 mm
Rotor	Diâmetro: 15,24 cm
Separação entre mancais	390 mm

3.2 Sistema de aquisição de dados

O sistema de aquisição de dados usado para coletar os sinais é composto pelos seguintes itens:

- Quatro sensores de vibração (acelerômetros).

- Tacômetro analógico para estimar a frequência de rotação da máquina.
- Microfone para captar a pressão sonora.
- Placas de aquisição de sinais, encarregadas de converter os sinal analógicos para digitais.
- Computador com o *software* de aquisição de sinais.

3.2.1 Sensores de vibração

Os acelerômetros piezoelétricos, situados nos mancais, captam as vibrações da máquina, produzindo um sinal de tensão proporcional. Neste projeto, foram utilizados quatro acelerômetros: três unidirecionais e um triaxial. Este ultimo é capaz de medir acelerações nos três eixos coordenados. Ele possui três cristais, posicionados de modo que cada um reage à vibração em um eixo diferente, fornecendo três tensões independentes de saída.

3.2.1.1 Características dos acelerômetros piezoelétricos utilizados

Acelerômetro industrial IMI Sensors, modelo 601A01

- Sensibilidade: ($\pm 20\%$) 100 mV/g (10,2 mV/(m/s²)).
- Faixa de frequência: (± 3 dB) 16-600000 CPM (0,27-10.000 Hz).
- Faixa de medição: ± 50 g (± 490 m/s²).



Figura 3.2: Acelerômetro industrial IMI Sensors, modelo 601A01 [20].

Acelerômetro triaxial IMI Sensors, modelo 604B31

- Sensibilidade: ($\pm 20\%$) 100 mV/g ($10,2 \text{ mV}/(\text{m}/\text{s}^2)$).
- Faixa de frequência: ($\pm 3 \text{ dB}$) 30-300000 CPM ($0,5$ - 5000 Hz).
- Faixa de medição: $\pm 50 \text{ g}$ ($\pm 490 \text{ m}/\text{s}^2$).



Figura 3.3: Acelerômetro triaxial IMI Sensors, modelo 604B31 [21].

3.2.1.2 Posicionamento dos acelerômetros na bancada

Ao medir a vibração, o acelerômetro deve se fixar no mancal. Mais especificamente, o transdutor deve ficar o mais próximo possível da linha central do mancal para evitar a captação de sinais distorcidos. A figura 3.4 mostra diversas configurações de colocação de acelerômetros, indicando as corretas e incorretas.




Figura 3.4: Configurações corretas e incorretas na colocação dos acelerômetros.

Para ajudar na determinação de falhas na máquina, é muito útil compilar dados de vibração de cada ponto de medição nas três direções axial, radial e tangencial. Por exemplo, como se viu no Capítulo 2, para detetar o problema de desbalanceamento no rotor, deve comparar-se o espectro de frequência do sinal de vibração nas direções axial e radial. A figura 3.5 mostra um esquema representativo dos planos de medição utilizados.

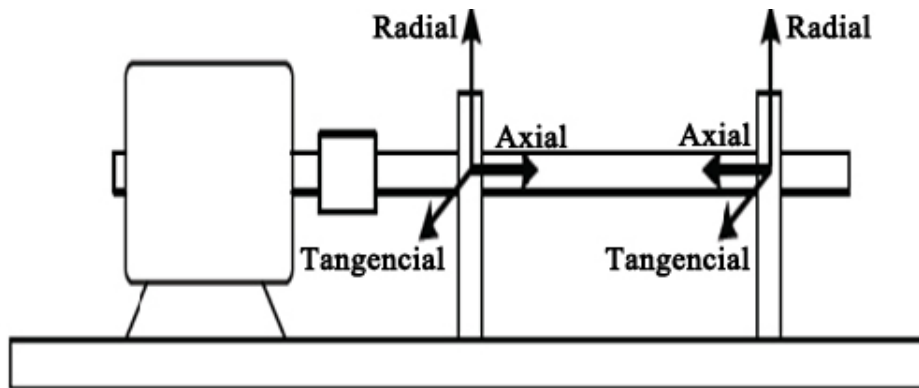


Figura 3.5: Esquema dos planos de medição.

Segundo [22], para os motores de menos de 50 CV, apenas um ponto de prova é adequado. Para motores de mais de 50 CV, cada mancal deveria ter o seu próprio ponto de prova. Nas máquinas sensíveis a danos em mancais de rolamento e nas que os problemas de mancais devem-se detetar o mais cedo possível, cada mancal deveria ter também seu próprio ponto de prova. Neste projeto, utilizou-se um bloco de montagem triaxial de alumínio com os três acelerômetros unidirecionais no mancal interior. O acelerômetro triaxial foi magnetizado diretamente no mancal exterior, como é mostrado na figura 3.6.



Figura 3.8: Chassi NI cDAQ 9178 [24].

3.2.3 Tacômetro analógico

Este tipo de sensores magnéticos convertem o movimento de um alvo ferroso em sinais de tensão proporcionais à velocidade. Conta com um módulo amplificador que converte esses sinais em pulsos. Neste projeto, foi utilizado um tacômetro analógico modelo MT-190 da *Monarch Instrument*, localizado próximo ao rotor para estimar a velocidade de rotação da máquina. A distância entre a máquina e o tacômetro deve ser inferior a 6,35 milímetros para seu correto funcionamento. A figura 3.9 mostra o conjunto sensor-amplificador utilizado.




Figura 3.9: tacômetro analógico: Monarch Instrument MT-190 [25].

3.2.4 Microfone

Além dos sensores citados anteriormente, foi utilizado um microfone Shure SM81, de tipo condensador e resposta de frequência de 20 Hz a 20 kHz, para captar o som produzido pela máquina. Foi situado a 10 cm do rotor, e ligado a um interface de áudio Alesis iO4, que fornece a alimentação *phantom* de 48 volts necessária e proporciona o sinal de saída. A figura 3.10 mostra o microfone e a interface de áudio utilizados.



(a)



(b)

Figura 3.10: Microfone Shure SM81 e interface Alesis iO4.

3.2.5 Cabos e conectores

A tabela seguinte mostra os conectores utilizados nos diferentes dispositivos:

Tabela 3.2: Cabos e conectores utilizados no processo de gravação.

Dispositivo	Entrada	Saída
NI 9178 + NI 9234 	BNC 	USB 
Acelerômetro 601A01 	2 pin MIL-C-5015 	BNC 
Acelerômetro 604B31 	4 pin MIL-C-26482 	BNC 
Tacômetro 		BNC 
Microfone Shure SM81 	Canon XLR – Fêmea 	Canon XLR – Macho 
Alesis iO4 	Canon XLR – Macho 	TRS 

3.2.6 *Softwares* utilizados na aquisição

Durante o processo de gravação foram utilizadas duas ferramentas de *software*:

- NI LabVIEW 2013.
- NI DIAdem 2010.

NI LabVIEW

O LabVIEW (acrônimo para *Laboratory Virtual Instrument Engineering Workbench*) é uma linguagem de programação gráfica originária da *National Instruments*. É ideal para o desenvolvimento de qualquer sistema de medição ou controle. Foram criados dois projetos no LabVIEW em formato *.vi*. O primeiro, realiza a estimação da frequência de rotação através do sinal do tacômetro. O segundo projeto têm a função de coletar todos os sinais, mostrar a forma de onda e o espectro dos mesmos e salvar os dados no formato *.tdms*.

NI DIAdem

O NI DIAdem é uma ferramenta de *software* que permite localizar, carregar, visualizar, analisar e gerar relatórios dos dados de medição coletados durante aquisições de dados e/ou gerados em simulações. Essa ferramenta foi utilizada para comprovar que os sinais obtidos foram gravados corretamente.



(a)



(b)

Figura 3.11: Logotipos do (a) LabVIEW e (b) DIAdem.

3.2.7 Conexões do sistema

As figuras 3.12 e 3.13 mostram as conexões dos equipamentos citados. No total, para cada medição são adquiridos oito sinais (seis sinais de vibração dos acelerômetros + sinal do tacômetro + sinal do microfone). Os dois módulos NI 9234 conectam-se ao chassi NI cDAQ 9178, acoplado a um notebook. O notebook, equipado com o *software* LabVIEW 2013, permite a gravação e compilação dos sinais.

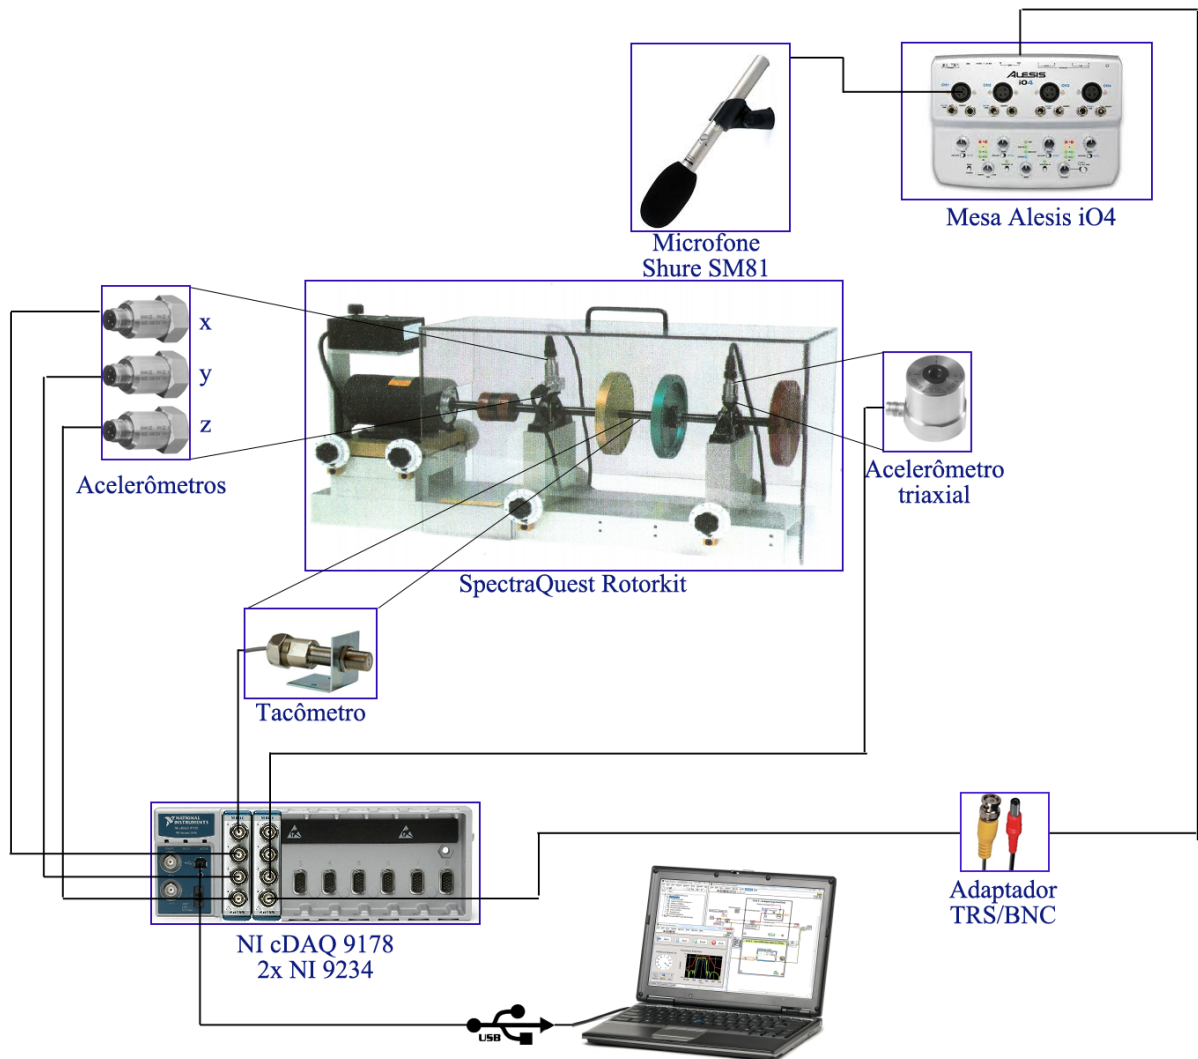




Figura 3.12: Diagrama das conexões no processo de gravação.



(a)



(b)

Figura 3.13: Conexões dos equipamentos.

3.3 Indução de defeitos na bancada

3.3.1 Desbalanceamento de massa

Existem duas configurações dos rotores nas máquinas rotativas. Na configuração *center-hung*, o rotor está localizado e centrado entre os dois mancais. Na configuração *over-hung*, comumente utilizada na indústria do gás e do petróleo, o rotor está situado na extremidade do eixo, depois do mancal exterior. As máquinas com esta configuração produzem níveis de vibração mais elevados devido aos efeitos de ressonância. A figura 3.14 mostra os esquemas destas duas configurações numa máquina rotativa. Neste projeto, unicamente foi utilizada a configuração *center-hung* do rotor.




Figura 3.14: Configurações do rotor (a) center-hung e (b) over-hung.

O material necessário para a inserção de massas desbalanceadoras no rotor consiste em vários parafusos e arruelas.

Primeiramente, a máquina deve estar corretamente alinhada, fixa e desligada. Para introduzir o desbalanceamento deve se fixar o parafuso com a(s) arruela(s) no rotor. Com o auxílio de uma balança de precisão, se pesaram as massas antes

de introduzi-lás no rotor, para fornecer uma medida quantitativa do nível de desequilíbrio. O parafuso deve ser apertado com firmeza utilizando uma chave. A figura 3.15 mostra o disco rotativo com o parafuso fixado.




Figura 3.15: Rotor com a massa desbalanceadora.

Neste projeto foram utilizados 7 massas diferentes para a indução do desbalanceamento: 6 g, 10 g, 15 g, 20 g, 25 g, 30 g e 35 g. A figura 3.16 mostra algumas das massas utilizadas sendo pesadas na balança.




Figura 3.16: Diferentes massas desbalanceadoras.

3.3.2 Desalinhamento de eixo

Neste trabalho se provocaram dois tipos de desalinhamento paralelo: horizontal e vertical, como é mostrado na figura 3.17.

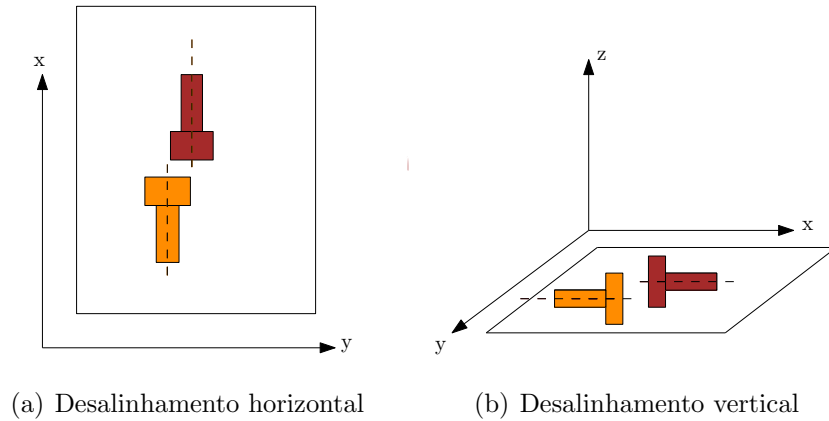


Figura 3.17: Desalinhamento paralelo induzido.

O motor da bancada têm instalados parafusos que permitem a indução de desalinhamento, como é mostrado na figura 3.18.




Figura 3.18: Parafusos de desalinhamento vertical e horizontal.

A máquina foi equipada com um acoplamento rígido, já que um acoplamento flexível pode compensar os desalinhamentos e fazé-los menos notórios. Para medir

a distâncias de desalinhamento horizontal, foi utilizado um paquímetro digital com resolução de 0.01 mm.

3.3.2.1 Desalinhamento paralelo horizontal

Para a indução de desalinhamento paralelo horizontal, primeiramente a máquina deve estar desligada e corretamente alinhada. Com o auxílio do paquímetro, deve se medir a distância de referência entre a base do motor e o segurador do parafuso, como é mostrado na figura 3.19.




Figura 3.19: Medição do desalinhamento com ajuda do paquímetro.

Depois, devem se apertar os parafusos horizontais do lado desejado, afrouxando por sua vez os parafusos do extremo contrário. Ambas extremidades da placa do motor devem ser movidas igualmente, para assegurar que o motor e o eixo permaneçam paralelos. Por último, deve se verificar, utilizando o paquímetro, que a diferença entre a distancia medida e a distancia de referência corresponde ao desalinhamento desejado.

Neste trabalho, os desalinhamentos paralelos horizontais efetuados foram de 0.5 mm, 1 mm, 1.5 mm e 2 mm.

3.3.2.2 Desalinhamento paralelo vertical

Para provocar desalinhamento vertical devem se soltar os parafusos verticais da base do motor ligeiramente (1 mm ou menos), fornecendo um espaço mínimo para levantar ou abaixar a placa da base do motor. A continuação, devem se inserir uma predeterminada e igual quantidade de calços em cada um dos quatro cantos da placa, elevando assim o eixo do motor acima do eixo do rotor. A figura 3.20 mostra os calços empregados para provocar o desalinhamento vertical e a figura 3.21 mostra esses calços colocados na placa do motor.



Figura 3.20: Calços empregados para o desalinhamento paralelo vertical.




Figura 3.21: Indução de desalinhamento paralelo vertical.

Os desalinhamentos paralelos verticais induzidos foram de 0.51 mm, 0.63 mm, 1.27 mm, 1.4 mm, 1.78 mm e 1.9 mm, utilizando diferentes combinações dos calços disponíveis.

3.3.3 Defeitos nos mancais de rolamento

Foram utilizados três mancais defeituosos: o primeiro, com falha na gaiola; o segundo, com falha na pista externa; e o terceiro, com falha no elemento rolante (esfera). As informações técnicas a respeito dos mancais utilizados são as seguintes:

- Número de elementos rolantes: 8 esferas.
- Diâmetro da esfera: 0,7145 cm.
- Diâmetro da gaiola: 2,8519 cm.
- FTF: 0,375 CPM/RPM.
- BPFO: 2,998 CPM/RPM.
- BPFI: 5,002 CPM/RPM.
- BSF: 1,871 CPM/RPM.

Foram utilizadas configurações com o mancal defeituoso invertido e com o mancal defeituoso não invertido, sempre individualmente, ou seja, não foram colocados dos mancais defeituosos ao mesmo tempo nas gravações. A figura 3.22 mostra as duas configurações utilizadas com os mancais defeituosos.





Figura 3.22: Configurações de mancal defeituoso (a) invertido e (b) não invertido.

Para colocar o mancal invertido, é preciso desmontar o eixo do ABVT, como é mostrado na figura 3.23




Figura 3.23: Desmontagem do eixo para a inserção do mancal invertido.

3.4 Medições e análise dos sinais de vibração

3.4.1 Estratégias de teste para inspeções de vibração

Antes de começar as medições, é importante realizar uma inspeção da vibração da máquina. Os seguintes itens foram considerados, de modo a assegurar a consistência dos dados a partir de uma medição para a outra.

- **Condições de teste:** A assinatura de uma máquina de vibração é fortemente dependente dos parâmetros operacionais, bem como da sua condição física. Provavelmente, o erro mais comum que se encontra na prática é o fato de compilar dados na mesma máquina, mas com diferentes parâmetros de operação e/ou níveis diferentes de vibração de fundo [22].
- **Condições de operação:** É fundamental que, quando os dados são compilados, a velocidade de rotação no teste esteja próxima à velocidade utilizada em testes anteriores. No momento da gravação, a velocidade de rotação deve ser constante e sem variações.
- **Aquecimento:** As máquinas devem ser testadas totalmente aquecidas. Uma máquina fria terá uma assinatura de vibração diferente do que uma máquina aquecida.
- **Inspeção Visual:** É importante inspecionar visualmente a máquina em operação no teste, verificando aspectos tais como ruídos inusitados, mancais mais quentes do que o normal, vibração excessiva, etc.

3.4.2 *Setup* de medição

A aquisição de dados foi realizada no Laboratório de Ensaio Dinâmicos e Análise de Vibrações (LEDAV). Os sinais de vibração foram adquiridos com uma taxa de aquisição de 50.000 amostras durante 5 segundos, totalizando 250.000 amostras. Com o auxílio do *software* LabVIEW, foi possível a obtenção e visualização das amostras coletadas. Os dados foram exportados em formato *.tdms*, próprio do LabVIEW.

Para cada defeito provocado na bancada, os dados foram adquiridos para rotações de 700 a 3600 RPM com passo de 60 RPM, aproximadamente.

Cada medição consta de oito sinais, como já foi dito na seção 3.2.7.

3.4.3 Estimação da frequência de rotação

A figura 3.24 mostra um exemplo de um sinal de tensão periódico captado pelo tacômetro, em que o inverso do período do sinal é a frequência de rotação. Na parte inferior da figura, é representado o espectro de frequência do sinal do tacômetro, que consiste em vários picos igualmente espaçados situados em f_r , $2f_r$, $3f_r$, etc., onde f_r é a frequência de rotação.




Figura 3.24: Exemplo de sinal do tacômetro no domínio do tempo e da frequência.

Neste exemplo, a velocidade de rotação é de 61 Hz.

Para a estimação da velocidade de rotação, foi criada uma rotina no LabVIEW, capaz de detectar o primeiro pico, acima de um certo limiar, do espectro de frequência correspondente ao sinal do tacômetro. A frequência de rotação da máquina foi anotada para cada medição. A figura 3.25 mostra um exemplo da estimação da

frequência de rotação para uma frequência de 21,58 Hz (1295 RPM).




Figura 3.25: Exemplo de estimação da frequência fundamental de rotação.

3.4.4 Medições de sinais normais (sem defeito)

Foram realizadas um total de 49 medições de sinais normais (sem defeito) nas frequências de rotação desde 737 RPM até 3686 RPM, com passo aproximado de 60 RPM.


3.4.5 Medições de desbalanceamento

Neste projeto, foram utilizadas sete massas desbalanceadoras diferentes para provocar o defeito de desbalanceamento no rotor, obtendo um total de 333 medições. A tabela 3.3 mostra a quantidade de medições para cada massa. À medida que o peso da massa é incrementado, o nível de vibração aumenta. A partir de um peso de 25 g, é inviável atingir velocidades de rotação acima de 3300 RPM. Por esse motivo, o número de sinais desbalanceados gravados é menor com as massas de 25 g, 30 g e 35 g.


Tabela 3.3: Sinais gravados para cada desbalanceamento introduzido.

Peso	Número de medições
6 g	49
10 g	48
15 g	48
20 g	49
25 g	47
30 g	47
35 g	45
Total	333

O defeito de desbalanceamento pode se apreciar mediante a análise espectral dos sinais de vibração captados na direção radial. A figura 3.26 compara a forma de onda e o espectro de um sinal de vibração sem defeito e um outro sinal com o rotor desbalanceado com uma massa de 35 g, a uma frequência de rotação de 3000 RPM (50 Hz). Ambos sinais correspondem ao acelerômetro da direção radial no mancal interior.



(a) Sinal sem desbalanceamento



(b) Sinal com desbalanceamento

Figura 3.26: Comparação dos sinais com e sem desbalanceamento na posição radial.

Analisando a figura anterior, se aprecia uma diferença evidente entre os dois sinais. O sinal temporal correspondente ao desbalanceamento apresenta uma maior amplitude e nível global, mas este fato é insuficiente para determinar a causa da falha. Já no espectro, observa-se um grande aumento da amplitude do sinal na frequência de rotação da máquina, indicando o desbalanceamento mecânico.

O desbalanceamento também pode ser comprovado comparando os espectros de vibração na posição radial e axial, lembrando que a força centrífuga devido ao desbalanceamento ocorre na posição radial. A figura 3.27 compara o espectro dos sinais obtidos pelos sensores nas posições axial e radial para um desbalanceamento de 20 g a 1800 RPM (30 Hz). Observa-se um aumento da amplitude de quase duas vezes, indicando o desbalanceamento.




Figura 3.27: Comparação entre as posições axial (figura superior) e radial (figura inferior) no desbalanceamento.

3.4.6 Medições de desalinhamento

As tabelas 3.4 e 3.5 mostram as medições efetuadas para cada desalinhamento paralelo horizontal e vertical, sendo 197 medições no caso do desalinhamento horizontal e 301 no desalinhamento vertical, contabilizando um total de 498 medições para este defeito.

Tabela 3.4: Sinais gravados para cada desalinhamento horizontal induzido.

Desalinhamento Horizontal	Número de medições
0.5 mm	50
1 mm	49
1.5 mm	49
2 mm	49
Total	197

Tabela 3.5: Sinais gravados para cada desalinhamento vertical induzido.

Desalinhamento Vertical	Sinais Gravados
0.51 mm	51
0.63 mm	50
1.27 mm	50
1.4 mm	50
1.78 mm	50
1.9 mm	50
Total	301

O desalinhamento paralelo manifesta-se principalmente na componente 2x rotação. A figura 3.28 compara o espectro de um sinal sem defeito e outro com desalinhamento vertical de 1.9 mm, ambos a uma velocidade de rotação de 3000 RPM (50 Hz). Observando a figura inferior, a falha de desalinhamento produz um aumento de amplitude na frequência de 100 Hz (segundo harmônico da frequência de rotação), indicando o desalinhamento.




Figura 3.28: Espectro de um sinal sem e com desbalanceamento a 3000 RPM (50 Hz).
 Observa-se o surgimento de um pico de amplitude na frequência 2x rotação.

3.4.7 Medições de mancais defeituosos

Os defeitos dos mancais são mais visíveis quando o rotor está desbalanceado. Por esse motivo, além da inserção dos mancais defeituosos, se introduziram massas de 6 g, 20 g e 35 g para provocar desbalanceamento. As tabelas 3.6 e 3.7 mostram o número de medições para cada mancal (invertido e não invertido).

Tabela 3.6: Número de medições com o mancal defeituoso não invertido.

	MANCAL 1				MANCAL 2				MANCAL 3			
Peso	0 g	6 g	20 g	35 g	0 g	6 g	20 g	35 g	0 g	6 g	20 g	35 g
Medições	49	48	49	42	49	49	49	37	50	49	49	38
Total	188				184				186			


Tabela 3.7: Número de medições com o mancal defeituoso invertido.

	MANCAL 1				MANCAL 2				MANCAL 3			
Peso	0 g	6 g	20 g	35 g	0 g	6 g	20 g	35 g	0 g	6 g	20 g	35 g
Medições	49	49	49	41	49	49	49	41	49	43	25	20
Total	188				188				137			


No total, foram realizadas 558 medições com o mancal defeituoso não invertido, e 513 sinais com o mancal defeituoso invertido. O mancal com falha no elemento rolante (mancal 3), na configuração invertida, junto com o rotor desbalanceado, gerou altos níveis de vibração, sendo impossível atingir altas velocidades de rotação para essa configuração. Por esse motivo, o número de medições gravados utilizando o mancal 3 invertido foi menor em comparação com as outras configurações.

3.4.8 Análise dos sinais coletados


Após a gravação da base de dados, é importante comprovar que todos os sinais tenham sido adquiridos corretamente. Com o auxílio do *software* DIAdem, foi possível a visualização dos sinais e a localização de falhas na gravação de uma forma rápida e eficaz. Devido a falhas nas conexões, alguns dos sinais podem ser adquiridos defeituosamente, devendo ser removidos da base de dados. No total, foram removidos 3 sinais defeituosos, mostrados na figura 3.29. Os dois primeiros sinais da figura correspondem ao sinal do acelerômetro triaxial na direção axial. O último sinal corresponde ao sinal do microfone. Estes três sinais aparecem distorcidos em comparação aos sinais adquiridos corretamente.



(a)



(b)



(c)

Figura 3.29: Sinais defeituosos removidos da base de dados.

3.5 Resumo da base de dados

No total, foram realizadas 1951 medições, contabilizando um total de 15.608 sinais. A tabela 3.8 mostra a desagregação de todos os sinais em função do defeito da máquina.

Tabela 3.8: Desagregação dos sinais gravados.

Defeito	Número de medições
Sem Defeito	49
Desbalanceamento	333
Desalinhamento Vertical	301
Desalinhamento Horizontal	197
Mancais Defeituosos não Invertidos	558
Mancais Defeituosos Invertidos	513
TOTAL	1951

Na prática, não é aconselhável determinar as falhas de uma máquina mediante a mera inspeção visual dos sinais. Pequenas variações da amplitude do espectro na frequência de rotação e nos harmônicos podem indicar a existência de defeitos, mas podem não ser apreciados visualmente. Gerar uma base de dados, com certa quantidade de sinais coletados para cada defeito, permite a detecção automática de falhas por meio de classificadores. Esta metodologia será explicada no próximo capítulo.

Capítulo 4

Classificação automática de defeitos

No capítulo anterior foi descrito o processo de gravação de uma base de dados de padrões de defeitos em uma máquina rotativa experimental. Neste capítulo será proposto um procedimento automático de reconhecimento do estado da máquina: normal, desbalanceada ou desalinhada. A primeira parte deste processo corresponde à extração das características sensíveis aos defeitos dos sinais de vibração obtidos, com o objetivo de reduzir a dimensionalidade e utilizar essas características no processo de classificação.

Serão descritos vários algoritmos de classificação, amplamente utilizados na atualidade: Regressão Logística, Máquinas de Vetor de Suporte, Redes Neurais Artificiais e *Random Forest*.

4.1 Reconhecimento de padrões

Reconhecimento de padrões é entendido como a caracterização de dados de entrada em classes identificáveis através de extração de características ou atributos fundamentais. Um projeto de reconhecimento de padrões envolve normalmente:

- Extração das características dos objetos a classificar.
- Seleção das características mais discriminativas.
- Construção de um classificador.

Em geral, os padrões são descritos por uma sequência de números reais que pode ser representada por um vetor num espaço multidimensional. Define-se espaço de medidas como o espaço no qual o padrão é inicialmente representado. Este espaço é, em geral, de alta dimensionalidade. Pode-se pensar em promover uma transformação com perda de informação que mapeie o espaço das medidas num outro de dimensionalidade reduzida. Este espaço é denominado de espaço de características.

O classificador implementa uma função de decisão, mapeando pontos do espaço das características em um conjunto de inteiros representando as classes.

4.2 Extração das características

O processo de extração das características é, provavelmente, o aspecto mais importante do reconhecimento de padrões [26]. As características extraídas dos sinais devem ser sensíveis às falhas da máquina, e robustas às condições operacionais variáveis. Além disso, é desejável que os algoritmos de extração das características permitam computações não dispendiosas. Isto é particularmente relevante durante o monitoramento de um sistema dinâmico, onde as mudanças devem ser capturadas dentro de um curto período de tempo.

Os sinais de vibração obtidos durante processo de gravação devem ser processados para a obtenção de características discriminativas que descrevam os padrões dos defeitos. A técnica de processamento de sinais utilizada neste trabalho foi a Transformada de Fourier, pois, como já foi dito nos capítulos anteriores, cada tipo de defeito afeta as vibrações da máquina num conjunto específico de frequências.

Na realização dos experimentos foram abordadas três classes: Normal (sem defeito), Desbalanceamento e Desalinhamento. A tabela 4.1 mostra a descrição e características de cada classe.

Tabela 4.1: Condições das classes definidas.

Classe	Descrição	Características espectrais	Numero de medições
Normal	Funcionamento normal da máquina, sem defeitos induzidos.	Sem características discriminativas	49
Desbalanceamento	Distribuição desigual de cargas em torno da linha central do eixo.	Predomínio de uma alta amplitude na frequência de rotação (1x rotação)	333
Desalinhamento	Deslocamento paralelo dos eixos no plano vertical e horizontal.	Amplitudes superiores em 2x e 3x rotação	498

Os defeitos considerados são fortemente dependentes da frequência de rotação e seus harmônicos. As características escolhidas neste trabalho foram obtidas a partir dos sinais dos acelerômetros situados em cada mancal: $s_x^{(1)}(n)$, $s_y^{(1)}(n)$, $s_z^{(1)}(n)$, $s_x^{(2)}(n)$, $s_y^{(2)}(n)$ e $s_z^{(2)}(n)$. Os sobrescritos (1) e (2) referem-se ao mancal 1 (interior) e 2 (exterior), e os subscritos x , y , z referem-se às três direções axial, tangencial e radial, respetivamente. Para cada um desses sinais, foram extraídas três características, correspondentes ao nível de amplitude no espectro nas frequências R_f , $2R_f$ e $3R_f$, sendo R_f a frequência de rotação da máquina, que também foi incluída como característica. A tabela 4.2 resume o conjunto das 19 características utilizadas.

Tabela 4.2: Conjunto de características.

Nome	Descrição
R_f	Frequência de rotação da máquina
$ S_x^{(1)}(R_f) $	Magnitude do espectro na frequência R_f do sinal do acelerômetro na direção axial no mancal 1
$ S_x^{(1)}(2R_f) $	Magnitude do espectro na frequência $2R_f$ do sinal do acelerômetro na direção axial no mancal 1

$ S_x^{(1)}(3R_f) $	Magnitude do espectro na frequência $3R_f$ do sinal do acelerômetro na direção axial no mancal 1
$ S_y^{(1)}(R_f) $	Magnitude do espectro na frequência R_f do sinal do acelerômetro na direção tangencial no mancal 1
$ S_y^{(1)}(2R_f) $	Magnitude do espectro na frequência $2R_f$ do sinal do acelerômetro na direção tangencial no mancal 1
$ S_y^{(1)}(3R_f) $	Magnitude do espectro na frequência $3R_f$ do sinal do acelerômetro na direção tangencial no mancal 1
$ S_z^{(1)}(R_f) $	Magnitude do espectro na frequência R_f do sinal do acelerômetro na direção radial no mancal 1
$ S_z^{(1)}(2R_f) $	Magnitude do espectro na frequência $2R_f$ do sinal do acelerômetro na direção radial no mancal 1
$ S_z^{(1)}(3R_f) $	Magnitude do espectro na frequência $3R_f$ do sinal do acelerômetro na direção radial no mancal 1
$ S_x^{(2)}(R_f) $	Magnitude do espectro na frequência R_f do sinal do acelerômetro na direção axial no mancal 2
$ S_x^{(2)}(2R_f) $	Magnitude do espectro na frequência $2R_f$ do sinal do acelerômetro na direção axial no mancal 2
$ S_x^{(2)}(3R_f) $	Magnitude do espectro na frequência $3R_f$ do sinal do acelerômetro na direção axial no mancal 2
$ S_y^{(2)}(R_f) $	Magnitude do espectro na frequência R_f do sinal do acelerômetro na direção tangencial no mancal 2
$ S_y^{(2)}(2R_f) $	Magnitude do espectro na frequência $2R_f$ do sinal do acelerômetro na direção tangencial do mancal 2
$ S_y^{(2)}(3R_f) $	Magnitude do espectro na frequência $3R_f$ do sinal do acelerômetro na direção tangencial do mancal 2
$ S_z^{(2)}(R_f) $	Magnitude do espectro na frequência R_f do sinal do acelerômetro na direção radial do mancal 2
$ S_z^{(2)}(2R_f) $	Magnitude do espectro na frequência $3R_f$ do sinal do acelerômetro na direção radial do mancal 2

$ S_z^{(2)}(3R_f) $	Magnitude do espectro na frequência $3R_f$ do sinal do acelerômetro na direção radial do mancal 2
---------------------	--

A extração das características supõe uma redução da dimensionalidade de 250.000 amostras iniciais para apenas 3 por cada sinal, o que permite remover o excesso de dados que não aportam informação discriminativa. Além disso, também é reduzida a complexidade computacional global associada ao processo de aprendizado do classificador.

A figura 4.1 mostra o esquema do sistema de reconhecimento de padrões. Uma vez que as características são extraídas, o último passo é utilizar essas *features* na entrada do classificador para obter as classes de saída.

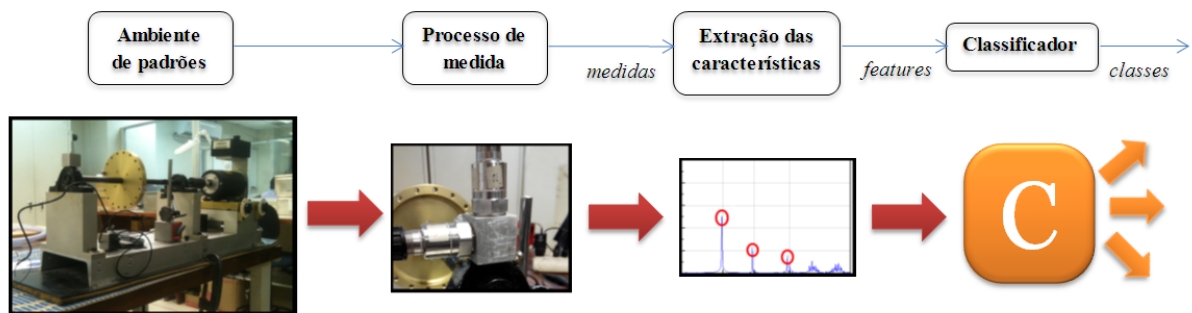


Figura 4.1: Sistema de reconhecimento de padrões. Após o processo de medida por meio dos acelerômetros, são extraídas as características para, finalmente, realizar a classificação e obter as diferentes classes predefinidas.

4.3 Métodos de classificação

Os métodos de classificação podem ser agrupados em duas categorias: métodos supervisionados e métodos não supervisionados. Nos métodos da classificação supervisionada, assume-se a existência de um conjunto de amostras de padrões cujas classes são conhecidas. Nos métodos não supervisionados, a natureza e número de classes presentes são desconhecidos. Neste caso, o problema a ser tratado consiste, além da classificação, na própria definição das classes.

Os processos de classificação também podem ser agrupados em métodos paramétricos e não paramétricos. Nos métodos paramétricos, supõe-se conhecida a forma geral da função densidade de probabilidade que descreve o comportamento dos dados. Os parâmetros existentes dessas funções são estimados, então, a partir das amostras de treinamento disponíveis para cada classe. Quando a função densidade de probabilidade é desconhecida, a alternativa consiste em utilizar os chamados métodos não paramétricos.

4.4 Algoritmos de aprendizado supervisionado

Dadas m amostras de treinamento, cada uma com n características, denomina-se conjunto de treinamento ao conjunto $\{(x^{(i)}, y^{(i)}); i = 1, \dots, m\}$, onde $x^{(i)} \in \mathbb{R}^n$ denota as variáveis de entrada (vetor de características) e $y^{(i)}$ é um valor discreto que representa a classe associada. Um par $(x^{(i)}, y^{(i)})$ é denominado amostra ou exemplo de treinamento. O espaço de valores de entrada será denotado como \mathcal{X} e o espaço de saída como \mathcal{Y} .

O algoritmo de aprendizado supervisionado pode ser descrito da seguinte forma: o classificador será treinado de forma que aprenda uma função $h : \mathcal{X} \mapsto \mathcal{Y}$ de modo que $h(x)$ seja um bom preditor para o valor correspondente de y ante uma entrada x ainda não vista. Este processo é descrito graficamente na figura 4.2.




Figura 4.2: Processo de aprendizado supervisionado de um classificador h .

Nos algoritmos de classificação, é fundamental se evitar o risco de sobreajuste, também conhecido como *overfitting*. Este problema consiste na memorização dos

padrões de treinamento por parte do classificador, gravando suas peculiaridades e ruídos, ao invés de extrair as características gerais que permitirão a generalização ou reconhecimento de padrões não utilizados no treinamento.

Os classificadores binários podem abordar a classificação de mais de uma classe utilizando o método conhecido como *um-contra-todos*. Com este método, treina-se o classificador para a primeira classe, usando-se como contra-exemplos as outras classes, e assim por diante. Para um novo dado de entrada x , é escolhida a classe i que satisfaz: $\operatorname{argmax}_i h^{(i)}(x)$.

4.4.1 Regressão Logística (*Logistic Regression*)

Neste classificador, em que $y \in \{0, 1\}$, a função h é definida pela seguinte equação:

$$h(x) = g(\theta^T x) = \frac{1}{1 + e^{-\theta^T x}}, \quad (4.1)$$

onde $g(z) = \frac{1}{1 + e^{-z}}$ é a função sigmóide, representada na figura 4.3.




Figura 4.3: Função sigmóide.

A função $h(x)$ retorna a probabilidade estimada de que $y = 1$ para uma entrada x , isto é, $h(x) = P(y = 1 \mid x; \theta)$. Se $h(x) \geq 0.5$ ou, equivalentemente, $\theta^T x > 0$, a predição será $y = 1$. Se $h(x) < 0.5$ ou, equivalentemente, $\theta^T x < 0$, a predição será $y = 0$.

O vetor $\theta = [\theta_0, \theta_1, \dots, \theta_n]$ contém os parâmetros desconhecidos que serão estimados com base nos dados amostrais. Estes parâmetros θ_i são ajustados para minimizar a função custo, definida por:

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m y^{(i)} \log(h(x^{(i)})) + (1 - y^{(i)}) \log(1 - h(x^{(i)})) \right] \quad (4.2)$$

Para um dado de entrada x , se y é exatamente igual ao que foi predito, então o custo será zero, pois $J(\theta) = 0$ se $y = 1$ e $h(x) = 1$. Pelo contrário, conforme $h(x)$ se aproxima a zero, sendo $y = 1$, o custo vai para infinito. Ou seja, o algoritmo prediz $P(y = 1 | x; \theta) = 0$ mas $y = 1$, resultando em um custo muito alto.

Existem outras funções custo que podem ser escolhidas, mas a função custo da equação (4.2) pode ser derivada usando o princípio de estimativa por máxima verossimilhança, que é um método estatístico para encontrar eficientemente os parâmetros θ que melhor ajustam os dados ao modelo. Esta função também possui a propriedade de ser convexa, o que facilita a convergência para seu mínimo global.

Para achar os parâmetros θ que minimizam $J(\theta)$ é usado o método conhecido como redução do gradiente, descrito por:

$$\theta_j := \theta_j - \alpha \frac{\partial}{\partial \theta_j} J(\theta) \quad (4.3)$$

Simplificando a equação anterior, obtém-se:

$$\theta_j := \theta_j - \alpha \sum_{i=1}^m (h(x^{(i)}) - y^{(i)}) x_j^{(i)}, \quad (4.4)$$

onde o parâmetro α , chamado de taxa de aprendizado, controla quão grande é o “passo” ao atualizar o parâmetro θ_j . Este algoritmo é repetido até convergir.

O classificador de regressão logística permite criar fronteiras de decisão lineares ou polinômicas, em função da escolha da função h . Uma regressão logística linear será caracterizada por $h(x) = g(\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n)$. Por sua vez, uma regressão logística polinômica será caracterizada por $h(x) = g(\theta_0 + \theta_1 x + \theta_2 x^2 + \dots + \theta_n x^n)$. A figura 4.4 mostra um exemplo bidimensional de regressão logística linear e polinômica.

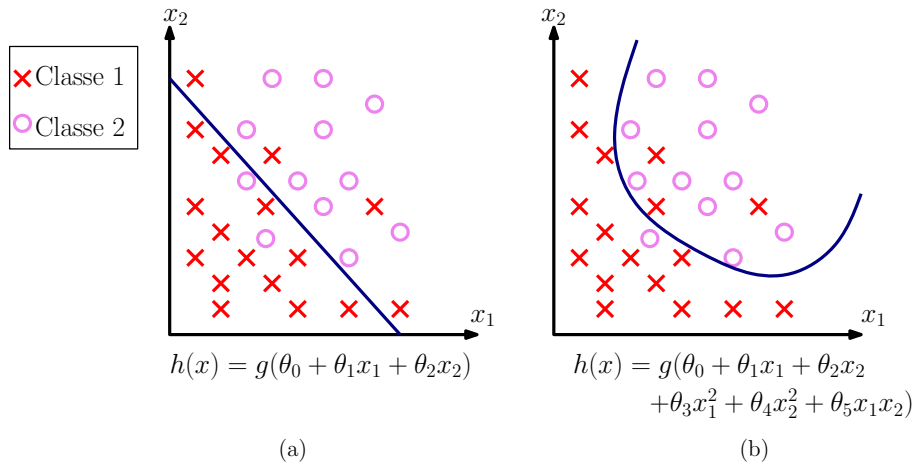


Figura 4.4: Exemplos de Regressão Logística: (a) linear; (b) polinômica. No caso linear, a fronteira de decisão é determinada por uma reta. Na regressão polinômica, os valores de entrada x_i podem ser combinados na função $h(x)$, obtendo uma fronteira de decisão não linear.

Para evitar o sobreajuste na regressão logística, pode-se utilizar a regularização, que consiste em reduzir a magnitude dos parâmetros θ_j , adicionando um termo na equação (4.2), resultando:

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m y^{(i)} \log(h(x^{(i)})) + (1 - y^{(i)}) \log(1 - h(x^{(i)})) \right] + \frac{\lambda}{2m} \sum_{j=1}^n \theta_j^2, \quad (4.5)$$

onde λ é o parâmetro de regularização. Se λ for muito elevado, os parâmetros θ_j ficariam próximos a zero, resultando numa $h(x) \approx \theta_0$, o que produziria um mal ajuste no treinamento (*underfit*). Deve-se, então, procurar um compromisso entre o correto ajuste dos dados de treinamento e a minimização do sobreajuste.

4.4.2 Máquinas de Vetor de Suporte (*Support Vector Machines*) - SVM

Este classificador é caracterizado por ser capaz de encontrar o hiperplano ótimo, que possui a maior margem de distância para os elementos de ambas as classes. Este fato possui a vantagem de permitir construir fronteiras de decisão flexíveis e atingir uma boa capacidade de generalização [27]. A figura 4.5 mostra um exemplo

de separação de duas classes com o hiperplano separador ótimo.




Figura 4.5: O hiperplano ótimo separando os dados com a máxima margem ρ em uma distribuição dos dados no \mathbb{R}^2 .

Quando as classes não são linearmente separáveis, o classificador SVM pode realizar um mapeamento não linear, transformando os vetores de entrada em vetores de um espaço de maior dimensão em que seja possível separar os dados linearmente, através de funções de *kernel*. A figura 4.6 mostra um exemplo de mapeamento do \mathbb{R}^2 a \mathbb{R}^3 utilizando uma função *kernel*.




Figura 4.6: Mapeamento de \mathbb{R}^2 a \mathbb{R}^3 mediante a função *kernel*. Na imagem da esquerda, não existe uma fronteira de decisão linear. A função *kernel* mapeia os dados no espaço \mathbb{R}^3 , onde são linearmente separáveis (imagem direita).

A função h no SVM pode ser escrita como:

$$h(x) = \sum_i \alpha_i y_i K(x_i, x_j) + \beta, \quad (4.6)$$

onde $K(x, x_i)$ é o *kernel* utilizado pelo SVM e α e β são os parâmetros encontrados durante o treinamento. As funções *kernel* mais comuns são:

- Polinômico: $K(x_i, x_j) = (\gamma x_i \cdot x_j + c)^d$
- Gaussiano (*Radial Basis Function*): $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$
- Tangente hiperbólica: $K(x_i, x_j) = \tanh(kx_i \cdot x_j + c)$

A função custo do SVM é similar à função custo da Regressão Logística, mostrada na equação (4.5). Neste caso, utiliza-se um parâmetro de regularização C para evitar o *overfitting*. Ao contrário que em Regressão Logística, um valor pequeno de C pode produzir um mal ajuste no treinamento.

4.5 Redes neurais artificiais

As redes neurais artificiais (RNAs) são sistemas de computação adaptativos inspirados nas características de processamento de informação encontradas nos neurônios reais e nas características de suas interconexões [28]. Basicamente, todos os tipos de redes neurais apresentam a mesma unidade de processamento: um neurônio artificial, que simula o comportamento do neurônio biológico. Esse neurônio artificial possui várias entradas, que correspondem às conexões com outras unidades similares a ele, e uma saída, cujo valor depende diretamente da somatória ponderada de todas as saídas dos outros neurônios a esse conectado. O modelo artificial de neurônio é mostrado na figura 4.7. Esse modelo inclui um sinal adicional *bias* que favorece ou limita a possibilidade de ativação do neurônio. O processo sináptico é representado pelos pesos ω que amplificam cada um dos sinais recebidos. A função de ativação h modela a forma em que o neurônio responde ao nível de excitação, limitando e definindo a saída da rede neural. As funções de ativação mais utilizadas são: limiar, linear e sigmóide.

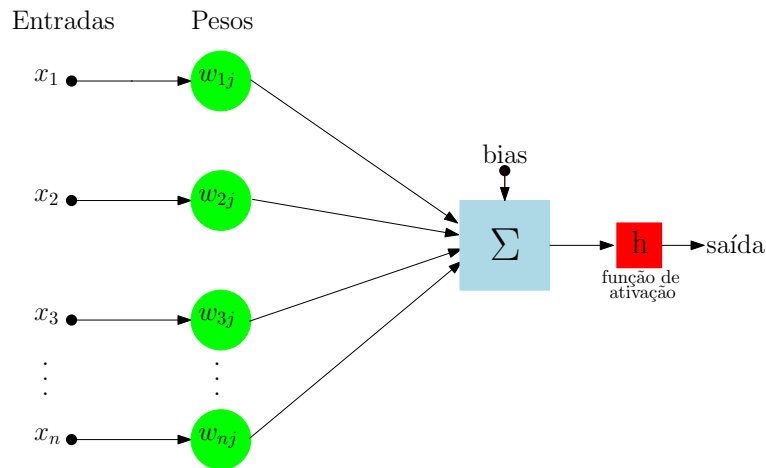


Figura 4.7: Modelo artificial do neurônio biológico

A arquitetura de uma rede neural pode variar em função dos seguintes itens:

- Camadas intermediárias.
- Quantidade de neurônios.
- Função de transferência.
- Algoritmo de aprendizado.

4.5.1 Perceptron de múltiplas camadas

As RNAs do tipo Perceptrons de Múltiplas Camadas (*Multilayer Perceptron* - MLP) são redes que apresentam uma ou mais camadas de neurônios intermediários ou escondidos. As redes MLP são muito utilizadas por apresentarem maior simplicidade e facilidade de implementação [29]. A figura 4.8 mostra um exemplo de MLP com quatro entradas, duas camadas intermediárias com três neurônios e uma camada de saída com dois neurônios.




Figura 4.8: Perceptron de múltiplas camadas

4.5.2 Treinamento e aprendizado das redes neurais

O aprendizado das redes neurais pode ser na forma supervisionada ou não supervisionada. O aprendizado supervisionado pode ser classificado em treinamento dinâmico e treinamento estático. No primeiro ocorrem alterações na estrutura de rede (redução ou aumento do número de camadas, número de neurônios em cada camada e número de conexões). No treinamento estático, somente os valores dos pesos sofrem alterações e a topologia da rede é mantida inalterada.

No treinamento supervisionado estático, a RNA compara o valor de saída calculado com o valor esperado, e avalia o erro decorrente das diferenças entre ambos. Assim, com a discrepância conhecida, os pesos são modificados de forma a minimizar o erro e encontrar a melhor relação entre as informações de entrada e saída.

Seja $d_j(t)$ a resposta desejada para o neurônio j no instante t e $y_j(t)$ a resposta observada do neurônio j no instante t , obtida através de um estímulo $x(t)$ presente na entrada da rede neural. O par $(x(t), d_j(t))$ constitui um exemplo de *estímulo-resposta* apresentado ao neurônio no instante t . O termo $e_j(t)$ é o sinal de erro observado na saída do neurônio j no instante t :

$$e_j(t) = d_j(t) - y_j(t) \quad (4.7)$$

O processo de aprendizado supervisionado têm por objetivo corrigir este erro, de maneira que, para um t suficientemente alto, os $y_j(t)$ estejam próximos, no sentido

estatístico, dos $d_j(t)$, com $j = 1, 2, \dots, k$, sendo k o número de neurônios da rede neural.

A cada etapa de treinamento são feitas pequenas modificações nos pesos, provocando uma minimização incremental dos erros, convergindo em direção do valor esperado. A forma genérica de alteração dos pesos é dada por:

$$w_{ij}(t+1) = w_{ij}(t) + \eta e_j(t) x_j(t), \quad (4.8)$$

onde η é a taxa de aprendizado que determina a velocidade com que os pesos serão ajustados em direção ao menor erro e $x_j(t)$ é a entrada para o neurônio j no tempo t .

Na prática, adota-se a soma dos erros quadráticos de todas as saídas como parâmetro de desempenho da rede. A função custo a ser minimizada pelo algoritmo de treinamento é descrita pela seguinte equação:

$$E(t) = \frac{1}{2} \sum_j e_j^2(t) \quad (4.9)$$

O algoritmo de retropropagação (*backpropagation*) é o mais comumente empregado no treinamento supervisionado de redes MLP [29]. Em uma primeira fase ocorre a propagação do sinal funcional (*feedforward*) mantendo-se os pesos fixos de modo a gerar um valor de saída $y_j(t)$ a partir das entradas fornecidas à RNA. Na segunda fase, as saídas são comparadas com os valores desejados $d_j(t)$, gerando um sinal de erro $e_j(t)$, que se propaga da saída para a entrada (retropropagação do erro), ajustando-se os pesos de forma a minimizar o erro e convergir assim para o valor de saída desejado $y_j(t)$. Na prática, pode-se estabelecer duas condições de convergência: um erro aceitável ou um número limite de iterações.

4.5.3 *Overfitting* e generalização nas RNAs

A generalização indica a capacidade da RNA em aprender através de um pequeno número de exemplos e, posteriormente, simular valores coerentes para um grupo desconhecido de dados. O excesso de treinamento (*overfitting*) pode acontecer quando

é empregado um número grande de neurônios nas camadas internas da rede. Para evitá-lo, pode-se utilizar regularização (já estudada na regressão logística), modificando a função custo para minimizar, além do erro $e_j(t)$, os valores dos pesos ao longo do treinamento, pois pesos elevados estão relacionados com a ocorrência de *overfitting* [29]. A função custo é definida, então, por:

$$J = \frac{1}{2} \sum_{i=1}^k (d_i - y_i)^2 + \frac{1}{2} \lambda \|w\|^2, \quad (4.10)$$

onde λ representa o parâmetro de regularização.

Outro método para evitar o sobreajuste é o treinamento com parada antecipada, em que os dados de entrada são divididos em dois conjuntos: um conjunto de treinamento e um conjunto de validação. Os pesos são ajustados empregando somente o conjunto de treinamento, porém o conjunto de validação é utilizado para avaliar a capacidade de generalização da RNA através da medida do erro que a RNA apresenta para esse conjunto ao longo do treinamento. Neste quesito, podem acontecer duas situações:

1. Os erros de treinamento e validação permanecem estáveis após um certo número de iterações. Esta situação é ilustrada na figura 4.9.




Figura 4.9: Os erros de treinamento e validação permanecem estáveis após certo número de iterações: não existe risco de *overfitting* e a capacidade de generalização é boa.

2. Após um certo número de iterações, o erro de validação começa a crescer, embora o erro de treinamento possa ser reduzido ainda mais se o treinamento

tivesse continuidade. Esta situação é mostrada na figura 4.10. Neste caso, o recomendado é parar o treinamento antes do erro de validação crescer.




Figura 4.10: O erro de validação cresce, indicando o *overfitting*. O número máximo de iterações neste caso deve ser 10000, mesmo que possa se atingir um erro menor com maior número de iterações.

4.6 Classificador *Random Forest*

O método de classificação conhecido como *Random Forest* consiste em uma técnica de agregação de classificadores do tipo árvore, construídos de forma que a sua estrutura seja composta de maneira aleatória [30]. Uma árvore de decisão é uma coleção de nós e arestas organizados de maneira hierárquica. Os nós podem ser internos (*splits*) ou nós terminais (folhas). Uma amostra entra pela parte superior da árvore e é submetida a uma série de testes binários em cada nó até chegar a uma folha, na que se encontra a resposta. A figura 4.11 mostra um exemplo de classificação utilizando uma árvore de decisão.




Figura 4.11: Criação de um árvore de decisão.

Para determinar a classe de uma instância, o método combina o resultado de várias árvores de decisão, por meio de um mecanismo de votação. Cada árvore dá uma classificação ou um voto para uma classe. A classificação final é dada pela classe que recebeu o maior número de votos entre todas as árvores da floresta.

O classificador é baseado no método *Bagging* [30]. Para cada árvore gerada é utilizado um conjunto de treinamento diferente, formado por n exemplos de treinamento escolhidos aleatoriamente. Para cada nó da árvore gerada, são escolhidas aleatoriamente m características que orientam o direcionamento do nó, baseado na melhor discriminação de classes do conjunto de treinamento, de acordo com uma métrica. Em geral, o valor de m deve ser bem menor que o total de atributos da base, de maneira que possam ser geradas árvores distintas, que são combinadas para classificar um novo exemplo.

O modelo gerado elege a classe mais frequente entre as opções individuais de cada árvore. A vantagem desse classificador é que ele permite bases de dados com um

número grande de atributos, contudo é suscetível a um sobreajuste (*overfitting*) em determinadas bases [30].

Capítulo 5

Análise dos resultados experimentais

Nos capítulos anteriores foram descritos os procedimentos de aquisição dos sinais no processo de gravação, a obtenção das características sensíveis as falhas e a possibilidade de utilização de vários classificadores automáticos para detectar os defeitos da máquina rotativa. Neste capítulo, será detalhado o procedimento experimental realizado no trabalho. Primeiramente, será descrito o algoritmo utilizado na extração das características e, posteriormente, a utilização desses atributos nos classificadores mencionados no Capítulo 4. Todos os testes foram realizados com auxílio da plataforma de *software* MATLAB®.

5.1 Algoritmo de extração das características

Primeiramente, foram feitas as leituras dos arquivos em formato *.tdms*, próprio da *National Instruments*, através do MATLAB. Estes arquivos foram convertidos para o formato aberto *comma-separated values (.csv)*, que não possui restrições de licenças.

Para extrair as características dos sinais foi criado um algoritmo, cujos passos são os seguintes:

1. Leitura dos dados discretos provenientes dos sinais dos acelerômetros.
2. Estimação da frequência de rotação através da identificação do primeiro pico no espectro do sinal do tacômetro (calculado mediante a FFT). A estimação foi feita guardando os quatro primeiros picos com amplitude maior que 0.3

e separação mínima de 15 amostras, escolhendo aquele com menor valor em frequência. A seguinte figura mostra um exemplo de estimação para uma frequência de rotação de 30 Hz.




Figura 5.1: Estimação da frequência de rotação. O algoritmo procura os quatro primeiros picos de amplitude do espectro do sinal do tacômetro e guarda aquele que apresenta um menor valor em frequência (30 Hz neste exemplo).

3. Para os outros sinais dos acelerômetros, foi calculada a magnitude da FFT e guardado o valor dos picos correspondentes à frequência de rotação R_f (calculada no passo 2), $2R_f$ e $3R_f$. Como a frequência do pico pode não coincidir exatamente com os harmônicos de R_f , o algoritmo procura o pico numa banda de ± 3 amostras em torno da frequência desejada, escolhendo o valor maior.
4. As três características de cada acelerômetro e a frequência de rotação foram salvas no vetor de características, sendo este de dimensão 19, conforme detalhado na tabela 4.2.

Este algoritmo foi utilizado para cada medição realizada das classes abordadas na classificação (Normal, Desbalanceamento e Desalinhamento), obtendo uma matriz de características $\mathcal{M}_{880 \times 19}$, na qual as 19 colunas correspondem às características de cada medição e as 880 linhas correspondem aos exemplos de cada classe, sendo:

- 49 exemplos da classe Normal.
- 333 exemplos da classe Desbalanceamento.
- 498 exemplos da classe Desalinhamento.

A matriz de características é determinada, então, da seguinte forma:

$$\mathcal{M} = \begin{pmatrix} x^{(1)} \\ x^{(2)} \\ x^{(3)} \\ \vdots \\ x^{(880)} \end{pmatrix} = \begin{pmatrix} n_1^{(1)} & n_2^{(1)} & \dots & n_{19}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ n_1^{(49)} & n_2^{(49)} & \dots & n_{19}^{(49)} \\ \hline b_1^{(1)} & b_2^{(1)} & \dots & b_{19}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ b_1^{(333)} & b_2^{(333)} & \dots & b_{19}^{(333)} \\ \hline l_1^{(1)} & l_2^{(1)} & \dots & l_{19}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ l_1^{(498)} & l_2^{(498)} & \dots & l_{19}^{(498)} \end{pmatrix},$$

onde os elementos n pertencem à classe Normal, os b à classe Desbalanceamento e os l à classe Desalinhamento.

5.2 Classificação mediante RNAs

Para este trabalho, foi proposta uma rede neural de tipo MLP. Segundo [31], uma configuração razoável de redes neurais de tipo MLP, empregadas na classificação, consiste na utilização de uma única camada oculta e o mesmo número de neurônios que de entradas, podendo chegar, no máximo, até duas vezes o número de entradas.

Foram criadas várias topologias de rede, todas com treinamento estático, retropropagação e parada antecipada. A divisão dos dados utilizada foi de 70% para treinamento, 10% para validação e 20% para teste, sendo estes blocos permanentes para todos os experimentos subsequentes.

5.2.1 Utilização das características de três sinais de vibração

O primeiro experimento realizado, foi a reprodução do artigo [32], em que se utilizaram apenas as características dos sinais dos três acelerômetros do mancal interior. Assim, o número de características foi diminuído de 19 para 10 (suprimindo as colunas correspondentes da matriz de características). A figura 5.2 mostra a topologia desta rede.

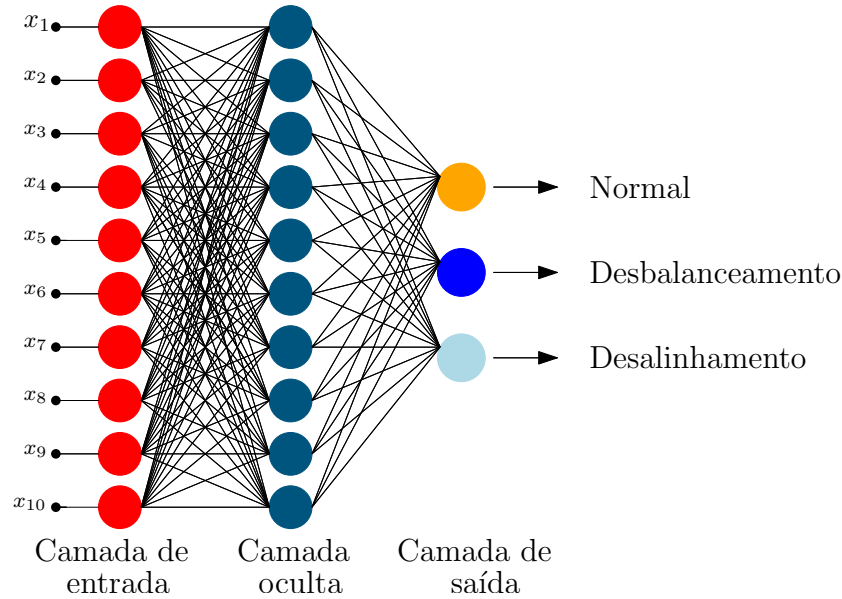


Figura 5.2: Topologia da RNA no primeiro experimento. A camada de entrada e a oculta contam com dez neurônios.

A tabela 5.1 mostra o desempenho deste primeiro classificador.

Tabela 5.1: Desempenho do classificador baseado em RNA utilizando as características de 3 acelerômetros.

Objetivo/ Predição	Normal	Desbalanceamento	Desalinhamento	Taxa de acerto (%)
Normal	0/10	0/67	0/99	0
Desbalanceamento	0/10	64/67	0/99	95.5
Desalinhamento	10/10	3/67	99/99	100
TOTAL				92.6

Devido ao baixo número de exemplos da classe Normal, o classificador erra na predição de todos exemplos dessa classe e os classifica como pertencentes à classe Desalinhamento. Para um classificador funcionar devidamente, é fundamental que o número de exemplos de todas as classes estejam na mesma ordem de grandeza. Este problema será tratado mais adiante.

Foram testadas outras topologias da RNA, alterando o número de neurônios da camada oculta. A figura 5.3 mostra um gráfico da taxa de acerto do classificador em função do número de neurônios da camada oculta, resultando uma função bastante irregular. Pode se apreciar como o incremento de neurônios não implica em uma melhora do desempenho da RNA.




Figura 5.3: Taxa de acerto x Neurônios da camada oculta.

5.2.2 Aumento dos exemplos de treinamento da classe Normal

A fim de evitar um desempenho dependente das classes predominantes, deve-se reduzir a diferença de exemplos de treinamento entre a classe Normal e as classes Desbalanceamento e Desalinhamento. Neste trabalho, foram aumentados por oito vezes os exemplos da classe Normal, passando de 49 a 392 exemplos.

Para abordar essa ampliação, foram elaborados dois métodos diferentes:

Método 1: Divisão de amostras dos sinais da classe Normal

Este método consiste em dividir os sinais originais pertencentes a classe Normal, transformando cada sinal de 250.000 amostras em oito sinais de 31.250 amostras, que serão processadas conforme a seção 5.1, para a obtenção das suas características. Estas novas entradas se utilizaram apenas para treinar a RNA. A simulação dos exemplos da classe Normal foi feita a partir dos 49 sinais originais (sem divisão). A tabela 5.2 mostra o desempenho para esta configuração, utilizando uma topologia de RNA com 18 neurônios na camada oculta.

Tabela 5.2: Desempenho do classificador baseado em RNA ampliando os sinais normais.

Objetivo/ Predição	Normal	Desbalanceamento	Desalinhamento	Taxa de acerto (%)
Normal	26/49	1/67	13/99	53.1
Desbalanceamento	1/49	63/67	0/99	94
Desalinhamento	22/49	3/67	86/99	86.9
TOTAL				81.4

Na tabela anterior pode-se observar como o desempenho global é reduzido em relação à tabela 5.2. Porém, aplicando este método, mais da metade dos sinais da classe Normal são corretamente classificados.

Método 2: Adição de ruído branco Gaussiano aos sinais da classe Normal

Neste segundo método foi adicionado ruído branco gaussiano a cada sinal da classe Normal, gerando oito novos sinais por cada um original. A figura 5.4 mostra um exemplo quantitativo do ruído adicionado e a figura 5.5 compara as mil primeiras amostras de um sinal original e um sinal ruidoso.




Figura 5.4: Exemplo quantitativo do ruído adicionado na ampliação dos sinais da classe Normal.




Figura 5.5: Comparação entre um sinal (a) sem alterar e um sinal (b) com ruído branco gaussiano adicionado.

Novamente, foram extraídas as características dos sinais ruidosos, que foram utilizadas para treinar uma nova RNA com 20 neurônios na camada oculta. A simulação foi efetuada com os 49 sinais originais da classe Normal. O desempenho deste método é mostrado na tabela 5.3.

Tabela 5.3: Desempenho do classificador baseado em RNA utilizando as características de 3 acelerômetros.

Objetivo/ Predição	Normal	Desbalanceamento	Desalinhamento	Taxa de acerto (%)
Normal	40/49	1/67	12/99	81.6
Desbalanceamento	1/49	63/67	0/99	94
Desalinhamento	8/49	3/67	87/99	87.9
TOTAL				88.4

Pode-se observar como o segundo método de ampliação dos sinais da classe Normal possui uma maior capacidade de generalização. Comparando com a tabela 5.2, reconhece quase 30% a mais dos exemplos da classe Normal. Este foi o método escolhido para os experimentos posteriores, tanto RNAs como os outros classificadores.

5.2.3 Utilização das características de todos os sinais de vibração

Ao ampliar o número de exemplos da classe Normal, têm-se os seguintes subconjuntos na base de dados:

- 392 exemplos da classe Normal.
- 333 exemplos da classe Desbalanceamento.
- 498 exemplos da classe Desalinhamento.

A nova matriz de características terá dimensão 1223×19 e será determinada da seguinte forma:

$$\mathcal{M}' = \begin{pmatrix} x^{(1)} \\ x^{(2)} \\ x^{(3)} \\ \vdots \\ x^{(1223)} \end{pmatrix} = \begin{pmatrix} n_1^{(1)} & n_2^{(1)} & \dots & n_{19}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ n_1^{(392)} & n_2^{(392)} & \dots & n_{19}^{(392)} \\ \hline b_1^{(1)} & b_2^{(1)} & \dots & b_{19}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ b_1^{(333)} & b_2^{(333)} & \dots & b_{19}^{(333)} \\ \hline l_1^{(1)} & l_2^{(1)} & \dots & l_{19}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ l_1^{(498)} & l_2^{(498)} & \dots & l_{19}^{(498)} \end{pmatrix},$$

Neste experimento, se utilizaram todas as características dos seis sinais de vibração, com o objetivo de comparar os resultados obtidos na tabela 5.3 e comprovar a melhoria na classificação automática de defeitos de uma máquina monitorizada com acelerômetros em cada mancal. A tabela 5.4 mostra os resultados da classificação mediante RNA com topologia de 17 neurônios na camada oculta.

Tabela 5.4: Desempenho do classificador baseado em RNA utilizando os seis acelerômetros.

Objetivo/ Predição	Normal	Desbalanceamento	Desalinhamento	Taxa de acerto (%)
Normal	49/49	0/67	2/99	100
Desbalanceamento	0/49	67/67	0/99	100
Desalinhamento	0/49	0/67	97/99	98
TOTAL				99.1

Na tabela anterior, observa-se a grande melhora do classificador ao adicionar as características dos acelerômetros do segundo mancal, detectando todos os defeitos exceto dois, com uma taxa de acerto de 99.1%. Porém, esta taxa pode variar bastante em função do número de neurônios empregados, o que pode levar a enganos. A figura 5.6 mostra um gráfico da taxa de acerto em função do número de neurônios

da camada oculta. Pode-se observar a grande variância e como o desempenho pode diminuir até 86%, por exemplo, escolhendo uma camada oculta de 36 neurônios.




Figura 5.6: Taxa de acerto x Neurônios da camada oculta.

5.3 Classificação mediante Regressão Logística

Neste teste, foi criado um algoritmo de classificação baseado no método de Regressão Logística, em que a função de aprendizado vem dada por

$$h(x) = \frac{1}{1 + e^{-\theta^T x}} = \frac{1}{1 + e^{-(\theta_1 x_1 + \theta_2 x_2 + \dots + \theta_{19} x_{19})}}. \quad (5.1)$$

O algoritmo utiliza a técnica de redução do gradiente para minimizar a função custo e o método *um-contra-todos* para poder identificar as três classes. Foi utilizado um parâmetro de regularização $\lambda = 0.1$ para evitar o *overfitting*.

Segundo o Teorema de Cover (Cover, 1965), um problema complexo de classificação de padrões disposto não linearmente em um espaço de alta dimensão, tem maior probabilidade de ser linearmente separável do que em um espaço de baixa dimensionalidade. Mediante este algoritmo, será utilizado um hiperplano separador linear, com o objetivo de comprovar o grau de linearidade existente entre as classes. Ao tratar com vetores de entrada pertencentes ao espaço \mathbb{R}^{19} , segundo Cover, os dados são mais facilmente classificáveis comparado com um espaço de menor dimensão.

A tabela 5.5 mostra os resultados obtidos utilizando este método de classificação.

Tabela 5.5: Desempenho do classificador baseado em Regressão Logística.

Objetivo/ Predição	Normal	Desbalanceamento	Desalinhamento	Taxa de acerto (%)
Normal	48/49	0/67	14/99	98
Desbalanceamento	0/49	62/67	1/99	92.5
Desalinhamento	1/49	5/67	84/99	84.8
TOTAL				90.2

Analisando os resultados da tabela anterior, comprova-se como realmente os dados podem ser separados, na sua maioria, mediante uma fronteira de decisão linear, obtendo-se uma taxa de acerto superior a 90%.

5.4 Classificação mediante SVM

Neste trabalho, foi adotado um classificador baseado em Máquinas de Vetores de Suporte (SVM), utilizando um parâmetro de regularização $C = 1$ e uma função *kernel* de tipo gaussiano, que permite a classificação de dados dispostos não-linearmente. Foi aplicado também o método *um-contra-todos* para possibilitar a identificação das três classes. A tabela 5.6 mostra os resultados obtidos utilizando este classificador.

Tabela 5.6: Desempenho do classificador baseado em SVM.

Objetivo/ Predição	Normal	Desbalanceamento	Desalinhamento	Taxa de acerto (%)
Normal	48/49	0/67	0/99	98
Desbalanceamento	1/49	67/67	0/99	100
Desalinhamento	0/49	0/67	99/99	100
TOTAL				99.5

Este classificador oferece resultados muito satisfatórios, melhorando o método da Regressão Logística, o qual era esperado, pois a utilização da função kernel gaussiana projeta os dados de entrada num espaço de maior dimensão em que seja possível separar as classes linearmente.

5.5 Classificação mediante *Random Forest*

O algoritmo de classificação *Random Forest* foi o último a ser usado. Na sua implementação, comprovou-se o seu desempenho em função do número de árvores de decisão utilizados. Para cada nó de árvore gerada, foram escolhidas aleatoriamente $m = 4$ características, que orientam o direcionamento do nó. A figura 5.7 mostra o desempenho deste algoritmo em função do número de árvores de decisão utilizados.

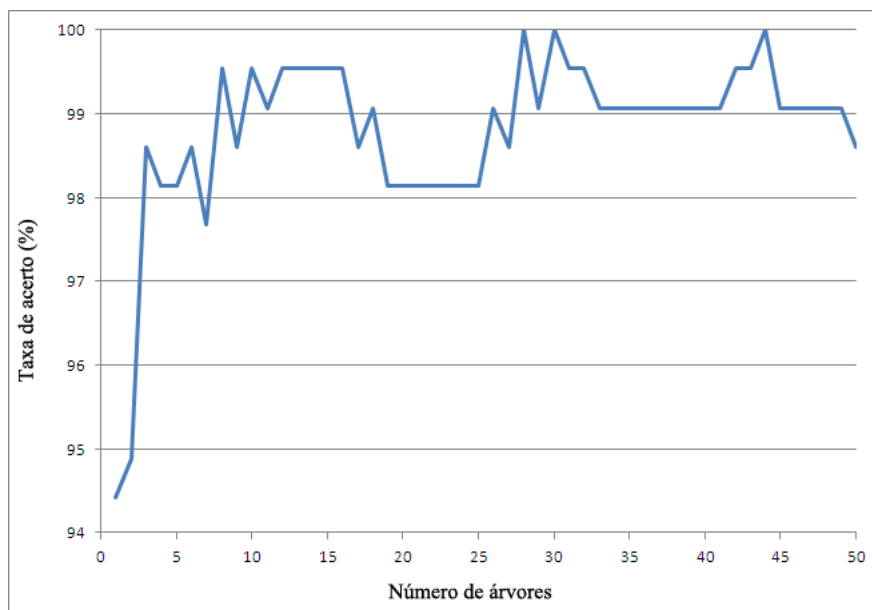


Figura 5.7: Taxa de acerto x Número de árvores de decisão utilizando *Random Forest*.

Na figura anterior, observa-se como o classificador atinge uma taxa de acerto superior a 98%, com apenas três árvores de decisão, chegando até uma taxa de acerto de 100% utilizando 28, 30 e 44 árvores. A diferença das RNAs, em que a variação do número de neurônios podia produzir uma drástica redução no desempenho do classificador, o *Random Forest* mantém um desempenho alto e estável quando é

alterado o número de árvores.

5.6 Comparação dos algoritmos utilizados

Dentre os algoritmos de classificação utilizados, o *Random Forest* apresentou os melhores resultados. Este classificador possui uma maior simplicidade, flexibilidade e facilidade de aplicação. Apresenta uma grande robustez, mantendo um grande desempenho em todas as combinações dos parâmetros utilizados, a diferença das RNAs, em que a variação da topologia da rede altera significativamente o desempenho. Além disso, *Random Forest* apresenta um treinamento muito eficiente. Outra vantagem é sua grande capacidade de generalização, evitando o sobreajuste sem necessidade de ter que escolher parâmetros de regularização.

Segundo [31], a utilização da Regressão Logística (ou SVM com *kernel* de tipo linear) é recomendada se o número de características é elevado em relação ao número de exemplos. Para um número de características pequeno em relação ao total de exemplos, como acontece neste projeto, o uso de SVM com *kernel* de tipo gaussiano apresentará melhores resultados. O desempenho do classificador SVM utilizado neste trabalho é similar ao atingido com *Random Forest*, conseguindo-se um treinamento muito eficiente e velocidades de execução mais rápidas. Uma vantagem do uso de SVM é a facilidade de implementação, escolhendo unicamente a função *kernel* e o parâmetro de regularização C . Porém, uma escolha errada deste parâmetro pode afetar radicalmente ao desempenho. É importante conhecer os valores típicos dos parâmetros de regularização. Neste trabalho, a variação desses parâmetros em torno aos seus valores típicos não afetou ao desempenho total dos classificadores.

Em relação às redes neurais, têm-se uma maior complexidade na hora de desenhar a topologia. Este algoritmo apresenta uma menor robustez, pois em função do número de camadas ocultas e neurônios por camada, conseguem-se taxas de acerto com grande variância. O treinamento deste classificador é mais lento em comparação a SVM e *Random Forest*.

Em suma, com base nos resultados obtidos neste trabalho, e tendo em consideração a taxa de acerto, a robustez e a complexidade de treinamento, os algoritmos de classificação utilizados podem ordenar-se de maior a menor desempenho da seguinte forma:

1. *Random Forest*.
2. Máquinas de Vetores de Suporte (SVM).
3. Redes Neurais Artificiais (RNAs).
4. Regressão Logística.

Capítulo 6

Conclusões e sugestões para trabalhos futuros

6.1 Conclusões

Através do estudo das falhas mecânicas mais comuns em máquinas rotativas, seus efeitos de vibração e das técnicas de análise de sinais utilizadas para o tratamento de dados e diagnóstico de defeitos, este trabalho apresentou um estudo experimental de classificação automática das falhas de desbalanceamento de massa e desalinhamento de eixo de uma bancada experimental. Foi projetada uma base de dados de sinais relativas aos defeitos mencionados, além de falhas em mancais de rolamento.

Com o desbalanceamento e desalinhamento obtiveram-se as características discriminativas de cada defeito através da análise espectral dos sinais de vibração. Especificamente, para cada sinal foram extraídas três características correspondentes ao nível de amplitude do espectro na frequência de rotação da máquina e seus dois primeiros harmônicos.

Após o processamento dos sinais, as características foram utilizadas como entrada de diversos algoritmos de classificação, sendo estes: Regressão Logística, Máquinas de Vetores de Suporte (SVM), Redes Neurais Artificiais (RNAs) e *Random Forest*. Este último classificador aportou os melhores resultados, chegando a detectar todos os defeitos com uma configuração de 28 árvores de decisão, apresentando altas taxas de acerto com outras configurações. Além disso, *Random Forest* conta com o treinamento mais eficiente. O classificador SVM também atingiu um bom desempenho, com um 99.5% de taxa de acerto e um tempo de execução similar ao

Random Forest. Por sua vez, as RNAs foram utilizadas para escolher os melhores conjuntos de treinamento, devido à necessidade de aumentar os exemplos da classe Normal. Este classificador apresentou um comportamento mais irregular, sendo o seu desempenho mais dependente da topologia de rede escolhida em comparação aos outros classificadores. A arquitetura da rede neural é um fator determinante para a eficiência da classificação. Contudo, não existe na bibliografia metodologia que permita a generalização, tornando necessária a experimentação, análise e ajustes desses parâmetros caso a caso.

6.2 Sugestões para trabalhos futuros

A continuação, descrevem-se algumas propostas para trabalhos futuros, em base ao trabalho realizado neste projeto:

- Utilizar a base de dados de sinais de vibração relativas aos mancais defeituosos e realizar a sua classificação, procurando as características discriminativas desses sinais através de diferentes métodos (Transformada Wavelet, Análise do Envelope, Transformada de Fourier de Curto tempo, etc.).
- Criar um sistema de classificação automática capaz de detetar todos os defeitos, procurando e comparando características discriminatórias de todos eles.
- Classificar o grau dos defeitos, estabelecendo subclasses dependendo da gravidade do defeito.
- Utilizar métodos diferentes para a extração das características: nível global, fator crista, média, variância, curtose, assimetria, etc.
- Criar algoritmos de seleção das melhores características antes de realizar a classificação.
- Utilizar o sinal de áudio do microfone. Neste trabalho, testou-se a inclusão do sinal de microfone junto com as outras 19 características, recebendo o mesmo processamento que os sinais de vibração. O resultado não foi satisfatório, pois as características do sinal de áudio pioraram o desempenho do classificador. Uma possibilidade seria a utilização do sinal de áudio para a estimação da

frequência de rotação, ou para medir parâmetros no domínio temporal, tais como o nível global.

- Empregar os algoritmos de classificação com novos sinais, comprovando a estabilidade de cada classificador para novas entradas.

Referências Bibliográficas

- [1] WIKIPEDIA, “Induction motor — Wikipedia, The Free Encyclopedia”, 2014, (Online; acesso em 30 Novembro 2014).
- [2] PACHOLOK, M., *Uso da termografia para avaliação do desalinhamento de eixos de máquinas rotativas. Uma ferramenta auxiliar à análise de vibrações*. M.Sc. dissertation, Pontifícia Universidade Católica do Paraná, 2004.
- [3] ESSEL ELETROMECAÂNICA, “Elementos de máquinas”, Disponível em <http://www.essel.com.br/cursos/material/01/ElementosMaquinas/17elem.pdf>, (Acesso em 18 Novembro 2014).
- [4] SPANER, F. R., *Técnicas preditivas de manutenção de máquinas rotativas*. M.Sc. dissertation, Universidade Federal do Rio de Janeiro, Agosto 2009.
- [5] GARCIA, M. S., *Análise de defeitos em sistemas mecânicos rotativos a partir da monitoração de vibrações*. M.Sc. dissertation, Universidade Federal do Rio de Janeiro, Junho 2005.
- [6] COSTA, E. D. S., *Diagnóstico de defeitos mecânicos em máquinas rotativas usando lógica fuzzy baseada no espectro completo de vibrações*. M.Sc. dissertation, Universidade Federal do Pará, 2011.
- [7] BARRA, F. D. S., *Reconhecimento de padrões de condições de funcionamento de rolamentos em máquinas rotativas com auxílio de redes neurais artificiais*. M.Sc. dissertation, Universidade Federal do Rio de Janeiro, Agosto 2013.
- [8] “Medição de Vibrações. Aspectos Gerais”, Disponível em [://www.httppisegnet.com.br/1index.asp](http://www.httppisegnet.com.br/1index.asp), 2007, (Acesso em Novembro 2014).
- [9] FERNANDES, J., “Segurança nas Vibrações sobre o corpo humano”, 2000, (Acesso em 14 Outubro 2014).

- [10] NERY, R. T. D. C., *Desenvolvimento de uma ferramenta virtual para análise de vibração em máquina rotativa: aplicação em uma bancada didática*. M.Sc. dissertation, Universidade Federal do Pará, 2008.
- [11] BONALDI, E. L., *Diagnóstico preditivo de avarias em motores de indução trifásicos com MCSA e teoria de conjuntos aproximados*. M.Sc. dissertation, Universidade Federal de Itajubá, Março 2005.
- [12] REZENDE, J. C. F., “Problemas de Vibração em Máquinas Rotativas”, Curso Básico de Vibrações Aplicado às Máquinas, Apostila.
- [13] RANGEL, J. D. S., *Análise rotodinâmica de equipamentos sujeitos a desbalanceamento estático, dinâmico e modal*. M.Sc. dissertation, Universidade Federal do Rio de Janeiro, Junho 2008.
- [14] ISO, *Mechanical vibration – Balancing – Vocabulary*, ISO 1925:2001, International Organization for Standardization, Geneva, Switzerland, 2001.
- [15] SZYMON, A. A., PIETA, F., *Bancada didática de alinhamento de máquinas rotativas*. M.Sc. dissertation, Universidade Tecnológica Federal do Paraná, 2011.
- [16] DIEZEL, A. R., MONTEIRO, U. A. B. V., PINTO, L. A. V., “Evolução das técnicas de identificação de falhas em mancais de rolamento na indústria naval e offshore”. In: *24 Congresso Nacional de Transporte Aquaviário, Construção Naval e Offshore*, Rio de Janeiro, 2012.
- [17] WIKIPEDIA, “Rolling element bearing — Wikipedia, The Free Encyclopedia”, 2014, (Online; acesso em 30 Novembro 2014).
- [18] CASTANO, M. Z., *Análisis de señales mediante STFT y wavelet. aplicación a defectología en rodamientos*. M.Sc. dissertation, Universidad Carlos III de Madrid, Dezembro 2010.
- [19] SPECTRA QUEST INC., *User operating manual for Alignment/Balance Vibration Trainer*, 1998.
- [20] PCB PIEZOTRONICS, INC., *Platinum Low-cost Industrial ICP Accelerometer Model 601A01*, 2014.

- [21] PCB PIEZOTRONICS, INC, *Low-cost Triaxial Industrial ICP Accelerometer Model 604B31*, 2014.
- [22] WHITE, G., *Introduction to Machine Vibration*. Woburn, Acima DLI, 1995.
- [23] NATIONAL INSTRUMENTS, *NI 9234 módulo IEPE de 4 canais*, 2014.
- [24] NATIONAL INSTRUMENTS, *NI cDAQ 9178 chassi NI CompactDAQ USB de 8 slots*, 2014.
- [25] MONARCH INSTRUMENT, *M-190W Magnetic Sensor*. Amherst, NH, 2014.
- [26] ALMEIDA, F. R. D. V., *Análises Estatísticas e Reconhecimento de Padrão Aplicados em Diagnósticos de Defeitos em Rolamentos Através da Análise de Vibração*. Ph.D. dissertation, Universidade Federal de Itajubá, 2007.
- [27] “Curso de visión artificial”, Universidad Rey Juan Carlos, Madrid, Tema 5. Reconocimiento de patrones.
- [28] MATSUNAGA, V. Y., “Curso de Redes Neurais utilizando o MATLAB”, 2012. Belém, Pará, Brasil.
- [29] FIORIN, D. V., MARTINS, F. R., SCHUCH, N. J., *et al.*, “Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares”, *Revista Brasileira de Ensino de Física*, v. 33, Abril 2011.
- [30] DINIZ, F. A., NETO, F. M. M., JUNIOR, F. D. C. L., *et al.*, “RedFace: um sistema de reconhecimento facial baseado em técnicas de análise de componentes principais e autofaces: comparação com diferentes classificadores”, *Revista Brasileira de Computação Aplicada*, v. 5, pp. 42–54, Abril 2013.
- [31] NG, A., “CS229 Machine Learning”, Disponível em <http://cs229.stanford.edu/>, 2014.
- [32] LIMA, A. A. D., PREGO, T. D. M., NETTO, S. L., *et al.*, “On Fault Classification in Rotating Machines using Fourier Domain Features and Neural Networks”. In: *Proc. IEEE Latin Am. Symp. on Circ. and Systems (LASCAS)*, Março 2013.

- [33] PIOTROWSKI, J., *Shaft alignment handbook*. New York, Marcel Dekker, 1995. Páginas 320-330.
- [34] PIOTROWSKI, J., “A importância do alinhamento entre eixos”, Disponível em <http://www.manter.com.br>, Traduzido por Julio Nascif Xavier.
- [35] MAGNAGO, L., SAULO, F., *Alinhamento de máquinas rotativas*. SENAI, 1997. CPM - Programa de Certificação de Pessoal de Manutenção.
- [36] PEREIRA, P., “Alinhamento de máquinas rotativas”, Disponível em Disponível em <http://mecanica-blog.blogspot.com.br>, (Acesso em 14 Outubro 2014).
- [37] ESTUPINAN, E. A., SAAVEDRA, P. N., *Análise de vibração aplicada em máquinas rotativas de baixa velocidade*, Report, Mundo mecânico, 2011.
- [38] ESTUPIAN, E., MARTIN, C. S., CANALES, L., “Desarrollo de un instrumento virtual para el balanceamiento dinámico de rotores”, *Ingeniare - Revista Chilena de Ingeniería*, v. 14, pp. 146–152, 2006.
- [39] SOUSA, K. M., SOEIRO, N. S., NERY, R. T., *et al.*, “Desenvolvimento de uma ferramenta virtual para diagnóstico de defeitos em máquinas rotativas: aplicação em uma bancada didática”. In: *CONEM 2010: VI Congresso nacional de engenharia mecânica*, Campina Grande, 2010.
- [40] FONTOURA, D. S., *Uso de modelos numéricos e medições em problemas de vibração excessiva*. M.Sc. dissertation, Universidade Federal do Rio de Janeiro, Agosto 2006.
- [41] PEREIRA, J. A. R., *Conceção e construção de um simulador de controlo de vibrações*. M.Sc. dissertation, Instituto superior de engenharia de lisboa, Setembro 2013.
- [42] MCMILLAN, R. B., *Rotating Machinery: Practical Solutions to Unbalance and Misalignment*. Lilburn, Fairmont Press, 2003.
- [43] BRANDAO, R. P., *Projeto mecânico de uma máquina de ensaio de fadiga por flexão rotativa*. M.Sc. dissertation, Universidade Federal do Rio de Janeiro, Agosto 2013.

- [44] ASSIS, A. C. D., *Identificação de velocidades críticas simulador de máquinas rotativas*. M.Sc. dissertation, Universidade Federal do Rio de Janeiro, Março 2014.
- [45] “Tipos mais comuns de acelerômetros”, Disponível em <http://www.seara.ufc.br/tintim/tecnologia/acelerometro/acelerometro01.htm/>, (Acesso em 14 Outubro 2014).
- [46] LIMA, A. A., PREGO, T. D. M., GOIS, J. N., *et al.*, *Rotating Machines Predictive Maintenance Performance: Matlab × Madlib × R*, Report, Universidade Federal do Rio de Janeiro, Maio 2014.
- [47] SAMANTA, B., AL-BALUSHI, K. R., AL-ARAIMI, S. A., “Artificial neural networks and genetic algorithm for bearing fault detection”, *Soft Comput*, v. 10, pp. 264–271, 2005.
- [48] GANERIWALA, S., “Field Balancing of Rotating Machinery”, Disponível em http://www.spectraquest.com, (Acesso em 22 Outubro 2014).
- [49] DIAS, W. D. A., VIEIRA, D. V., *Instrumento virtual de detecção e diagnóstico de barras quebradas em motores elétricos de indução baseado em análise espectral da corrente de estator*. M.Sc. dissertation, Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, 2013.
- [50] HERNANDEZ, N. F. G., ROSENDE, P. H. J., *Técnica de la demodulación en el diagnóstico de fallas en máquinas rotatorias*. M.Sc. dissertation, Universidad Austral de Chile, 2002.

Apêndice A

Projeto Labview

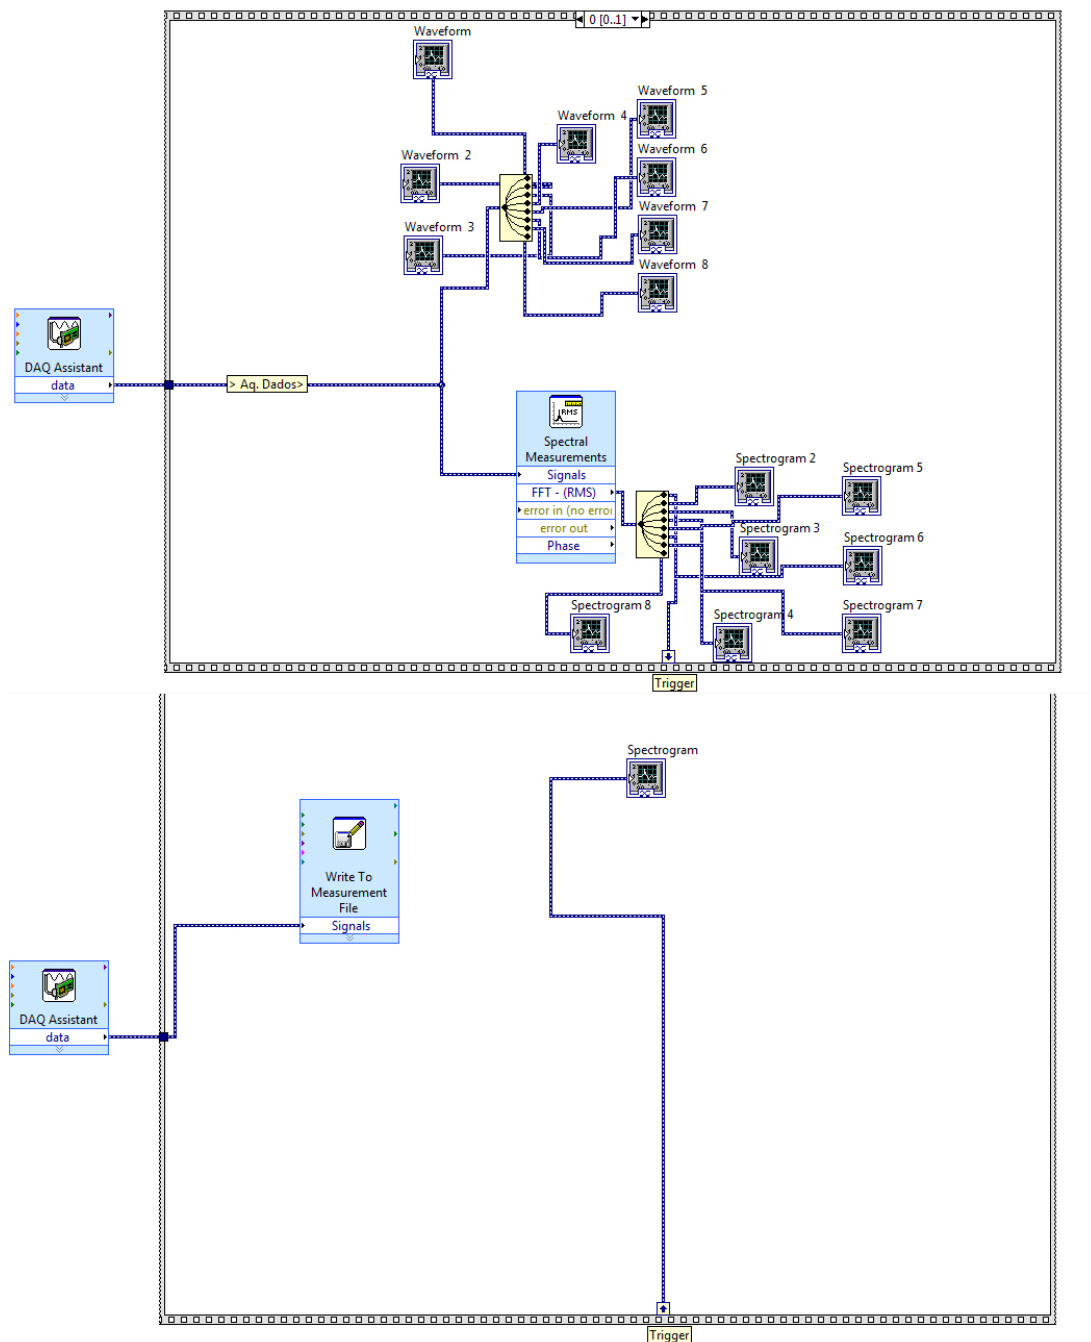


Figura A.1: Diagrama de bloco do módulo de aquisição e visualização de sinais.

Apêndice B

Especificações dos equipamentos

NI cDAQ 9178

Especificações gerais

Quantidade de slots	8
Sistema operacional / target	Real-Time Windows
Suporte a LabVIEW RT	Sim
Trigger interno	Sim

Requisitos de alimentação

Potência total disponível	15 W
Faixa de tensão de entrada	9 V - 30 V

Contadores / temporizadores

Contadores	4
Dimensões	32 bits

Choque e vibração

Choque em operação	30 g
Vibração aleatória	5 Hz - 500 Hz
Faixa de frequência de operação aleatória	0.3 g

Especificações físicas

Comprimento	25.4 cm
Largura	8.81 cm

Altura	5.89 cm
Altura	878 gram
Temperatura de operação	-20 °C - 55 °C
Altitude máxima	5000 m

Módulo NI 9234

Especificações gerais

Família de produtos	Industrial I / O
Tipo de medição	Accelerômetro Microfone
Form Factor	CompactDAQ CompactRIO
Sistema operacional / target	Real-Time Windows
Conformidade com RoHS	Sim

Entrada analógica

Canais single-ended	0
Canais diferenciais	4
Resolução da entrada analógica	24 bits
Faixa máxima de tensão	-5 V - 5 V
Amostragem simultânea	Sim
Corrente de excitação	2 mA
Faixa dinâmica	102 dB
Maximum Bandwidth	23.04 kHz
Impedância de entrada	305 kOhm
Condicionamento de sinais	Anti-aliasing filter Current excitation

Saída analógica

Quantidade de canais	0
----------------------	---

E / S digitais

Canais bidirecionais	0
Canais somente de entrada	0
Canais somente de saída	0

Contadores / temporizadores

Contadores	0
------------	---

Especificações físicas

Comprimento	9 cm
Largura	2.3 cm
Conector de E / S	BNC connectors
Temperatura de operação	-40 °C - 70 °C

Microfone Shure SM81

Tipo de Microfone:	Condensador (eletreto bias)
Resposta de Freqüência:	20 Hz a 20 kHz
Padrão Polar:	Cardióide (unidirecional)
Impedância:	150 Ohms (85 Ohms real)
Saída e Conector:	Saída balanceada com transformador acoplador Conector XLR macho profissional de 3 pinos.
Sensibilidade @ 1kHz (tensão de circuito aberto):	-45 dBV/Pa (5.6mV), 1 Pascal = 94dB SPL
Nível de Clipping @ 1kHz:	800 Ohm de carga: -4 dBV (0.63V) 150 Ohm de carga: -15dBV (0.18V)
THD:	Menor que 0.5% (131dB SPL @ 250 Hz em 800 Ohms de carga)
Máximo SPL @ 1kHz:	800 Ohm de carga: 136dB (atenuador em 0) 150 Ohm de carga: 128dB (atenuador em 0)
Captação de Hum:	-3dB equivalente em SPL em 1mOe (60Hz)

Nível de Ruído:	16dB típico, A-weighted 19dB típico, weighted por DIN 45 405
Relação Sinal-Ruído (94dB SPL @ 1kHz):	78dB (IEC 651) Essa relação é a diferença entre 94dB SPL e o nível de ruído SPL equivalente produzido pelo próprio circuito do microfone, A-weighted
Proteção de sobretensão e polaridade reversa:	Tensão máxima aplicada nos pinos 2 e 3 em relação ao pino 1: +52Vdc Proteção de polaridade reversa: 200mA máx
Polaridade:	Pressão positiva no diafragma produz tensão negativa no pino 2, em relação ao pino 3
Capacitância da Cápsula:	54 pF
Resposta de graves (conforme posição da chave):	Flat -6dB/oitava abaixo de 100Hz -18dB/oitava abaixo de 80Hz
Posições da chave atenuadora (com trava):	0dB ou -10dB
Alimentação:	Phantom Power necessário: 11 a 52Vdc, positivo nos pinos 2 e 3. Corrente: 1.2mA máx
Condições de Clima:	O microfone opera a temperaturas entre -6.7°C e 49°C. O microfone pode ser armazenado em temperaturas entre -29°C e 74°C. Umidade relativa: 0 a 95%
Corpo:	Corpo em metal resistente com acabamento na cor prata. Tela da cápsula em aço inoxidável.
Peso:	230g