



Universidade Federal
do Rio de Janeiro
Escola Politécnica

UTILIZAÇÃO DE CLASSIFICADOR *RANDOM FOREST* NA DETECÇÃO DE FALHAS EM MÁQUINAS ROTATIVAS

Guilherme Vieira Dantas

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 e Amaro Azevedo de Lima

Rio de Janeiro
Agosto de 2015

UTILIZAÇÃO DE CLASSIFICADOR *RANDOM FOREST* NA DETECÇÃO E PREVISÃO DE FALHAS EM MÁQUINAS ROTATIVAS

Guilherme Vieira Dantas

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:

Guilherme Vieira Dantas

Orientador:

Sergio Lima Netto, Ph. D.

Orientador:

Amaro Azevedo de Lima, Ph. D.

Examinador:

Eduardo Antônio Barros da Silva, Ph. D.

Examinador:

Thiago de Moura Prego, D. Sc.

Rio de Janeiro – RJ, Brasil

Agosto de 2015

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(s) autor(es).

DEDICATÓRIA

Aos meus pais Carlos e Selma pelo apoio incondicional, pela boa educação e por todos os momentos de dificuldades que atravessamos juntos com esperança, dedicação, sacrifícios e fé.

À minha tia Célia por todo apoio, carinho, compreensão e por toda a orientação profissional, pessoal e acadêmica recebida ao longo desses cinco anos e durante meus momentos de ensino médio.

À toda a minha família, sempre presente, aos meus avôs Dantas e João e às minhas avós Alzira e Jane. Às minhas madrinhas Mauriza e Vera e ao meu padrinho Darlan.

Aos meus grandes amigos do ensino médio, da eterna turma 201, com a qual compartilhei e com a qual compartilho experiências únicas.

Aos meus grandes conselheiros e tutores.

A todos, obrigado.

AGRADECIMENTOS

Agradeço fortemente ao professor Sérgio Lima Neto por toda a orientação e por me ter permitido participar deste projeto, que certamente ficará marcado como uma das mais valiosas experiências pelas quais passei na UFRJ.

Ao professor Amaro A. Lima, pela disponibilização do banco de dados e pelas sugestões de melhorias, fundamentais para a concretização do trabalho.

Aos amigos da INOVAX, pela sugestão de participar do excelente projeto coordenado por meus orientadores e pela experiência profissional que tive a oportunidade de ter logo após meu retorno ao Brasil.

Ao professor Carlos José Ribas d'Ávila, que exerce a função de coordenador do curso de Engenharia Eletrônica e de Computação com excelência e humanidade e que me acompanhou em cada passo de minha experiência na Universidade, sendo um exemplo e uma referência que tomarei para toda a minha vida profissional.

Ao professor Felipe Acker, que sempre me guiou nos caminhos da Matemática Aplicada e que me auxiliou muito na preparação para a experiência do Duplo-Diploma. As lições aprendidas nesse curso jamais serão esquecidas e ficarão guardadas para sempre em minha memória.

À professora Marie-Françoise El Fassi, por me permitir desfrutar da excelente experiência de estudo que tive na École Centrale de Lyon. Direcionando a mim e a todos os brasileiros com dedicação e carinho.

Ao amigo Thiago Valentin de Oliveira, com a qual tive o prazer de estudar e aprender na experiência da vida no Departamento de Engenharia Eletrônica.

À Natalia Glumenko, pela troca de experiências Brasil-Ucrânia, pelos ensinamentos e pelo *coaching* profissional e cultural e à toda equipe dos Jeunes Ambassadeurs de Rhône-Alpes. A meus amigos operários da SNCF, a Laurent-Blanc.

Aos professores do DEL, que me permitiram desfrutar de um estudo e de uma formação de excelência.

À banca examinadora, pelo convite aceito e pela avaliação do trabalho.

RESUMO

A questão da detecção de falhas em máquinas rotativas possui ampla relevância no contexto industrial: a predição de problemas passíveis de surgir em sistemas industriais permite o desenvolvimento de sistemas de manutenção preventiva que podem ser utilizados apenas diante de quadros realmente necessários e de forma econômica, ao evitar futuros prejuízos ligados a reparos e trocas de peças.

O presente trabalho propõe um sistema de previsão fundamentado no classificador do tipo *random forest* (árvores de decisão). O classificador utiliza um conjunto de parâmetros extraídos de sinais de vibração provenientes da máquina por meio de um conjunto de técnicas de processamento de sinais presentes na literatura tais como a transformada de Hilbert e a técnica da curtose espectral.

Palavras-Chave: *random forest*, árvores de decisão, máquinas rotativas, rotores, mancais de rolamento, desbalanceamento, desalinhamento, transformada de Hilbert, curtose espectral, manutenção preventiva.

ABSTRACT

Failure detection in rotating machines problem has a strong relevance in the industrial context: the prediction of future operation problems enables the development of predictive maintenance processes which are able to be used just in case of real necessity. This technique can assure an economical approach to the industries, reducing the potential costs of repairing the machinery.

The objective of this project is the development of a prediction system based on the random forest (random trees) classifier. The classifier receives and interprets an ensemble of parameters extracted from vibration signals generated by the machine with techniques of signal processing from the literature as the Hilbert transform and the spectral kurtosis.

Keywords: random forest, random trees, rotating machines, rotors, bearings, unbalance, alignment failure, Hilbert transform, spectral kurtosis, predictive maintenance.

SIGLAS

LEDAV – Laboratório de Ensaios Dinâmicos e Análises de Vibração

SMT – Laboratório de Sinais, Multimídia e Telecomunicações

P&D – Pesquisa e Desenvolvimento

Random forest – Classificador por árvores de decisão ou nós de decisão

Defeito A – Falha na gaiola do mancal de rolamento

Defeito B – Falha na pista externa do mancal de rolamento

Defeito C – Falha no elemento rolante do mancal de rolamento

ANC – Controle Ativo de Ruído (*Active Noise Control*)

AR – Auto regressão

FIR – Filtro de resposta ao impulso finita (*Finite Impulse Response filter*)

LMS – Mínimos quadrados (*Least Mean Square*)

RMS – Valor médio quadrático (*Root Mean Square*)

Sumário

Capítulo 1	1
Introdução	1
1.1 – Tema.....	1
1.2 – Delimitação.....	1
1.3 – Justificativa.....	2
1.4 – Objetivos.....	3
1.5 – Metodologia.....	3
1.6 – Descrição.....	4
Capítulo 2	6
Máquinas rotativas e mancais de rolamento	6
2.1 – Estrutura e funcionamento	6
2.2 – Tipos de defeitos em mancais de rolamento	8
2.3 – Desalinhamento	10
2.4 – Desbalanceamento.....	11
2.5 – Dispositivos utilizados na aquisição de dados.....	12
Capítulo 3	15
Pré-processamento do sinal	15
3.1 – Modelagem dos sinais.....	15
3.2 – Controle ativo de ruído	15
3.3 – Filtro auto regressivo.....	18
3.2 – Defeitos em mancais de rolamento	20
Capítulo 4	23
Extração de parâmetros das amostras	23
4.1 – Momentos de ordem superior	23
4.2 – Curtose espectral.....	24
4.3 – Transformada de Hilbert	27
Capítulo 5	34
Classificadores e Método <i>Random Forest</i>	34
5.1 – Conceito e validação cruzada	34
5.2 – Implementação dos conjuntos de treino e de teste	34
5.3 – <i>Random Forest</i> (Nós de decisão).....	36
Capítulo 6	39
Avaliação dos resultados finais	39

6.1 – Classificador de mancais individuais	40
6.1.1 – Mancais não invertido: percentuais de acertos.....	41
6.1.2 – Mancais invertido – Percentuais de acerto	44
6.1.3 – Avaliação geral e matrizes de confusão	46
6.1.4 – Frequências relativas aos erros de classificação	49
6.2 – Distinção de falhas nos mancais invertido ou não invertido	52
6.2.1 – Percentuais de acertos	52
6.2.2 – Avaliação geral e matrizes de confusão	56
6.2.3 – Frequências relativas aos erros de classificação	59
6.3 – Classificador universal – distinção entre falhas nos eixos e nos mancais de rolamento.....	60
6.3.1 – Percentuais de acerto obtidos.....	62
6.3.2. Avaliação geral e matrizes de confusão	67
6.3.3. Frequências relativas aos erros de classificação	70
Capítulo 7.....	72
Conclusões e melhorias futuras.....	72
Apêndice A.....	78
Algoritmo de curtose espectral utilizado.....	78

Lista de Figuras

1.1 – Percentual de falhas em máquinas rotativas	2
2.1 – Estrutura básica: mancal e eixo de rotação	7
2.2 – Simulador de falhas de máquina rotativa utilizado	9
2.3 – Estrutura interna de um mancal de rolamento	9
2.4 – Par de mancais de rolamento analisados	10
2.5 – Tipos de desalinhamento	11
2.6 – Indução do desbalanceamento no rotor	13
2.6 – Sistema de medição utilizado	16
3.1 – Filtro ANC – LMS	17
3.2 – Efeito da aplicação do filtro ANC no domínio do tempo	18
3.3 – Efeito da aplicação do filtro ANC no domínio da frequência	19
3.4 – Efeito da aplicação do filtro AR no domínio do tempo	20
3.5 – Efeito da aplicação do filtro AR no domínio da frequência	21
3.6 – Padrão de sinais de defeitos de mancais de rolamento	25
4.1 – Ilustração do procedimento para determinação da curtose espectral	26
4.2 – Curtose espectral – Defeito A – 13,2 Hz	28
4.3 – Sinal pré-processado – Defeito A – 13,2 Hz – Antes e após filtragem	29
4.4 – Comparação entre o sinal filtrado antes e depois da transformada de Hilbert	30
4.5 – Sinal pré-processado, filtrado e demodulado obtido	31

5.1 – Ilustração do procedimento de validação cruzada de 3 <i> folds</i>	36
5.2 – Criação da árvore de decisão	37
5.3 – Etapas do projeto	38
6.1 – Percentual de acertos – SET1, SET2 e SET3 – Mancal não invertido	41
6.2 – Acertos (%) – Mancal não invertido – Com e sem variáveis empíricas	43
6.3 – Percentual de acertos – SET1, SET2 e SET3 – Mancal invertido	44
6.4 – Acertos (%) – Mancal invertido – Com e sem variáveis empíricas	45
6.5 – Score encontrado para os quatro casos	47
6.6 – Histogramas com erros obtidos pelo classificador para cada mancal	50
6.7 – Acertos (%) –Análise conjunta de mancais	53
6.8 – Acertos médios - mancais conjuntos (%) – Sem variáveis empíricas	54
6.9 – Acertos médios - mancais conjuntos (%) – Com variáveis empíricas	55
6.10 – Score para cada um dos dois classificadores – dois mancais	57
6.11 – Histogramas com erros obtidos para os dois classificadores	59
6.12 – Acertos (%) – Classificador universal – mancais de rolamento – Sem variáveis empíricas	62
6.13 – Acertos (%) – Classificador universal – mancais de rolamento – Com variáveis empíricas	63
6.14 – Acertos (%) – Classificador universal – Desalinhamento e desbalanceamento	65
6.15 – Acertos médios – Com variáveis empíricas	66
6.16 – <i>Score</i> do classificador universal	67

Lista de Tabelas

2.1 – Medições de defeitos realizadas	14
3.1 – Dimensões do rolamento utilizado no experimento	21
3.2 – Cálculo das frequências características de defeitos em mancais	22
6.1 – Percentual de acertos – Média entre conjuntos – Mancais não invertido	43
6.2 – Percentual de acertos – Média entre conjuntos – Mancais invertido	46
6.3 – Número de árvores dos classificadores com melhor score	48
6.4 – Matrizes de confusão para classificador de mancais individuais	48
6.5 – Matrizes de confusão para classificador de mancais conjuntos	58
6.6 – Matriz de confusão para classificador universal	69

Capítulo 1

Introdução

1.1 – Tema

O presente trabalho objetiva detectar falhas em máquinas rotativas por meio da análise de vibrações obtidas a partir de um simulador de falha de máquina presente no LEDAV (Laboratório de Ensaio Dinâmico e Análise de Vibração). O projeto é realizado conjuntamente com o SMT (Laboratório de Sinais, Multimídia e Telecomunicações).

A predição de falhas é realizada em duas grandes etapas. A primeira delas consiste na extração de parâmetros fortemente ligados aos diferentes defeitos que buscamos detectar. Em seguida, os parâmetros extraídos são organizados em um vetor de falhas que, ao treinar o sistema de classificação, poderá fornecer resultados significativos quanto à problemática em análise. Conforme mencionaremos mais adiante, as principais referências do projeto se encontram em [1] e em [2].

1.2 – Delimitação

Contemporaneamente, grandes indústrias emergem em um contínuo contexto de inovação e crescimento centradas no objetivo de inserção em um mercado progressivamente mais competitivo e em um panorama mercadológico cumulativamente mais violento. Neste contexto, desperdícios e perdas de recursos tornam-se cada vez mais inaceitáveis para o desenvolvimento salutar das empresas.

Conseqüentemente, esta crescente busca por melhorias tem permitido uma produção de valores econômicos e sociais cada vez maior para a sociedade em geral. No entanto, esforços para a inovação de produtos e processos têm se tornado cada vez mais estratégicos. Tal fato justifica a crescente importância dos esforços em P&D que devem ser engajados em vínculos cada vez mais tênues entre empresas e centros de pesquisa de universidades.

Dentro dessa realidade, perdas e prejuízos financeiros ligados ao mal funcionamento de máquinas e, em especial, de mancais de rolamento tornam-se cada vez menos suportáveis. Logo, esforços na predição de problemas mecânicos em tais peças devem ser dispendidos no intento de gerar não apenas inovação nas esferas empresariais como também aumentar o desenvolvimento da comunidade em geral. Podemos observar na figura 1.1 a alta incidência de problemas ligados a mancais de rolamento no meio industrial, conforme indicado em [3]. Um estudo aprofundado e específico das causas de falhas de mancais de rolamentos pode ser conferido em [4] e em [5].

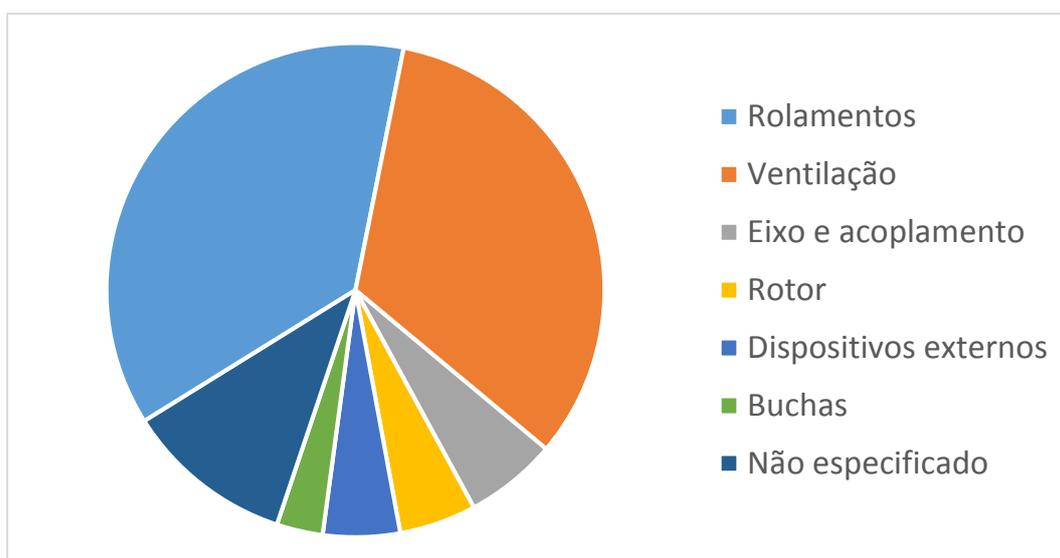


Figura 1.1. Percentuais de falhas em máquinas rotativas. Fonte: [3].

1.3 – Justificativa

Os eixos e os mancais de rolamento são peças críticas que são utilizadas nas mais diferentes máquinas rotativas, com os mais distintos objetivos. Tais tipos de máquinas são importantes não apenas nos processos de conversão de energia elétrica em energia mecânica e vice-versa como também na transferência de movimentos mecânicos em geral.

Os eixos de rotação de máquinas rotativas são sustentados pelos mancais. Em máquinas que operam em altas frequências de rotação, utilizam-se mancais de rolamento: a vantagem destas peças se encontra na possibilidade de se reduzirem influências do atrito, o que possibilita um aumento no tempo de vida das máquinas rotativas e uma redução em perdas de energia.

No entanto, mancais de rolamento são peças complexas, divididas em várias partes distintas, o que as torna extremamente vulneráveis a defeitos quando operam continuamente. Por isso tais sistemas são tidos como verdadeiros gargalos no que diz respeito à análise de risco dos diferentes componentes de diversas plantas industriais.

As primeiras análises são, conseqüentemente, realizadas nos mancais de rolamento do simulador de falha de máquina estudado e, posteriormente, analisa-se brevemente o problema da detecção de falhas no alinhamento e no balanceamento do eixo.

Assim, o presente trabalho interessa a praticamente todas as indústrias que se utilizam de sistemas mecânicos tais como indústrias de transformação. Podemos afirmar que virtualmente todos esses tipos de indústria utilizam, em algum processo, uma máquina rotativa, fato que justifica a realização de esforços no que concerne ao estudo de técnicas de manutenção preditiva nas mesmas.

1.4 – Objetivos

O objetivo principal do projeto é a obtenção de classificadores capazes de diagnosticar falhas em mancais de rolamento com o máximo de rapidez logo após o surgimento de algum tipo de defeito. Para isso, tais classificadores devem possuir altas taxas de acertos bem como uma considerável robustez (sensibilidade na medida) com relação às informações extraídas do sinal de vibração detectado e utilizadas pelos classificadores.

Num primeiro momento, analisa-se as falhas em mancais de rolamento isoladamente e, num segundo momento, desenvolve-se um classificador capaz de diagnosticar tanto falhas em mancais de rolamento quanto falhas relativas ao eixo do rotor (classificador universal).

1.5 – Metodologia

Conforme já exposto, o projeto se divide em duas grandes etapas: a extração de parâmetros do sinal que estejam amplamente associados aos possíveis defeitos que iremos

analisar e o desenvolvimento do classificador utilizado no processamento dos parâmetros e na obtenção dos resultados.

1. A primeira etapa consiste em:
 - 1.1. Analisar o processo de medida de vibrações e os parâmetros dos dispositivos utilizados em tal medida tais como a frequência amostragem, o número de sinais coletados e o tempo de total de aquisição do sinal.
 - 1.2. Filtrar o sinal obtido, retirando do mesmo componentes nocivos à análise e à detecção de defeitos.
 - 1.3. Extrair do sinal refinado os parâmetros de entrada do classificador.
2. Na segunda etapa realizam-se os seguintes procedimentos:
 - 2.1. Extrair os parâmetros obtidos para cada medição e dividir as amostras em conjuntos de treino e de teste.
 - 2.2. Criar o classificador e realizar o treino e o teste do mesmo.
 - 2.3. Interpretar o resultado e dele obter conclusões.

As bases principais do projeto realizado são, além de outras demonstradas nas diversas referências bibliográficas citadas ao longo deste trabalho, obtidas em [1], que possui informações valiosas no que diz respeito ao uso de classificadores e à detecção de problemas de desalinhamento e desbalanceamento e em [2], que possui informações sobre a análise mais complexa que deve ser realizada nos mancais de rolamento e no pré-processamento que deve ser realizado no sinal antes de se recorrer ao classificador.

1.6 – Descrição

No capítulo 2, o protótipo utilizado será apresentado e, a partir do mesmo, especificaremos:

1. A estrutura básica do sistema em análise e seus componentes.
2. Os tipos de defeitos em máquinas rotativas que serão analisados e a forma com a qual tais defeitos foram induzidos no protótipo.

3. Os dispositivos utilizados na aquisição dos sinais de vibração, o processo e os parâmetros de aquisição de dados.

No capítulo 3, o procedimento de eliminação dos componentes do sinal que não são úteis na análise é exposto em duas etapas: primeiramente, tais componentes são isolados a partir da modelagem do sinal. Em seguida, os métodos utilizados na eliminação de tais componentes é realizado.

No capítulo 4, as técnicas de extração de parâmetros dos sinais filtrados são apresentadas e realizadas.

No capítulo 5, o classificador *random forest* é apresentado juntamente com a técnica utilizada na separação de conjuntos de treino e de teste que serão utilizados.

No capítulo 6, os resultados finais obtidos são apresentados e discutidos, apurando-se as vantagens e as desvantagens do procedimento realizado.

No capítulo 7, as conclusões e as possíveis melhorias que podem ser realizadas em projetos futuros são apresentadas.

Capítulo 2

Máquinas rotativas e mancais de rolamento

2.1 – Estrutura e funcionamento

Diferentes máquinas rotativas podem ser utilizadas nas mais diversas finalidades tais como:

- Sistemas de conversão eletromecânica de energia.
- Eixos de veículos aéreos e terrestres.
- Sistemas de conversão de movimentos mecânicos.

A manutenção preditiva de máquinas rotativas é mais custosa nos casos em que altas frequências de rotação estão envolvidas. Nesses casos, o sistema mecânico utilizado é dividido em duas partes básicas, conforme exposto na figura 2.1.

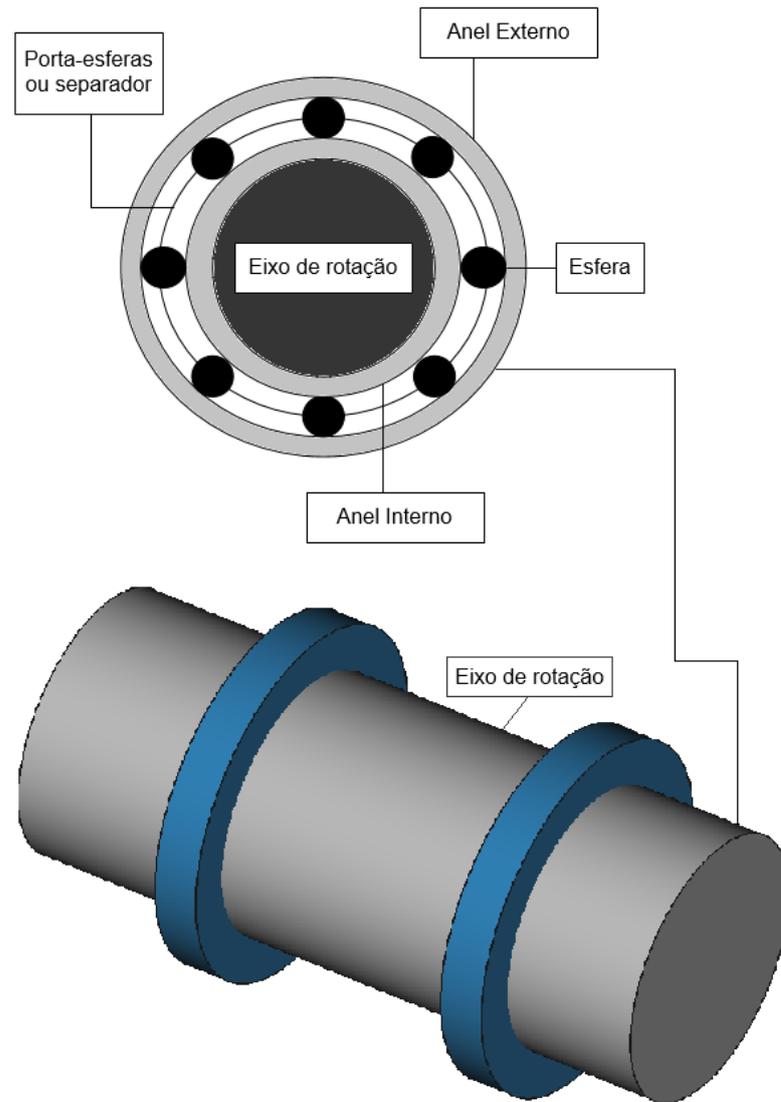


Figura 2.1. Estrutura básica: mancal e eixo de rotação.

Podemos observar que o mancal de rolamento possui uma estrutura extremamente complexa em relação ao restante do sistema, o que justifica o fato de tais componentes se encontrarem entre aqueles passíveis à incidência mais frequente de defeitos. Além disso, a modelagem dos sinais de defeitos oriundos de tal peça também possui uma maior complexidade.

A máquina rotativa utilizada como simulador de falha de máquina e os componentes da mesma são exibidos na figura 2.2:

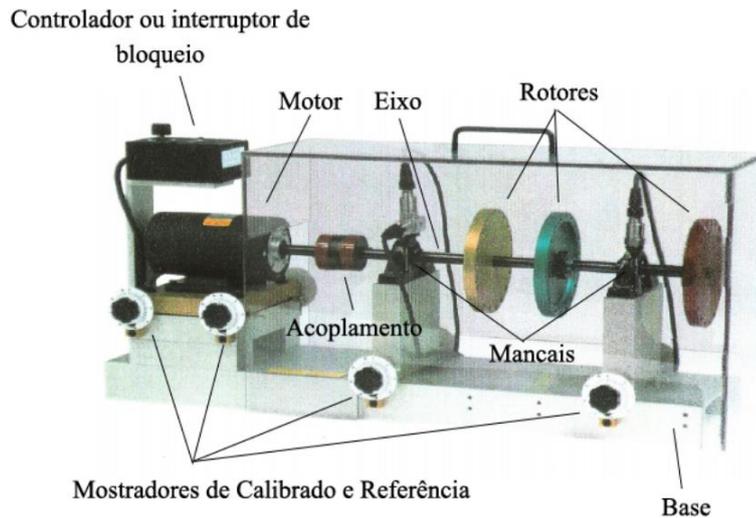


Figura 2.2. Simulador de falha de máquina rotativa utilizado. Fonte: [1].

O procedimento experimental foi integralmente realizado em [1] e, por isso, as informações relativas aos dispositivos utilizados e aos parâmetros de medição foram extraídos integralmente dessa fonte.

2.2 – Tipos de defeitos em mancais de rolamento

Primeiramente, apresentamos os defeitos mais críticos na análise realizada - os defeitos potenciais nos mancais de rolamento. Tais defeitos são gerados devido a desgastes que se propagam nos mancais de rolamento em quatro regiões distintas segundo [2]:

- Defeitos na gaiola
- Defeitos na pista externa
- Defeitos na pista interna
- Defeitos no elemento rolante

As regiões nas quais as falhas são analisadas, nos mancais de rolamentos, são expostas na figura 2.3.

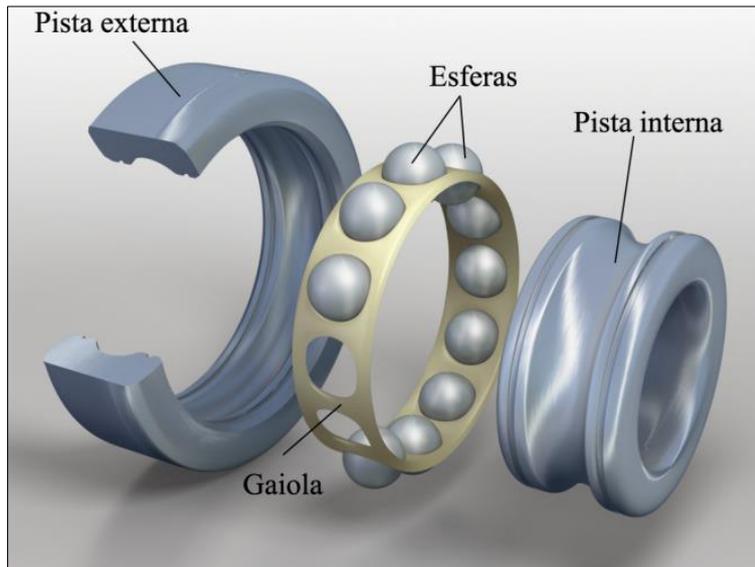


Figura 2.3. Estrutura interna de um mancal de rolamento.

Desses defeitos, três tipos foram coletados: os defeitos na gaiola (defeitos de tipo A ou simplesmente “defeito A” – essa nomenclatura será utilizada no presente projeto), os defeitos na pista externa (defeito B) e os defeitos no elemento rolante (defeito C) para cada um dos dois mancais de rolamento presentes na montagem *exibida* na figura 2.3.

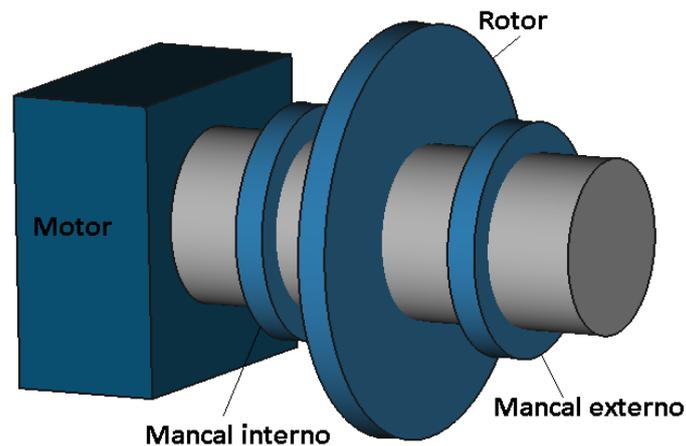


Figura 2.4. Par de mancais de rolamento analisados.

Assim, no presente projeto e a título de referência, o mancal mais próximo do motor do protótipo (mancal interno) será definido como o mancal não invertido e o mancal mais distante do mesmo (mancal externo) será definido como o mancal invertido (essa nomenclatura também será utilizada no decorrer do projeto).

Além disso, podemos notar que, na montagem, os rotores se encontram entre o par de mancais. Tal disposição de componentes é denominada *center-hung*. Também é

possível utilizar-se a disposição do tipo *over-hung*, amplamente utilizada na indústria do petróleo, na qual o rotor se encontra na extremidade mais próxima ao mancal externo [1].

Na seção 3.1, a modelagem dos componentes de vibração referentes a cada um dos três tipos de defeitos presentes na base de dados utilizada é explorada. A indução experimental de defeitos é realizada de forma direta, substituindo-se elementos do sistema mecânico por peças defeituosas.

2.3 – Desalinhamento

Podem ser de dois tipos básicos no caso do presente projeto: o desalinhamento se divide, para os sinais coletados, em desalinhamento vertical e desalinhamento horizontal. Outras situações tais como o desalinhamento angular são possíveis mas não serão consideradas no trabalho realizado.

A classificação do tipo de desalinhamento ocorre segundo o seguinte critério: tomamos a linha normal aos eixos de cada uma das duas metades do sistema segundo a figura 2.4. Se tal linha for perpendicular ao solo (eixo XY) então o desalinhamento é vertical. No caso onde tal linha é paralela ao plano do solo temos o caso de falha horizontal. A direção do desalinhamento é relevante e gera diferentes resultados devido aos diferentes ângulos entre o eixo de desalinhamento e o vetor de aceleração da gravidade.

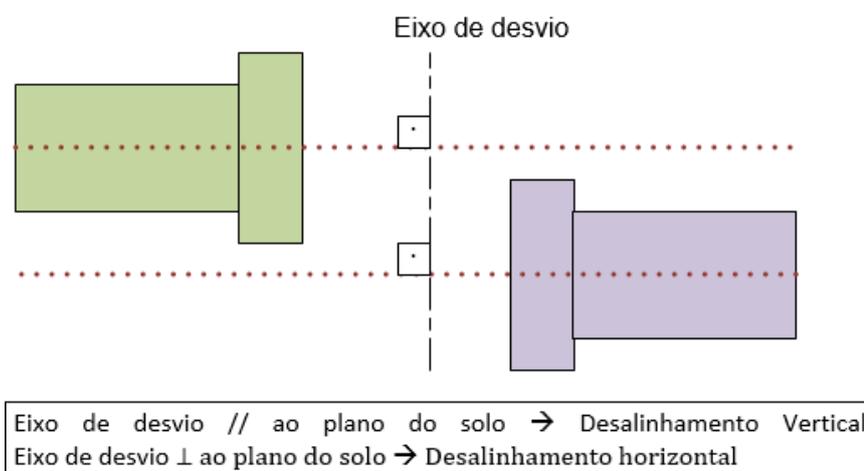


Figura 2.5. Tipos de desalinhamento.

Além disso, podemos notar que o desalinhamento só é possível em montagens do tipo *center-hung*, que são as utilizadas no simulador de falhas implementado em [1]. Nesse caso, cada eixo é ligado por uma de suas extremidades ao rotor central e o desvio gera o desalinhamento.

Para o caso vertical são obtidos os dados relativos às distâncias de: 0,51 mm, 0,63 mm, 1,27 mm, 1,4 mm, 1,78 mm e 1,9 mm. Já para o desalinhamento horizontal, obtém-se dados relativos às seguintes distâncias: 0,5 mm, 1,5 mm, 1 mm e 2 mm. Maiores detalhes sobre as induções experimentais de cada um dos defeitos podem ser obtidas em [1].

2.4 – Desbalanceamento

Em operação normal, o rotor possui uma simetria axial virtualmente perfeita. No entanto, existem casos nos quais a operação da máquina pode desbalancear o peso com a adesão de um corpo estranho sobre o rotor. Trata-se do defeito de desbalanceamento.

O rotor utilizado em [1] possui espaços para a inserção de parafusos nas regiões próximas às extremidades. A alteração do momento de inércia do componente altera o padrão da vibração medida (conforme será demonstrado no capítulo 3). A figura 2.5 demonstra a montagem experimental utilizada na indução do defeito de desbalanceamento.

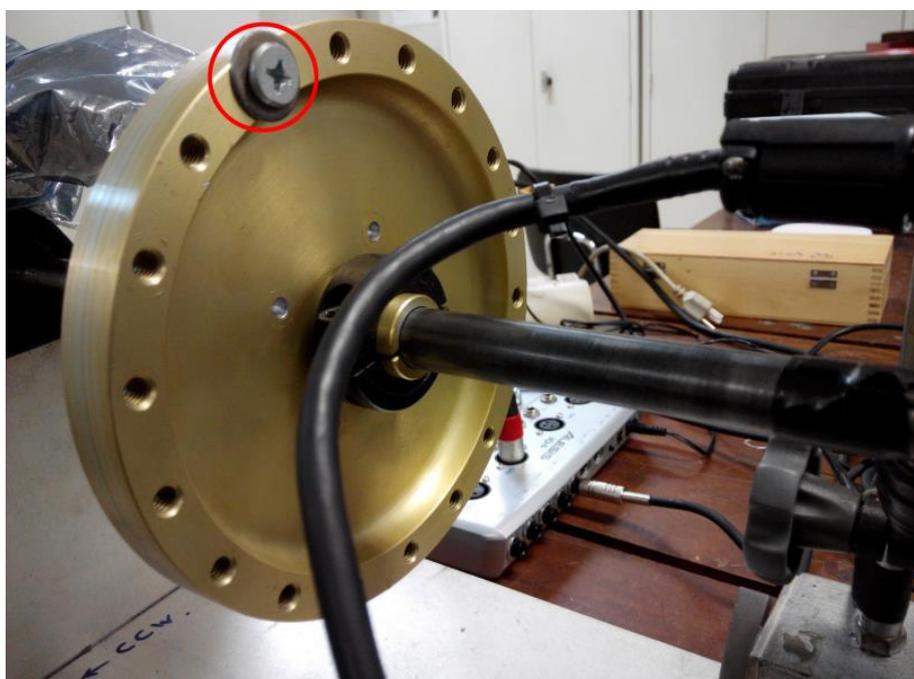


Figura 2.6. Indução do desbalanceamento no rotor. Fonte: [1].

A região envolvida em vermelho na figura 2.5 demonstra o parafuso utilizado no desbalanceamento. As massas acrescentadas em cada experimento nesse caso possuem os valores de 6 g, 10 g, 15 g, 20 g, 25 g, 30 g e 35 g.

2.5 – Dispositivos utilizados na aquisição de dados

Informações mais específicas sobre os dispositivos utilizados podem ser obtidas em [1]. A aquisição de dados foi possibilitada, resumidamente, por meio dos seguintes dispositivos:

- Microfone Shure SM81: Não utilizado no contexto deste projeto.
- Tacômetro: Permite a medição da frequência de rotação do eixo.
- Acelerômetros: Dispostos nos eixos axial, radial e tangencial da figura 2.6, permitem a medição dos sinais de vibrações em cada uma dessas direções. São os sinais obtidos a partir deste dispositivo que serão utilizados na análise proposta.

A montagem completa dos dispositivos de medição é exibida na figura 2.6.

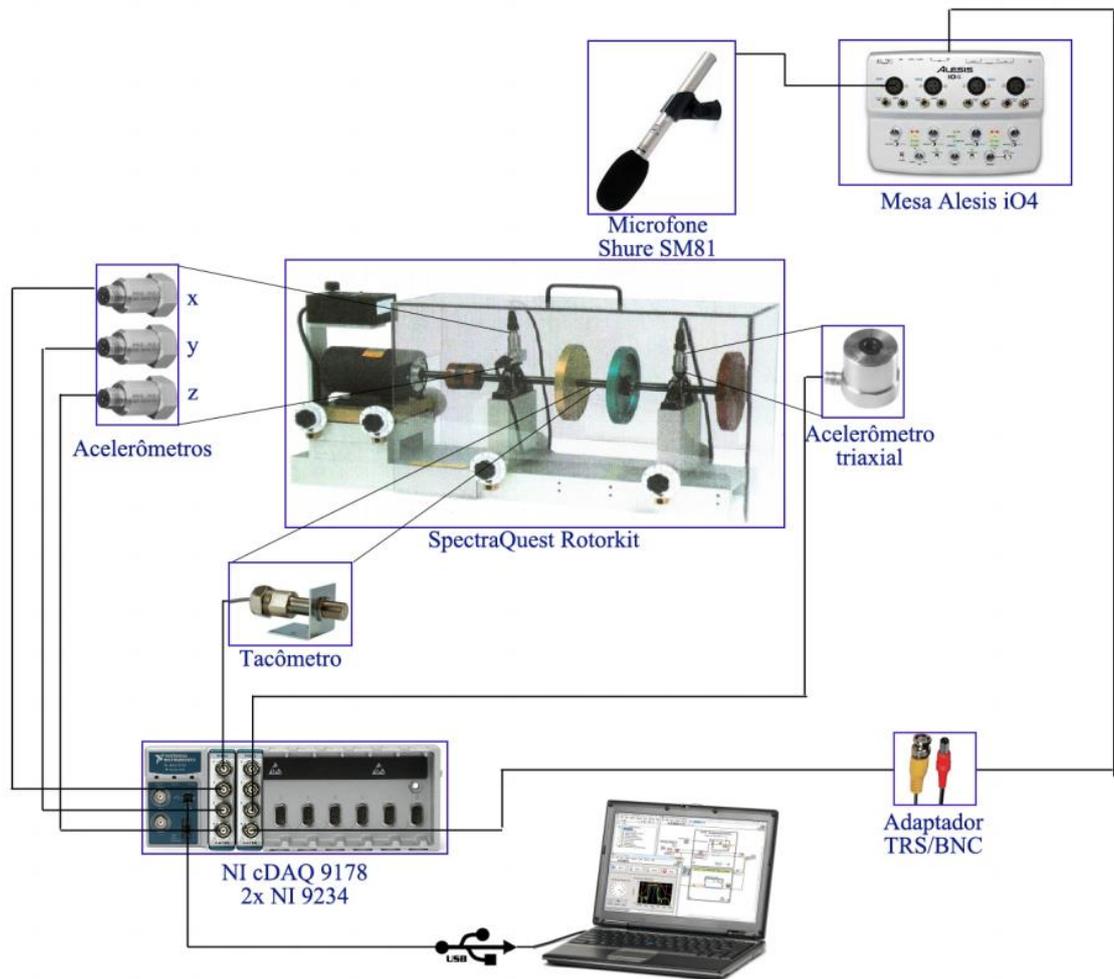


Figura 2.7. Sistema de medição utilizado. Fonte: [1].

As medições foram realizadas dentro das seguintes características:

- Frequência de amostragem: 50 kHz
- Número de amostras por sinal: 250.000 (5 segundos de medição)
- 50 sinais medidos para frequências de rotação do rotor:
 - Distribuídas uniformemente entre 10 Hz e 60 Hz.
 - Frequências analisadas detalhadas em [1].
- Esse número de sinais é coletado para cada um dos casos (incluindo o caso no qual não há nenhum defeito induzido na montagem), sintetizados na tabela 2.1 (o número exato de sinais e os valores específicos utilizados e disponibilizados na base de dados podem ser consultados de forma completa e detalhada em [1]).

Tabela 2.1. Medições de defeitos realizadas.

Normal		
Mancal	Defeito A	Invertido
		Não Invertido
	Defeito B	Invertido
		Não Invertido
	Defeito C	Invertido
		Não Invertido
Desalinhamento	Vertical	0.51 mm
		0.63 mm
		1.27 mm
		1.4 mm
		1.78 mm
		1.9 mm
	Horizontal	0.5 mm
		1.5 mm
		1 mm
		2 mm
Desbalanceamento	6 g	
	10 g	
	15 g	
	20 g	
	25 g	
	30 g	
	35 g	

Capítulo 3

Pré-processamento do sinal

Após a obtenção dos sinais de vibração, é necessário que se elimine os componentes ruidosos e desprezíveis em nossa análise por meio de um conjunto de técnicas de pré-processamento que serão aqui expostas. Para isso, primeiramente, deve-se modelar os componentes a serem eliminados, procedimento que será realizado na próxima subseção. Os algoritmos realizados neste projeto foram desenvolvidos por meio da plataforma MATLAB.

3.1 – Modelagem dos sinais

Os sinais medidos consistem em uma adição de componentes oriundos de diferentes origens. Primeiramente, podemos dividir o sinal X_{MEDIDO} em três partes principais:

- X_{NOISE} → Trata-se da componente formada pelos ruídos ambientes, que será, nesta etapa, eliminado primeiramente por meio de um filtro de controle ativo de ruído (filtro ANC – *active noise control*).
- $X_{\text{DETERMINÍSTICO}}$ → Trata-se da parte determinística do sinal, que será eliminada em seguida. Esta componente é formada pelas vibrações do sinal que são sempre obtidas, haja defeitos ou não e pode ser atenuada por meio de um algoritmo de auto regressão (filtro AR).
- $X_{\text{ALEATÓRIO}}$ → O sinal remanescente após as duas etapas de pré-processamento é de natureza estocástica pois as falhas que devem ser analisadas geram componentes não determinísticas. Os dois processos de filtragem utilizados serão especificados na subseção seguinte.

3.2 – Controle ativo de ruído

O algoritmo de controle ativo de ruído recebe como entrada dois sinais distintos: o sinal a se filtrar e um sinal de referência, que possui componentes que se quer eliminar do sinal. Por meio da diferença entre os dois sinais fornecidos, pode-se realizar um algoritmo que altera o filtro de forma a fazê-lo se aproximar continuamente da solução ótima durante o funcionamento da máquina. Assim, o filtro processa apenas informações relativas a instantes passados, de onde podemos concluir que esse tipo de sistema permite que simulemos um sistema causal.

Mais especificamente, a implementação da técnica foi realizada por meio do algoritmo LMS (*least mean squares filter*). A partir da figura 3.1 podemos especificar o funcionamento do mesmo com mais detalhes.

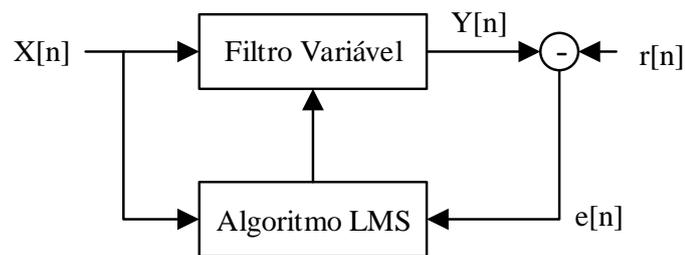


Figura 3.1. Filtro ANC – LMS.

O sinal de entrada $X[n]$ é aplicado a um filtro de resposta ao impulso finita cujos coeficientes são variáveis em função do sinal de erro $e[n]$, formado pela diferença entre a saída anterior $Y[n-1]$ e o sinal de referência $r[n]$. O sinal X é composto por um sinal com algum dos defeitos descritos anteriormente e o sinal de referência é composto pelo sinal medido sem a indução de nenhuma das falhas possíveis cuja frequência de rotação do rotor é a mais próxima da frequência de rotação do rotor em X .

Ou seja, para cada sinal defeituoso X utilizado, o algoritmo desenvolvido busca, entre os sinais da máquina sem indução de defeitos, aquele mais próximo de uma “versão não defeituosa” de X , buscando minimizar o desvio de frequências entre $X[n]$ e $r[n]$ medidas pelo tacômetro. Ou seja, procura-se, dentre os sinais nos quais a máquina opera sem defeitos, aquele cuja frequência medida pelo tacômetro é mais próxima daquela medida para o sinal X em análise.

A cada iteração os coeficientes h_1, h_2, \dots, h_N do filtro variável FIR (filtro de resposta finita ao impulso) são atualizados por meio da seguinte equação: $h_k[n + 1] = h_k[n] + \mu X[n].e[n]$, para cada valor de k entre 1 e N , inclusive – onde N é a ordem do filtro. Pode-se demonstrar que essa abordagem minimiza o erro quadrático obtido em $e[n]$. Assim,

dois parâmetros devem ser fornecidos a esse filtro: o valor de μ e a ordem N do filtro FIR. Durante a execução do algoritmo, a saída do filtro $Y[n]$ converge ao sinal livre de ruídos que utilizaremos no restante da análise.

O parâmetro μ deve ser fornecido de forma a garantir uma convergência adequada ao sistema: se o seu valor for elevado, o vetor de pesos do filtro FIR sofre grandes alterações a cada iteração, a convergência é acelerada mas o ponto ótimo é encontrado com menor acurácia.

Inversamente, se μ for excessivamente pequeno, a convergência torna-se lenta apesar da alta acurácia na determinação do filtro ótimo. Observou-se um funcionamento adequado do algoritmo para uma ordem $N = 11$ e para $\mu = 0,05$.

Podemos interpretar a dinâmica do filtro ANC da seguinte forma: um vetor formado pelos coeficientes do filtro FIR se atualiza a cada iteração na direção do gradiente do erro, em um sentido que visa minimizá-lo. Assim, μ regula o comprimento do passo dado na direção do gradiente a cada etapa do algoritmo.

Observemos que o sinal de referência fornecido é o sinal coletado sem nenhuma indução de defeito. Logo, eliminamos nesta etapa tanto as componentes ruidosas do ambiente quanto as componentes determinísticas ligadas à operação normal do sistema, conforme podemos notar no exemplo obtido para um sinal com defeito de classe A sob uma frequência de rotação de 13,3 Hz (figuras 3.2 e 3.3).

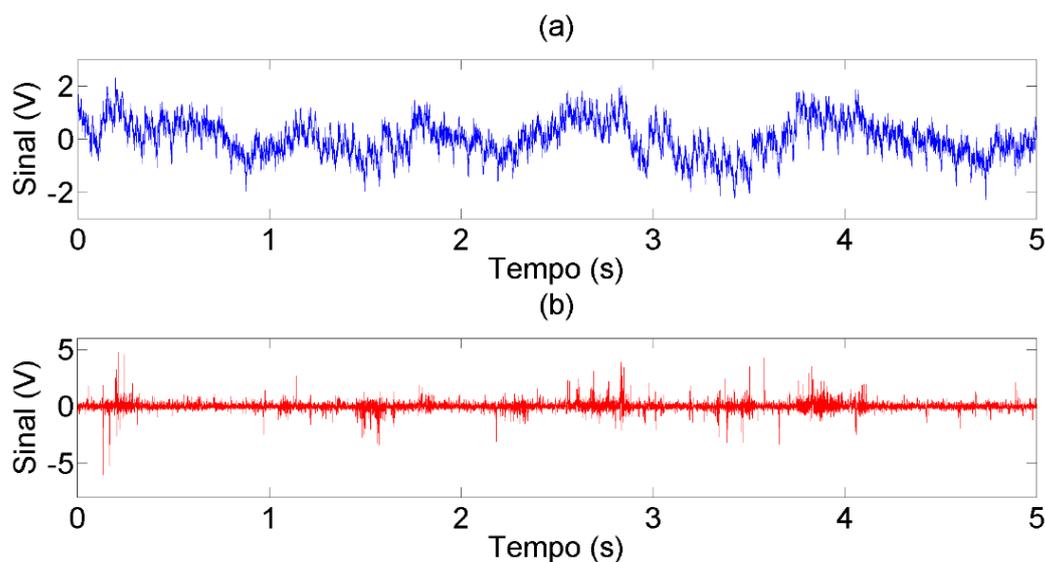


Figura 3.2. Efeito da aplicação do filtro ANC no domínio do tempo.
(a) Entrada – Defeito A – 13,3 Hz – Sensor radial – Mancal não invertido.
(b) Saída após aplicação do filtro ANC correspondente.

No domínio do tempo, podemos observar qualitativamente o efeito de se utilizar o sinal normal total (e não apenas o ruído ambiente) no sinal de referência: componentes de oscilação regulares são eliminadas e, na saída, obtemos um sinal mais irregular e livre dos sinais gerados pela operação rotineira do sinal (não foram testados casos em que apenas o ruído ambiente representasse o sinal de referência devido ao interesse de se eliminar, juntamente com os termos ruidosos do sinal, os elementos determinísticos do mesmo). Este efeito pode também ser observado no domínio da frequência (figura 3.3).

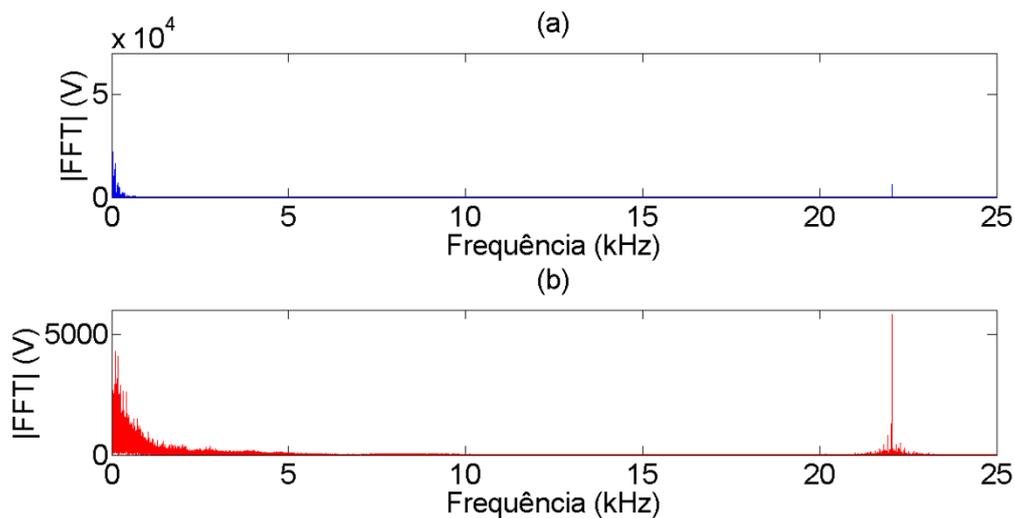


Figura 3.3. Efeito da aplicação do filtro ANC no domínio da frequência.
(a) Espectro da entrada – Defeito A – 13,3 Hz – Sensor radial – Mancal não invertido.
(b) Espectro da saída após aplicação do filtro ANC correspondente.

No domínio de Fourier, podemos notar o efeito do realce de um componente em alta frequência – o pequeno pico localizado em 22,3 kHz é evidenciado e o espectro é atenuado nos arredores das frequências normais de operação da máquina (frequências mais baixas, entre 0 e 5 kHz).

3.3 – Filtro auto regressivo

Conforme especificado, durante a etapa de utilização do filtro ANC, parte do sinal determinístico foi eliminada conforme verificado nos resultados. O filtro AR reitera esse tratamento, eliminando os componentes determinísticos remanescentes do sinal obtido no filtro ANC.

Tal operação, é realizada por meio de um algoritmo de regressão linear aplicado ao sinal em questão. Se a ordem deste filtro é N , a aplicação contínua da equação linear

encontrada a partir das N primeiras amostras do sinal permite a obtenção de um sinal ideal, previsto pelo modelo calculado. Esse modelo representa um componente determinístico do sinal de entrada: trata-se do componente que pode ser deterministicamente previsto por meio de um modelo regressivo.

Assim, o efeito desta etapa é restringir ainda mais o sinal às suas componentes efetivamente ligadas às falhas não determinísticas. Em [2], a ordem proposta para esse tipo de filtro é $N = 4$ e é esse valor que será utilizado no presente projeto. Os efeitos da aplicação desse algoritmo na saída do filtro LMS do defeito A sob uma frequência de $13,3 \text{ Hz}$ (exibido na etapa anterior) é demonstrado no domínio do tempo e da frequência nas figuras 3.4 e 3.5.

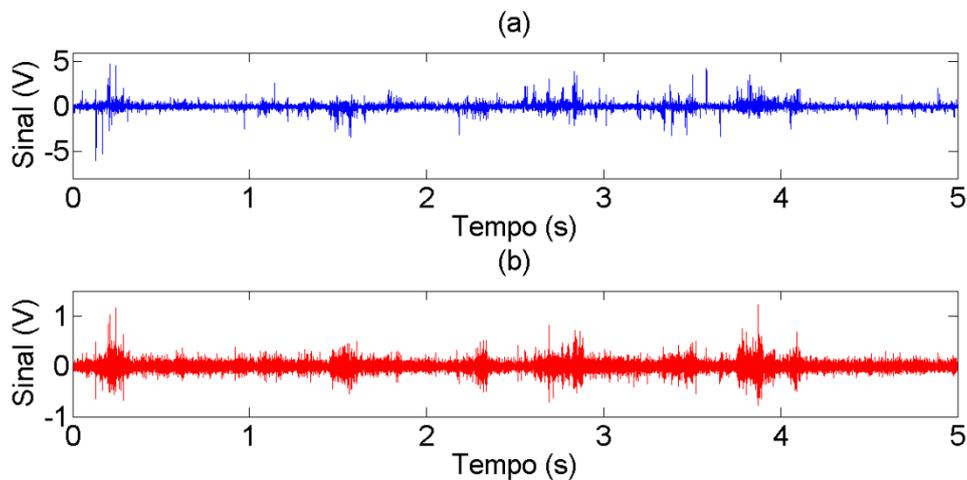


Figura 3.4. Efeito da aplicação do filtro AR no domínio do tempo.
(a) Saída do filtro ANC – Sinal 13,3 Hz – Defeito A – Sensor radial – Mancal não invertido.
(b) Saída do filtro AR aplicado em (a).

Observa-se, novamente, que a aplicação do filtro tendeu a uniformizar o sinal, destacando componentes ruidosos mais relacionados aos defeitos induzidos durante a aquisição da amostra. Este resultado é reiterado quando observamos o efeito do filtro no domínio da frequência (figura 3.5).

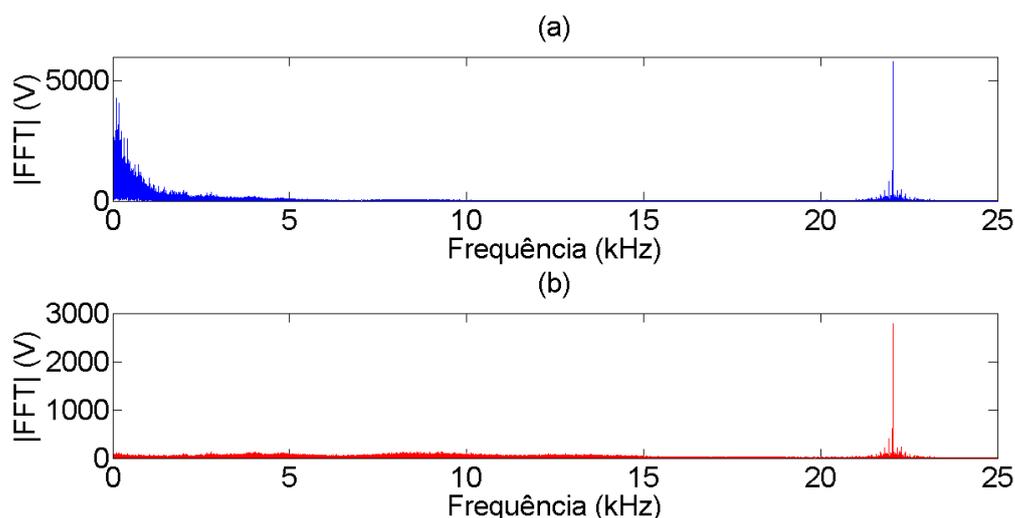


Figura 3.5. Efeito da aplicação do filtro AR no domínio da frequência
(a) Espectro saída do filtro ANC – Sinal 13,3 Hz – Defeito A – Sensor radial – Mancal não invertido.
(b) Espectro da saída do filtro AR aplicado em (a).

O pico de maior frequência (em torno de 22 kHz) ligado aos componentes não determinísticos e destacado na etapa anterior permanece presente enquanto os componentes de menores frequências, ligados aos fatores determinísticos da amostra coletada, são eliminados. Assim, observamos que os componentes determinísticos possuem menores frequências e componentes ligados a defeitos e ruídos tendem a possuir maiores frequências por serem mais irregulares.

3.4 – Defeitos em mancais de rolamento

Em [1], nenhuma modelagem específica para defeitos ligados ao eixo foi necessária e uma extração direta de parâmetros a partir do sinal original foi suficiente para a obtenção de acertos de predição na ordem de 90%. Assim, nem mesmo as etapas de filtragem expostas precisam ser utilizadas nesse caso. Porém, em [2], observamos que uma modelagem ainda mais minuciosa deve ser realizada nos sinais de defeitos ligados aos mancais de rolamento. Cada tipo diferente de defeito produz um padrão de sinal distinto durante a etapa de extração de parâmetros para o classificador.

Basicamente, quando um defeito surge em alguma região do mancal de rolamento (pista externa, pista interna ou esfera), um pico surge no sinal coletado em frequências

que podem ser teoricamente previstas por meio de conceitos de dinâmica. Uma ilustração resumida do processo é ilustrada na figura 3.6.

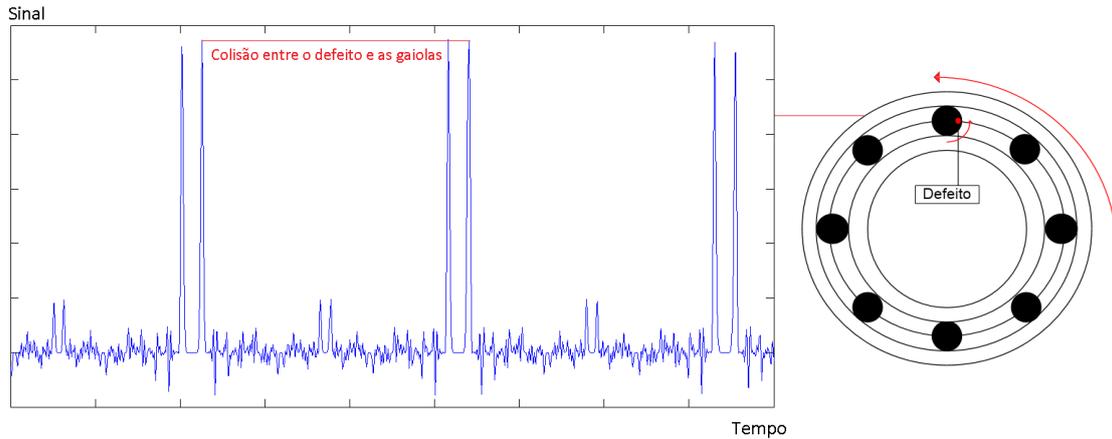


Figura 3.6. Padrão de sinais de defeitos de mancais de rolamento.

Na figura 3.6, exemplificamos o caso onde existe um defeito em uma das esferas. Claramente, cada defeito gera picos distanciados entre si de T_X no domínio do tempo e, conseqüentemente, distanciados no domínio da frequência em $f_X = T_X^{-1}$ (a transformada de Fourier de um trem de impulsos é um outro trem de impulsos e podemos utilizar a aproximação desse conceito para tomar tal conclusão). O cálculo da frequência característica para cada falha possível é demonstrado analiticamente em [3] a partir dos seguintes parâmetros:

Variável	Descrição	Valor nos experimentos
D	Diâmetro da esfera	0.7145 cm
d	Diâmetro primitivo (distância entre os centros de duas esferas diametralmente opostas)	2.8519 cm
β	Ângulo de contato entre a esfera e a gaiola	0°
N_e	Número de elementos rolantes	8

Tabela 3.1. Dimensões do rolamento utilizado no experimento.

Aplicando as equações de cálculo das frequências características de [2] e de [3] (demonstradas formalmente em [6]), podemos calcular a razão entre a frequência de defeito $f_{DEFEITO}$ e a frequência de rotação $f_{ROTAÇÃO}$ (notemos a proporcionalidade entre essas duas grandezas, constante para todas as amostras), conforme podemos observar na

tabela 3.2.

Mancal	Defeito	$\frac{f_{\text{DEFEITO}}}{f_{\text{ROTAÇÃO}}}$	
		Cálculo teórico	Valor encontrado
Defeito A	Gaiola	$\frac{1}{2} \left(1 + \frac{D \cdot \cos(\beta)}{d}\right)$	<i>0,375 Hz / Hz</i>
Defeito B	Pista externa	$\frac{N_e}{2} \left(1 - \frac{D \cdot \cos(\beta)}{d}\right)$	<i>2,998 Hz / Hz</i>
Defeito C	Elemento rolante	$\frac{D}{2 \cdot d} \left(1 + \left(\frac{D \cdot \cos(\beta)}{d}\right)^2\right)$	<i>2,12 Hz / Hz</i>

Tabela 3.2. Cálculo das frequências características de defeitos em mancais de rolamento.

Tais fatores serão importantes para a próxima etapa, durante a interpretação dos parâmetros obtidos a partir de cada sinal e para a posterior separação de dados que serão inseridos no classificador.

Maiores detalhes relativos à modelagem de falhas em mancais de rolamento podem ser encontrados em [7].

Capítulo 4

Extração de parâmetros das amostras

A extração de parâmetros das amostras é uma das etapas mais cruciais do trabalho realizado, pois a seleção correta de dados que representem o problema a ser resolvido pelo classificador possui extrema influência nos resultados finais.

Os parâmetros utilizados em [1] na análise de problemas de classificação são de obtenção extremamente simples:

- Estima-se a frequência de rotação do dispositivo a partir do pico de frequência mais significativo medido no tacômetro.
- Procura-se, dentro de uma distância de 3 amostras ao redor dos 3 primeiros harmônicos, picos que não coincidam com estes harmônicos. Essa análise é feita sobre os sinais medidos por cada um dos acelerômetros (alinhados com os três eixos; axial, tangencial e radial).
- Para cada sinal, registra-se a frequência fundamental de rotação e as 9 frequências de pico encontradas no passo anterior em uma matriz de características, que é apresentada para o classificador.

A simplicidade dos parâmetros não interfere no bom rendimento do algoritmo: conforme já mencionado, acertos de predição da ordem de 90% foram encontrados.

No entanto, em [2], para o caso dos mancais de rolamento, uma análise mais complexa é proposta: utiliza-se uma combinação entre o método da curtose espectral e da análise de envoltória (demodulação) para se encontrar o sinal final, que disponibiliza um padrão de picos agrupados dentro de uma das frequências características a um dos três tipos de defeito induzidos no mancal, apresentadas no final do capítulo anterior.

Assim, especificamos tais técnicas nas próximas seções.

4.1 – Momentos de ordem superior

Apresentamos nesta seção os momentos de ordem 3 e 4 de um sinal: a assimetria (ordem 3) e a curtose (ordem 4). Aquela será utilizada diretamente como parâmetro que caracteriza o sinal durante a etapa de classificação do mancal de rolamento e esta será

utilizada para a obtenção da frequência característica de defeito do mancal em análise por meio da técnica da curtose espectral. Sejam ζ e σ a média e o desvio padrão do sinal X , respectivamente, e seja ϵ o operador valor esperado (esperança) de variáveis aleatórias.

- A assimetria pode ser calculada por meio da equação: $\gamma_1[X] = \epsilon \left[\frac{X-\zeta}{\sigma} \right]^3$ e indica o quanto uma distribuição se encontra mais concentrada à esquerda do valor médio ou à direita do mesmo. Esta informação é fornecida diretamente ao classificador conforme veremos adiante.
- A curtose pode ser calculada por meio de: $\gamma_2[X] = \epsilon \left[\frac{X-\zeta}{\sigma} \right]^4$ e será utilizada na aplicação da técnica de curtose espectral proposta em [2].

4.2 – Curtose espectral

O sinal pré-processado consiste, no caso do mancal de rolamento defeituoso, numa versão modulada do sinal que procuramos: aquele apresentado na seção 3.2 e que guarda as informações relativas à frequência característica do tipo de falha que se pretende encontrar. A técnica da curtose espectral permite que encontremos a frequência central na qual a demodulação deverá ser realizada por meio do seguinte procedimento:

- Tomamos o espectrograma do sinal por meio da transformada de Fourier de tempo curto. Os parâmetros utilizados neste algoritmo são os seguintes:
 - Tipo de janela utilizada: janela de Hanning.
 - Número de amostras da janela: 512 (Recomendado em [2]).
 - Número de pontos nas transformadas de Fourier das janelas: $512 \times 2 = 1024$ (recomendado pelo autor do algoritmo utilizado, disponibilizado abertamente à comunidade MATLAB e demonstrado no anexo A).
 - Número de pontos em *overlap* = *Noverlap* = (75%) (Número de amostras na janela). Este parâmetro indica o percentual de sobreposição entre as janelas tomadas no espectrograma. Assim, duas janelas tomadas em passos consecutivos possuem 75% de amostras em comum e isso permite a obtenção de um espectrograma cujos valores variam mais suavemente tanto no eixo temporal quanto no eixo frequencial.

- A partir do espectrograma obtido:

$$STFT_X(n = \text{tempo discreto}, \nu = \text{frequência discreta})$$

Tomamos para cada frequência ν fixa, o valor da curtose em função da frequência. Ou seja, calculamos a curtose de:

$$f_\nu(t) = STFT_X(n = \text{variável}, \nu = \text{fixo})$$

em função de n conforme podemos observar na figura 4.1.

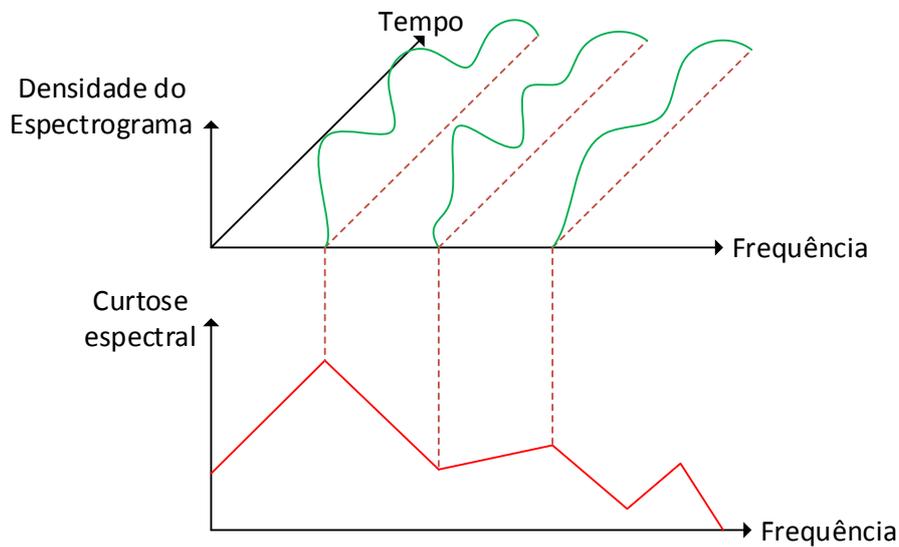


Figura 4.1. Ilustração do procedimento para determinação da curtose espectral.

Todo o procedimento é realizado por meio de uma implementação do algoritmo de curtose espectral disponível na comunidade MATLAB e exibido no anexo A. Para o caso que analisamos no pré-processamento, foi obtida a curva de curtose espectral exibida na figura 4.2.

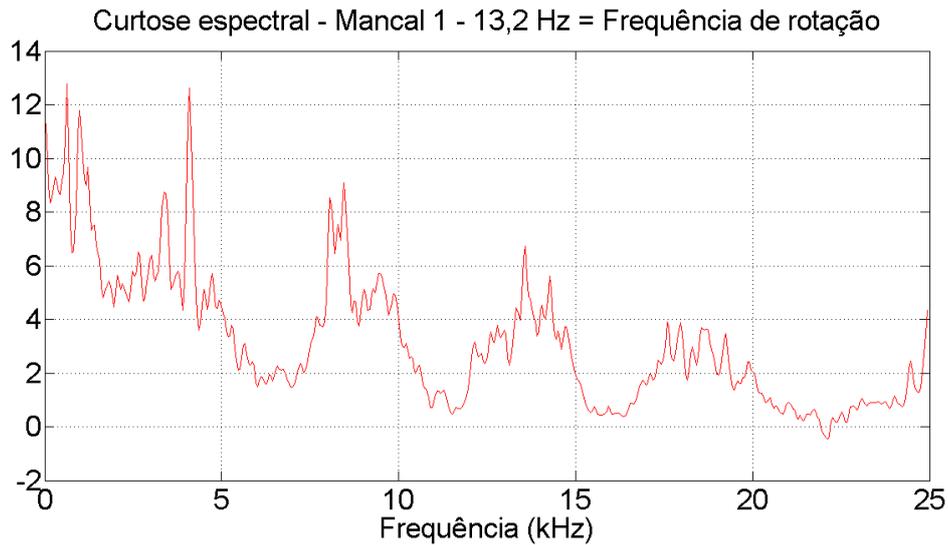


Figura 4.2. Curtose espectral – Defeito A – 13,2 Hz.

Na demodulação do sinal, os picos mais intensos de curtose fornecem os sinais com as informações relativas às frequências características das falhas. Assim, tomamos a frequência de pico encontrada no gráfico da curtose espectral e realizamos a demodulação ao redor da mesma após o pré-processamento.

O processo de demodulação do sinal é realizado em duas etapas:

- Seja $F_{MAX,SK}$ a frequência relativa ao maior pico de curtose. Um filtro passa banda com banda de passagem de $\Delta F = \pm 5kHz$ e centrado em $F_{MAX,SK}$ é aplicado. Utilizamos no projeto um filtro de Butterworth de ordem 5.
- O cálculo da envoltória do sinal obtido irá centrar a banda filtrada ao redor da origem. Este procedimento pode ser realizado tanto com um filtro passa-baixa como por meio da transformada de Hilbert. Utiliza-se no caso deste trabalho a transformada de Hilbert, que será apresentada na próxima seção.

4.3 – Transformada de Hilbert

Seja f uma função $\mathbb{C} \rightarrow \mathbb{C}$. Podemos representá-la na seguinte forma:

$$f(x, y) = f(x + i \cdot y) = u_R(x, y) + u_I(x, y) \cdot i$$

Onde x e y são reais, $u_R(x, y)$ e $u_I(x, y)$ são funções $\mathbb{R}^2 \rightarrow \mathbb{R}$. Dizemos que f é analítica se ela puder ser expressa em uma série de Taylor convergente em todos os pontos. Esta função é analítica se, e somente se, ela for diferenciável. Historicamente, a motivação inicial da transformada de Hilbert foi a solução do seguinte problema:

Dada a função $u_R(x, y)$, encontrar $u_I(x, y)$ que torne a função $f(x, y)$ analítica

Solucionando-se o sistema formado pelas equações de Cauchy-Riemann:

$$\begin{cases} \frac{\partial u_R}{\partial x} = \frac{\partial u_I}{\partial y} \\ \frac{\partial u_R}{\partial y} = -\frac{\partial u_I}{\partial x} \end{cases}$$

Encontramos que a função u_I deve ser a transformada de Hilbert de u_R , definida por:

$$H[u_R](t) = u_I(t) = \frac{1}{\pi} \cdot \mathfrak{C} \left(\int_{t=-\infty}^{t=\infty} \frac{u_R(\tau)}{t - \tau} \cdot d\tau \right)$$

Onde \mathfrak{C} é o valor principal de Cauchy, que corrige singularidades que podem ser encontradas no plano complexo durante o procedimento de cálculo.

Seja $u_R(x, y) = u_R(x) = A(x) \cdot \cos(x)$, temos que:

$$H[u_R](t) = u_I = H[A(\bullet) \cdot \cos(\bullet)](t) = A(\bullet) \cdot \sin(\bullet)$$

Logo:

$$\|u\| = \|(u_R, u_I)\| = \|(u_R, H[u_R])\| = A(\bullet) \cdot \|(\sin(\bullet), \cos(\bullet))\| = A(\bullet)$$

Assim, a norma do sinal analítico obtido é, para esse caso especial, a envoltória do sinal u_R . Essa propriedade pode ser estendida para sinais em geral e, conseqüentemente, a transformada de Hilbert pode ser utilizada para a determinação da envoltória de sinais em geral.

Uma demonstração completa das propriedades bem como a derivação da transformada de Hilbert podem ser consultadas em [8].

A título de exemplo, os resultados obtidos com a demodulação e com a transformada de Hilbert são exibidos nas figuras seguintes. Primeiramente, na figura 4.3, demonstramos o procedimento de filtragem no sinal, demonstrando o espectro da saída do pré-processamento e o sinal obtido após a filtragem ao redor da frequência encontrada pelo método da curtose espectral:

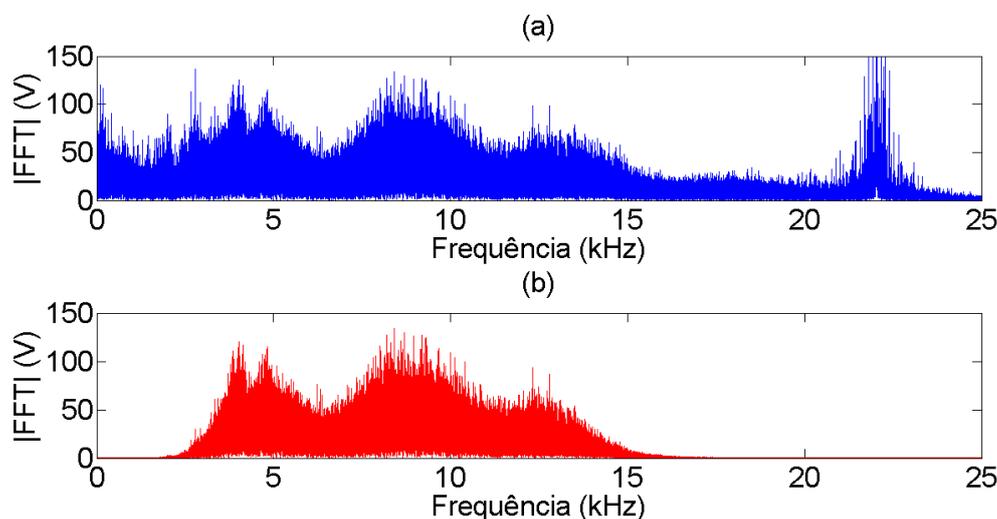


Figura 4.3. Sinal pré-processado – Defeito A – 13,2 Hz – Comparação de espectros antes e depois da aplicação do filtro passa-banda de Butterworth de ordem 5.

(a) Sinal após pré-processamento.
(b) Sinal obtido após filtragem de (a).

Observamos, efetivamente, que o espectro ficou restrito à região na qual o 3º maior pico (em 8,7 kHz) da figura 4.2 gera com uma largura de banda de ± 5 kHz, conforme recomendado em [2]. Não tomamos os 2 primeiros maiores picos porque ambos ocorrem para frequências abaixo de 5 kHz e não há sentido em se filtrar frequências negativas. Poderíamos truncar o resultado, no entanto, caso se encontrem máximos em frequências muito baixas utilizaríamos uma largura de banda efetiva (não nula) muito restrita e, no presente problema, buscamos maximizar a utilização de informações.

Em [2], indica-se que a utilização de outros picos relevantes não altera o resultado significativamente. Assim, a providência adotada altera em certos casos o pico escolhido além de maximizar a largura de banda efetivamente utilizada pelo algoritmo – isso permitirá a obtenção de um sinal de saída que possui maior riqueza de detalhes ligados às falhas que visamos detectar.

O mesmo ocorre para frequências superiores: picos centrados em frequências maiores que 20 kHz também não são considerados na análise da curtose espectral.

Por meio da transformada de Hilbert buscamos encontrar uma envoltória para o sinal original. Efetivamente, a envoltória é encontrada no domínio do tempo conforme podemos observar na figura 4.4.

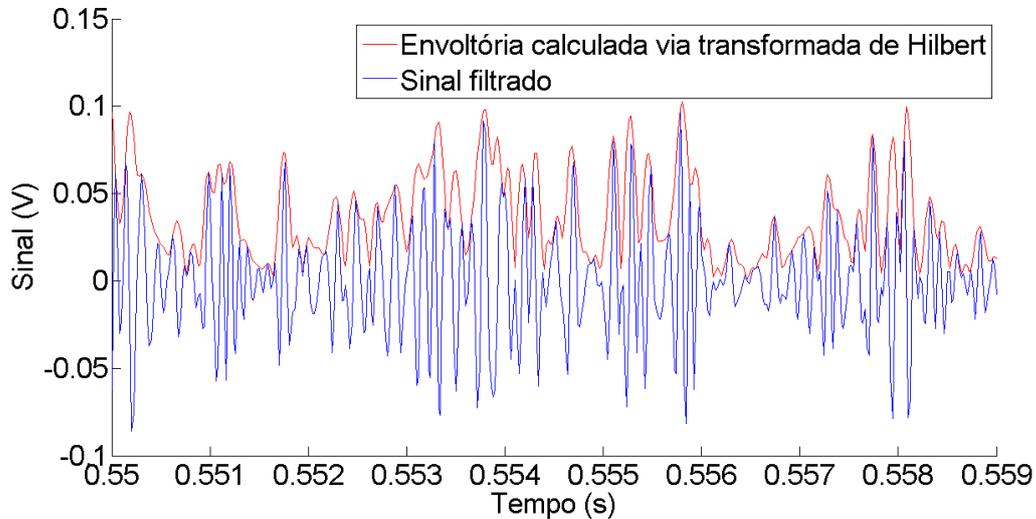


Figura 4.4. Comparação entre o sinal filtrado antes da transformada de Hilbert e após a transformada de Hilbert.

Verificamos, com a análise do sinal em intervalos de tempo reduzidos, como é o caso do intervalo tomado na figura 4.4, que o método da transformada de Hilbert calcula a envoltória do sinal de maneira eficaz. Podemos observar na figura 4.5 que, no domínio da frequência, isso representa tomar a banda remanescente e centralizá-la ao redor do zero de forma a completar o processo de demodulação.

O espectro da envoltória encontrado é formado por picos isolados entre si de forma a evidenciar um conjunto cristas centradas nas frequências características dos defeitos de mancais induzidos no experimento. A utilização de frequências de demodulação menores que 5 kHz e maiores que 20 kHz geraria sinais válidos em teoria, no entanto, a quantidade de picos relativos a falhas seria reduzida nestes sinais.

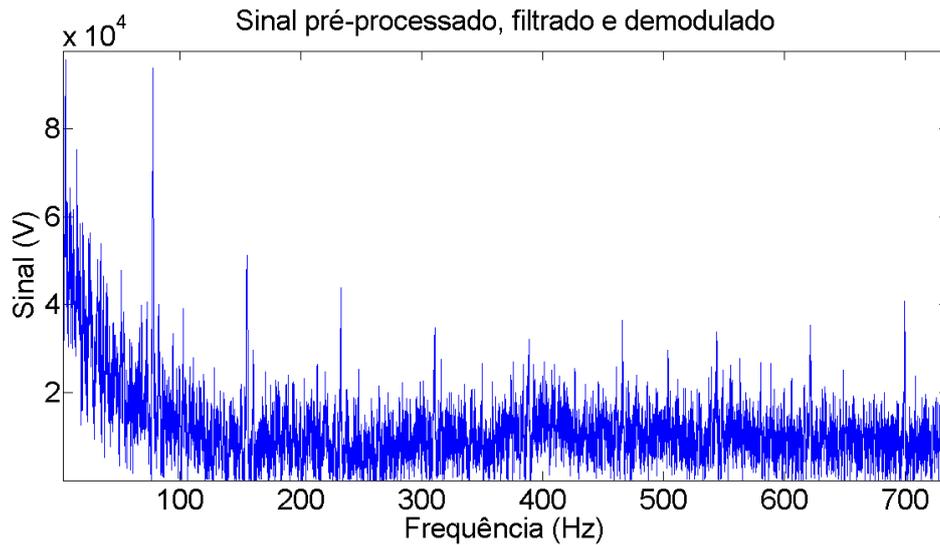


Figura 4.5. Sinal final obtido.

Retornando-se à tabela 3.2 podemos observar que $\frac{f_{DEFEITO}}{f_{ROTAÇÃO}} = 0,375$. Assim, a frequência característica que devemos encontrar na figura 4.5 deve valer $0,375 \times 13,2 \text{ Hz} = 4,95 \text{ Hz}$. Com efeito, podemos encontrar diversos picos aproximadamente múltiplos de tal frequência, como, por exemplo, um pico centrado em $4,9 \text{ Hz}$. O procedimento utilizado em [2] é realizado de forma direta, por meio da observação do gráfico. Uma das propostas deste projeto é a realização de um algoritmo que realize tal tarefa de maneira automática e para todos os sinais da base de dados.

Para isso, devemos extrair do gráfico obtido um conjunto de parâmetros amplamente ligado ao tipo de defeito do mancal de rolamento e apresentá-lo ao classificador.

Antes da realização da análise com o classificador, uma tentativa de automatizar o processo de identificação de defeito por meio da observação direta do gráfico (conforme descrito em [2]) foi realizada. No entanto, os resultados não foram positivos. A tentativa consistiu na seguinte sequência de passos:

- Detectou-se as frequências relativas aos 5 maiores picos do sinal demodulado
- Cada frequência foi comparada com as três frequências de defeitos possíveis
- A comparação se deu por meio da seguinte equação:

$$\frac{\min(\text{resto}(F_{PICO}, F_{DEFEITO}), \text{resto}(F_{DEFEITO} - F_{PICO}, F_{DEFEITO}))}{F_{DEFEITO}} = R_R$$

Tal equação foi aplicada para cada um dos três defeitos em cada uma das 20 frequências de pico, onde $resto(A, B)$ representa o resto de A na divisão por B . Essa equação calcula um tipo de resto relativo R_R .

Dada uma frequência de pico F_{PICO} , R_R é mínimo quando o defeito é aquele que possui o harmônico mais próximo F_{PICO} em relação às demais frequências características. O valor calculado é dividido por $F_{DEFEITO}$ pois defeitos distintos podem ter ordens de grandeza variáveis. Assim, o resto relativo calcula o percentual mínimo de desvio entre a frequência do pico em análise e a frequência de falha.

Teoricamente, a observação direta do gráfico consiste, aproximadamente, na aplicação dessa técnica: procura-se qual tipo de falha possui harmônico que mais se aproxime da frequência do pico.

Toma-se o conjunto de restos relativos para os diferentes picos e ligados a diferentes tipos de falhas. Seleciona-se o menor deles e observa-se qual o tipo de falha ligado ao resto relativo mínimo. Esse tipo de falha encontrado seria uma potencial classificação de defeitos para o mancal utilizado na aquisição da respectiva amostra.

No entanto, taxas de acerto inferiores a 33,3% foram encontradas para cada uma das 3 possíveis falhas. Esse resultado indica uma classificação inadequada.

Finalmente, mitigou-se o problema: foi observado que a maioria das classificações acusava falha na gaiola (defeito A). E é exatamente esse tipo de falha que possui as menores frequências características. Assim, os harmônicos desse tipo de defeito são espaçados entre si em distâncias muito menores que nos demais casos. Por isso observou-se a existência de uma probabilidade extremamente grande de se classificar o defeito como defeito na gaiola. Assim, a tentativa de se relativizar o resto, dividindo-o por $F_{DEFEITO}$ não surtiu o efeito desejado.

Esse tipo de problema reforça a importância de se utilizar um classificador para o diagnóstico. O processo de observação humana realizado em [2] funciona, efetivamente, mas é de difícil automação.

Assim, os parâmetros extraídos para classificação num primeiro momento foram:

- A frequência de rotação do rotor;
- As frequências teóricas para cada um dos três tipos de falhas, calculadas para cada sinal, segundo a multiplicação dos fatores calculados na tabela 3.2 à frequência de rotação do rotor;

- E as 5 frequências relativas aos cinco maiores picos do sinal demodulado obtidos dos três sensores de vibração, relativos aos eixos radial, axial e tangencial.

Assim, listamos acima um total de 9 variáveis de entrada. Em [2] observamos que diversos trabalhos também propõem parâmetros empíricos e, num segundo momento, repetimos a análise acrescentando as novas variáveis ao crivo do classificador. As variáveis empíricas propostas e calculadas também sobre o sinal demodulado são:

- A assimetria;
- A curtose;
- O valor de pico;
- O valor médio quadrático (valor RMS);
- O valor médio quadrático do sinal demodulado (RMS) multiplicado pelo valor de pico (valor K).

Conforme observaremos no capítulo 6, mesmo com bons resultados na ausência de parâmetros empíricos, podemos observar uma significativa melhora nos resultados após a utilização dos mesmos.

Os parâmetros empíricos acrescentados, num segundo momento, aos da análise original são: a assimetria, a curtose, e produto entre o valor RMS e o valor de pico (valor K). Não há necessidade de se fornecer ao classificador nem o valor RMS nem o valor de pico separadamente pois tais informações já estão contidas no valor K. Assim, temos 12 variáveis de entrada utilizadas na análise que considera as novas variáveis.

Finalmente, no último classificador desenvolvido (classificador universal – defeitos nos eixos e mancais de rolamento), busca-se diagnosticar, igualmente, falhas no eixo de rotação por meio da utilização de parâmetros propostos em [1]: as magnitudes do espectro nos três primeiros harmônicos dos sinais de cada um dos seis tacômetros (três localizados nos eixos axial, radial e tangencial do mancal não invertido e três localizados nos eixos axial, radial e transversal do mancal invertido num total de 18 variáveis adicionais). As novas variáveis são acrescentadas às variáveis anteriores, obtendo-se 27 (18 + 9) termos de entrada para o classificador universal sem variáveis empíricas e 30 (18 + 3 + 9) termos de entrada para o classificador universal que considera a utilização de tais variáveis. Ambos os casos serão analisados posteriormente.

Deve-se notar que os parâmetros empíricos e teóricos determinados em [2] são extraídos após a etapa de pré-processamento. Porém, os parâmetros oriundos de [1], acrescentados posteriormente, não devem passar pela etapa de pré-processamento: o cálculo dos picos é realizado sobre os harmônicos naturais do sinal em análise e estes são eliminados após a remoção de suas componentes determinísticas ligadas ao sinal normal.

Capítulo 5

Classificadores e Método *Random Forest*

5.1 – Conceito e validação cruzada

A interpretação dos parâmetros finais obtidos pelo algoritmo desenvolvido será garantida pela utilização de um classificador. Os classificadores consistem em objetos abstratos que, ao serem programados, são capazes de realizar decisões em contextos complexos e com um bom nível de abstração. Para isso, é necessária a realização de uma etapa denominada “treinamento”, durante a qual resultados previamente conhecidos são apresentados ao classificador.

Em seguida, outros resultados (não pertencentes ao conjunto apresentado ao classificador durante a etapa de treino) são inseridos no classificador treinado no intuito de se testar a veracidade e a eficácia das decisões do mesmo. Esta etapa é denominada “teste”. Assim, será necessário dividir o conjunto de dados coletados em duas partes disjuntas: uma parte para treino e outra para teste.

Tal divisão não deve ser feita de forma arbitrária: deve-se dividir os dados da maneira mais equilibrada possível, de forma a possuir em ambos os conjuntos um máximo de diversificação no que diz respeito aos diferentes casos que deverão ser analisados. Além disso, espera-se que um bom classificador seja capaz de tomar um alto número de boas decisões por meio da apresentação de um número pequeno de casos-base do conjunto de treino.

5.2 – Implementação dos conjuntos de treino e de teste

Os parâmetros extraídos dos sinais apresentados no capítulo anterior são apresentados como variáveis de decisão ao classificador. Resta-nos determinar o processo de separação entre os conjuntos de treino e teste. Para isso, a seguinte sequência de passos é realizada:

1. Separam-se os sinais de mancais defeituosos em duas classes: uma para os mancais não invertidos e outra para os mancais invertidos. A análise será realizada separadamente para cada um desses dois casos pois as posições são diferentes e, logo, análises distintas devem ser efetuadas.
2. Cada classe é separada em três subclasses: defeito A (gaiola), defeito B (pista externa) e defeito C (elemento rolante – esfera).
3. Cada subclasse é representada em um vetor ordenado em relação à frequência de rotação do rotor.
4. Cada subclasse é dividida em três conjuntos: o conjunto dos elementos com índices múltiplos de 3 (na figura 5.1, por exemplo, representados pelos blocos azuis), o conjunto dos elementos que deixam resto 1 na divisão por três (na figura 5.1, representados pelos blocos verdes) e o conjunto dos elementos que deixam resto 2 na divisão por três (representados, na mesma figura, pelos blocos roxos). Essa divisão permite que as três divisões englobem todas as faixas de frequência (entre 10 Hz e 60 Hz aproximadamente) de maneira uniforme, beneficiando o treinamento do classificador.
5. Os conjuntos representados pelos mesmos restos na divisão por 3 (ou, na figura 5.1, pelas mesmas cores), são unidos para cada um dos três casos: formam-se os conjuntos “SET1”, “SET2” e “SET3”.

Finalmente, para cada um dos dois casos (mancal invertido defeituoso e mancal não invertido defeituoso), realizamos os seguintes procedimentos:

- Utilizar o SET1 para treino e a união entre SET2 e SET3 para teste
- Utilizar o SET2 para treino e a união entre SET1 e SET3 para teste
- Utilizar o SET3 para treino e a união entre SET1 e SET2 para teste

Ou seja: três análises são realizadas em paralelo para cada um dos dois casos (defeito no mancal invertido e defeito no mancal não invertido). Esse método de decisão é denominado “validação cruzada de 3 *folds*”. A figura 5.1 demonstra, visualmente, um exemplo da aplicação do método de validação cruzada utilizado para um caso no qual a frequência de 10 amostras hipotéticas varia uniformemente de 1 Hz a 10 Hz.

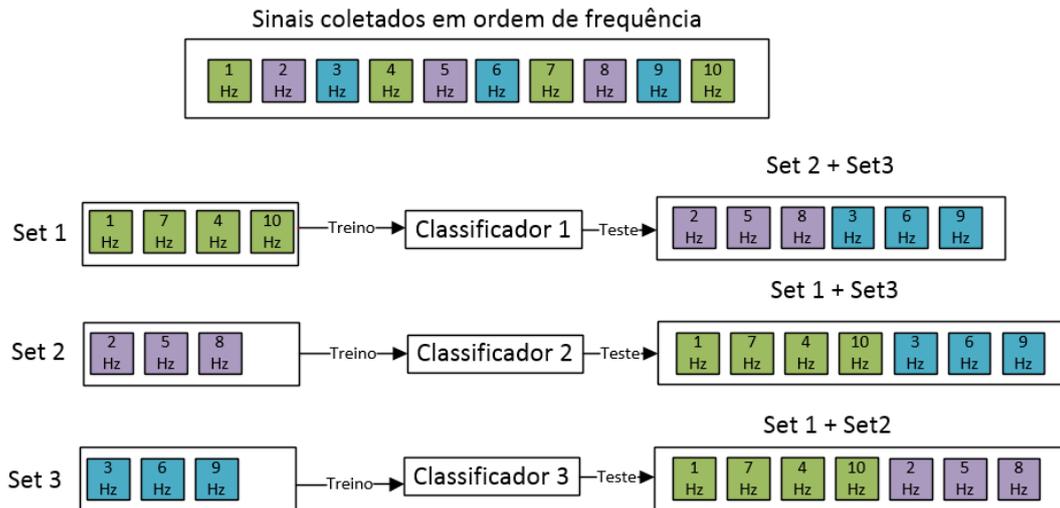


Figura 5.1. Validação cruzada de 3 folds: Procedimento realizado separadamente para medições do defeito A, defeito B e defeito C em cada um dos dois casos: mancal invertido defeituoso e mancal não invertido defeituoso.

5.3 – *Random Forest* (Nós de decisão)

Com base nas observações realizadas em [1], concluiu-se que, dentre os diversos tipos de classificadores, o classificador do tipo *random forest* (ou classificador por árvores de decisão) se apresentou como o gerador de melhores resultados no problema da análise de máquinas rotativas. Por isso, no presente trabalho, utilizamos este método, que será apresentado nesta seção.

O método *random forest* consiste em um conjunto de árvores de decisão geradas dentro de um mesmo objeto. Cada objeto (conjunto de árvores) passa por um mecanismo de votação (*bagging*), que elege a classificação mais votada. A classificação encontra-se nos nós terminais das mesmas. Um exemplo de árvore de decisão interna ao classificador é exibido na figura 5.2.

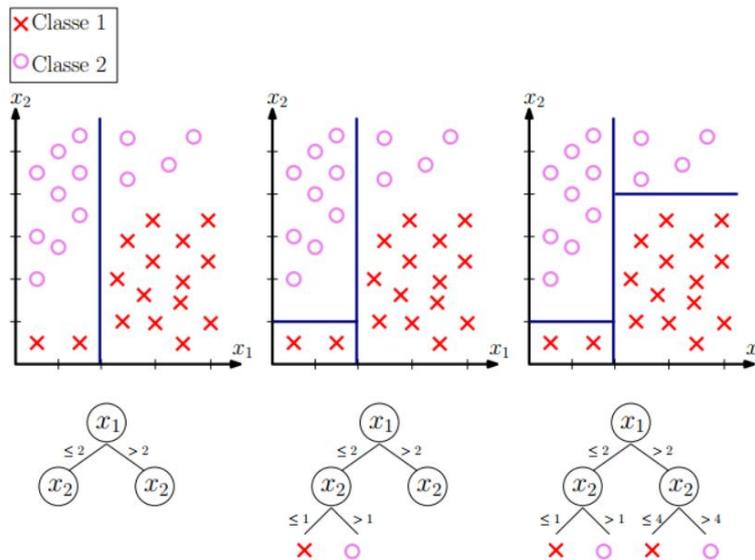
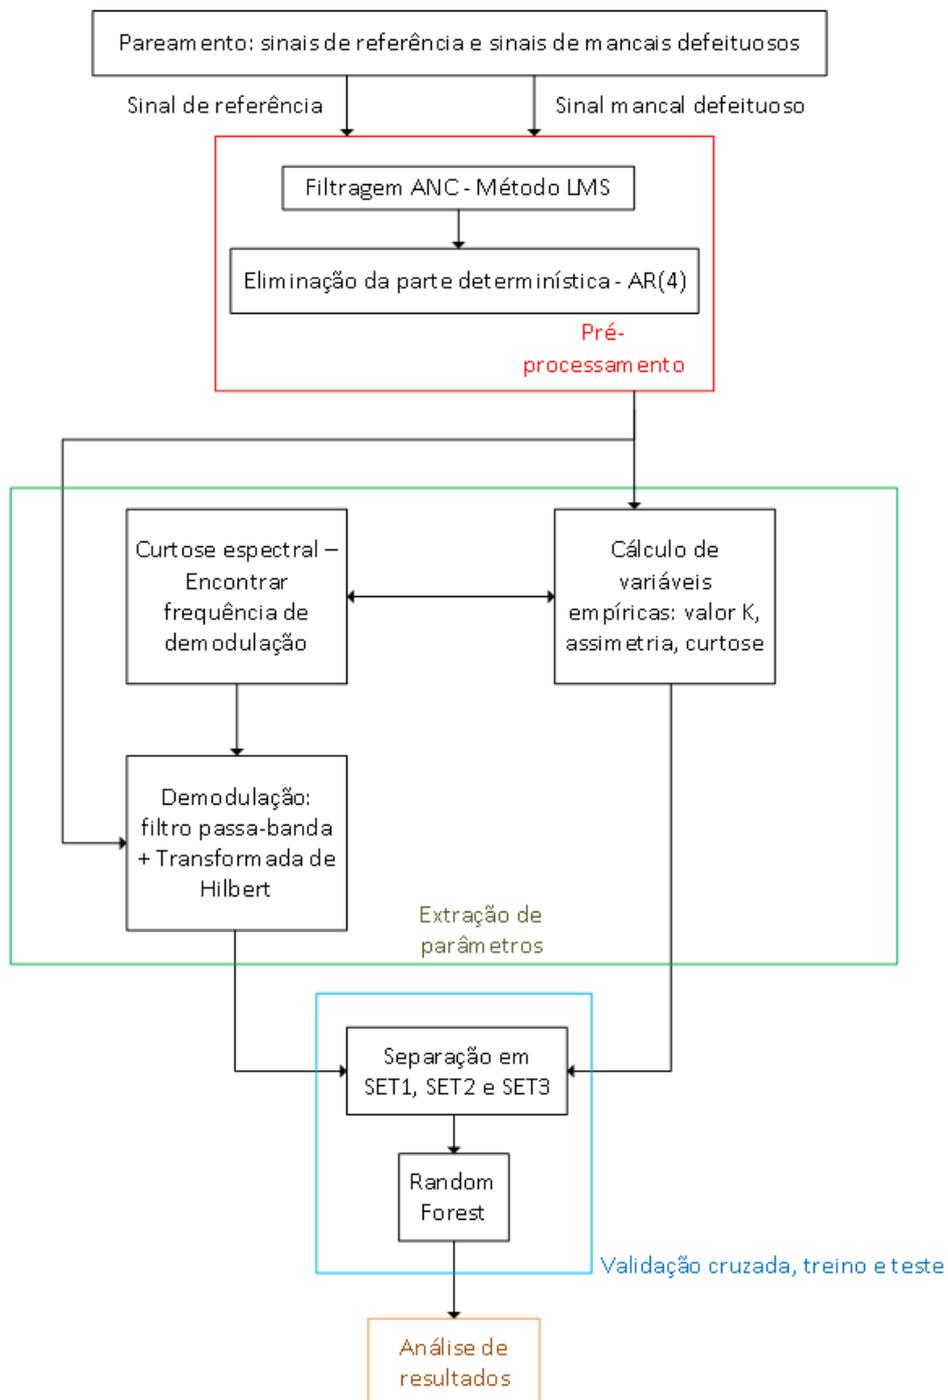


Figura 5.2. Criação de árvore de decisão. Fonte: [1].

Podemos observar na figura 5.2 que o problema de classificação consiste, basicamente, em um problema de separação de superfícies de decisão em um espaço cujo número de dimensões é igual ao número de parâmetros de entrada no classificador. Mais especificamente, o classificador *random forest* separa as superfícies de decisão por meio da criação de uma sequência de hiperplanos paralelos aos eixos.

No capítulo 6, o método é aplicado sobre os parâmetros extraídos da amostra e organizados em conjuntos de treino e teste por meio da validação cruzada já especificada. A análise é realizada para um número de árvores presentes no processo de *bagging* (votação) variando de 1 a 60. A profundidade da árvore de decisão é determinada automaticamente pelo algoritmo do MATLAB utilizado, que segue um critério interno de parada em sua configuração padrão.

Antes de se demonstrar e interpretar os resultados finais, propomos um resumo de todos os procedimentos realizados para a obtenção dos mesmos na figura 5.3, demonstrando a entrada e saída de cada algoritmo aplicado.



■ - Capítulo 3 ■ - Capítulo 4 ■ - Capítulo 5 ■ - Capítulo 6

Figura 5.3. Etapas do projeto.

Capítulo 6

Avaliação dos resultados finais

Conforme já exposto, a saída do classificador é obtida a partir dos conjuntos de treino e teste gerados na validação cruzada e aplicados sobre os parâmetros extraídos dos sinais originais. Observa-se tanto a influência das variáveis empíricas nos índices de acerto quanto a influência exercida com uma variação de árvores de decisão em cada classificador para o processo de *bagging*.

Logo, as respostas são obtidas em três etapas:

- Utiliza-se os sinais coletados do mancal não invertido para o desenvolvimento de um classificador que opere apenas sobre este mancal. Os sinais coletados do mancal invertido são utilizados para a criação de um outro classificador, que deverá operar apenas no mancal invertido. Em cada um desses dois casos, testamos as classificações nos casos em que variáveis empíricas não são utilizadas e são utilizadas, obtendo-se quatro tipos de classificador.
- Desenvolvimento de um classificador que utilize dados de todos os seis sensores (axial, radial e tangencial, sobre os mancais invertido e não invertido) capaz de distinguir falhas no mancal invertido e no mancal não invertido. Chamaremos este classificador de “classificador de mancais conjuntos” e nele pode-se observar a capacidade de distinção entre falhas em cada um dos mancais ao se unir os dados relativos aos mesmos.
- Desenvolvimento de um classificador que utilize dados de todos os seis sensores e receba, além das variáveis listadas na descrição dos parâmetros extraídos para a análise dos mancais, os parâmetros listados em [1] no intuito de se diagnosticar todos os possíveis tipos de falhas presentes na base de dados: falhas no mancal invertido, falhas no mancal não invertido, desalinhamento e desbalanceamento. Chamaremos este classificador de “classificador universal”.

Para cada uma dessas etapas, determinamos primeiramente a curva de percentual acertos de diagnóstico para cada uma das três classes de defeitos de mancais (A, B e C, plotadas em um mesmo gráfico para fins de comparação) e, em seguida, representamos o percentual de acertos total - acertos médios somando-se os defeitos dos mancais 1 (falha

na gaiola), 2 (falha na pista externa) e 3 (falha no elemento rolante) para os conjuntos SET1, SET2 e SET3 conjuntamente.

Em seguida, representamos a matriz de confusão para o valor N ligado ao melhor classificador encontrado. Essa matriz permite a representação dos acertos e dos tipos de erro que foram encontrados no sistema desenvolvido.

O número N de árvores de decisão do classificador representado em tal matriz deveria, em termos mais formais, ter sido determinado por meio de um procedimento de validação.

Porém, a validação reduziria o número de sinais disponíveis no conjunto de treino e, como apenas 50 sinais foram utilizados em cada caso, demos preferência à representação da matriz de confusão para um valor escolhido com base num critério fundamentado no compromisso entre a velocidade e a complexidade do algoritmo.

Por meio desse procedimento, obtém-se, em troca, um maior número de classificadores considerados nas curvas de acertos e no histograma de erros.

A matriz de confusão consiste em uma matriz $\Pi = (c_{ij})_{N \times N}$, onde N é o número de classificações possíveis. A matriz é definida de forma que cada termo c_{ij} indica o percentual de diagnósticos do tipo j realizados sobre um elemento da classe i . Assim, a diagonal da matriz de confusão indica os acertos na classificação e os termos fora da mesma aponta a incidência dos diferentes tipos de erro possíveis.

Finalmente, realizamos uma análise individual de cada termo classificado, observando, por meio de uma tabela, em quais frequências os erros ocorrem e em que tipo de frequências, para cada uma das falhas para cada uma das três etapas descritas.

6.1 – Classificador de mancais individuais

Neste classificador, para cada caso, três saídas são possíveis: falha na gaiola (defeito A), falha na pista externa (defeito B) e falha no elemento rolante (defeito C). As entradas envolvem parâmetros ligados apenas ao mancal externo ou apenas ao mancal interno para cada situação tratada.

6.1.1 – Mancal não invertido: percentuais de acertos

Primeiramente, demonstramos os percentuais de acerto individuais, para cada tipo de erro, exibidos conjuntamente para fins de comparação na figura 6.1: na primeira coluna, exibimos os resultados obtidos para o caso em que parâmetros empíricos não foram utilizados e na segunda coluna podemos observar o efeito de adição das mesmas.

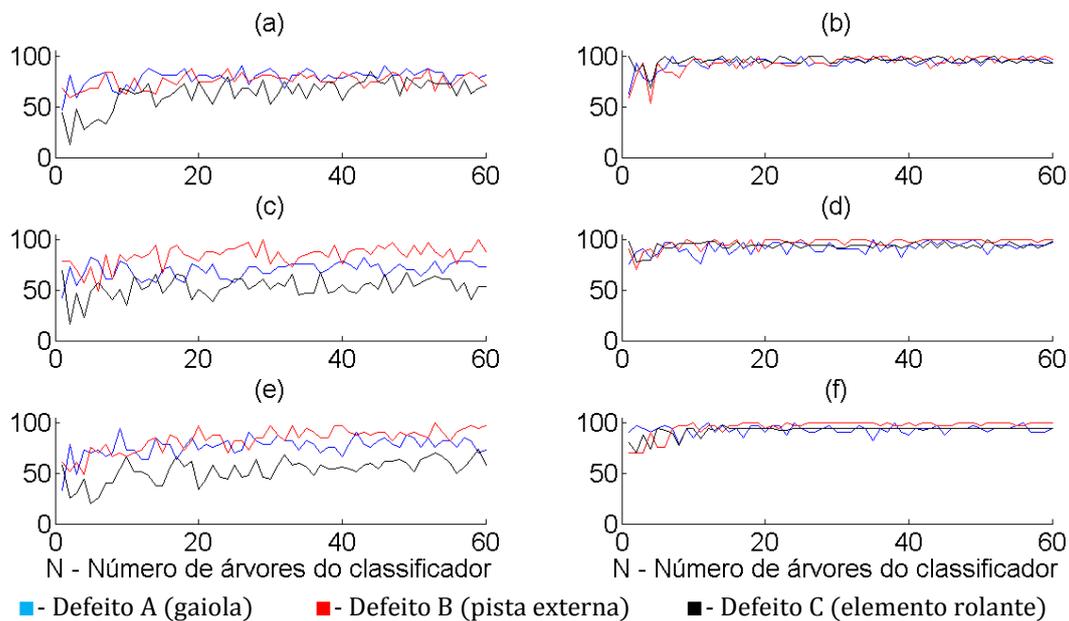


Figura 6.1. Percentual de acertos – SET1, SET2 e SET3 – Mancal não invertido.

Primeira coluna – (a), (c) e (e): Sem utilização de variáveis empíricas.

Segunda coluna – (b), (d) e (f): Com utilização de variáveis empíricas.

Primeira linha – (a) e (b): SET1.

Segunda linha – (c) e (d): SET2.

Terceira linha – (e) e (f): SET3.

Assim, podemos observar, inicialmente, dois aspectos distintos: comparando-se os temas de uma mesma coluna podemos observar que a utilização de diferentes conjuntos de treino (SET1, SET2 e SET3) não altera significativamente o percentual de acertos obtidos. Logo, o classificador *random forest* se mostrou robusto no que tange às variações de entrada.

Além disso, comparando-se termos de uma mesma linha e em colunas distintas, observamos que os gráficos à direita (oriundos da análise com o uso de variáveis empíricas) possuem percentuais de acertos significativamente maiores que os obtidos por meio da análise direta, sem o uso de variáveis empíricas. Com efeito, acertos na faixa de 60% a 80% são levados à faixa de 90% a 100% por meio do pequeno aprimoramento realizado no classificador.

Finalmente, podemos observar, com relação aos mancais que:

- Em 5 das 6 análises os problemas de defeito B foram diagnosticados com maior percentual de acertos.
- Em 5 dos 6 casos os problemas de defeito A foram diagnosticados com segundo maior percentual de erros.
- Em 5 dos 6 casos os problemas de defeito C foram diagnosticados com o menor percentual de erros.

Assim, também podemos observar que falhas na gaiola (defeito A) são detectadas mais facilmente, seguidas pelas falhas na pista externa (defeito B) e, por último, pelas falhas no elemento rolante (defeito C). Não houve variações significativas no percentual de acertos com a mudança de conjunto utilizado para o treinamento: para o caso onde não se utilizam variáveis empíricas, a partir de $N = 20$, os acertos dos mancais 1, 2 e 3 oscilam ao redor de índices de acerto de 75%, 75% e 50% respectivamente para os três conjuntos (SET1, SET2 e SET3). Após a utilização de variáveis empíricas na análise, tais acertos se estabilizam a partir de $N = 10$ (logo, estabilizam-se mais facilmente) ao redor de valores iguais, aproximadamente a 95% para os três casos.

Como não houve variações significativas no percentual de acertos com a mudança de conjunto utilizado para treinamento, podemos sintetizar a figura acima, tomando a média de acertos entre os três (figura 6.2).

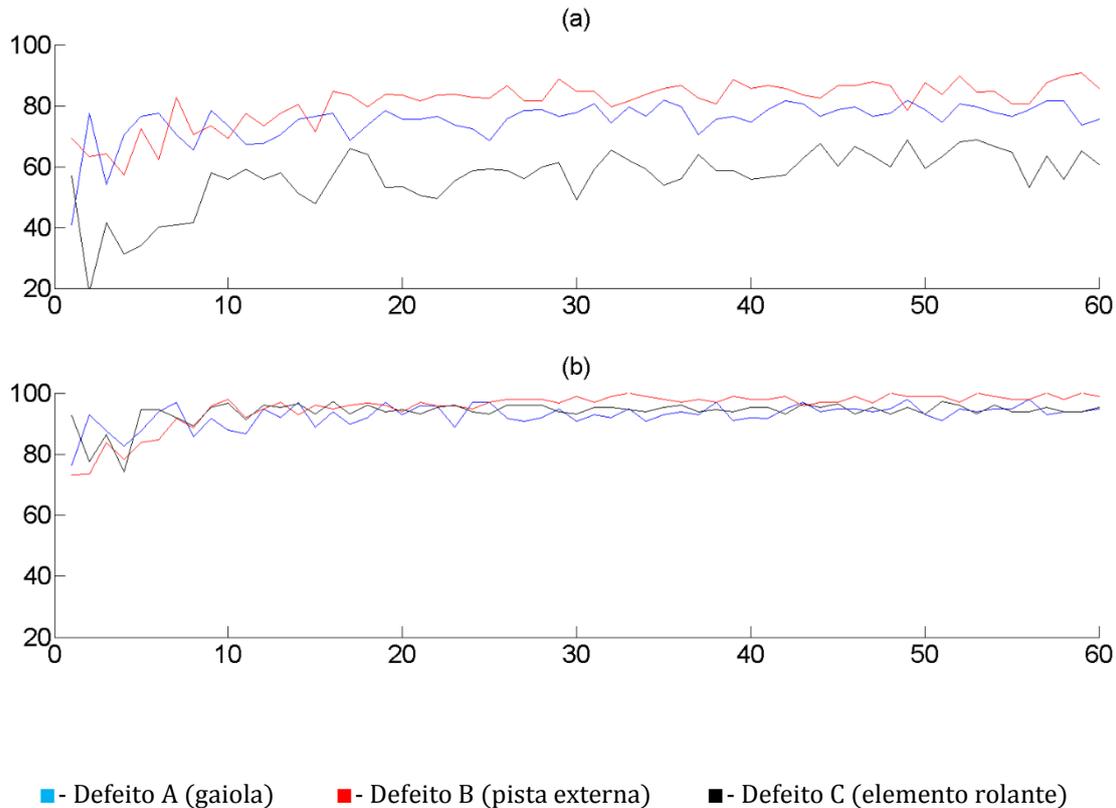


Figura 6.2. Acertos (%) – Comparação – Mancal não invertido – Com e sem variáveis empíricas.
 (a) – Acertos médios (média entre SET1, SET2 e SET3) – Sem variáveis empíricas.
 (b) – Acertos médios (média entre SET1, SET2 e SET3) – Com variáveis empíricas.

Os acertos médios se estabilizam a partir de $N = 20$ (20 árvores) para o caso em que variáveis empíricas não são utilizadas e se estabilizam a partir de $N = 10$ para o caso em que tais variáveis são adicionadas à análise – Assim, podemos observar que o uso de variáveis empíricas torna o classificador mais eficaz mesmo diante de um número reduzido de árvores utilizadas. A faixa de percentuais de acertos após a estabilização observada para cada um dos dois casos é indicado na tabela 6.1 e resume as conclusões tomadas.

Tipo de falha	Sem variáveis empíricas - $N \geq 20$	Com variáveis empíricas - $N \geq 10$
Defeito A – Falha na gaiola	76%	94%
Defeito B – Falha na pista externa	80%	98%
Defeito C – Falha no elemento rolantes (esfera)	50%	95%

Tabela 6.1. Percentual de acertos – Média entre SET1, SET2 e SET3 – Com e sem o uso de variáveis empíricas – comparação da faixa de acertos após o uso de um número suficientemente grande de árvores no classificador – Mancal não invertido.

Observa-se que, sem variáveis empíricas, o percentual de acertos do defeito C em específico é relativamente muito baixo. Segundo a modelagem realizada em [2], podemos interpretar esse resultado observando que o defeito na falha do elemento rolante é modulado pelo defeito de falha na gaiola, o que torna os dois defeitos similares. De todo modo, o uso das variáveis empíricas proposto se mostrou suficiente para separar de forma eficaz o defeito A do defeito C.

6.1.2 – Mancal invertido – Percentuais de acerto

A análise do mancal invertido foi realizada separadamente por se tratar de outro tipo de experimento: realiza-se a análise do problema para o mancal situado na outra posição, utilizando-se outros sensores: os 3 acelerômetros (X, Y e Z) situados nas proximidades do mesmo. O percentual de acertos para os classificadores treinados pelo SET1, pelo SET2 e pelo SET3 sem a utilização de variáveis empíricas são exibidos na figura 6.3.

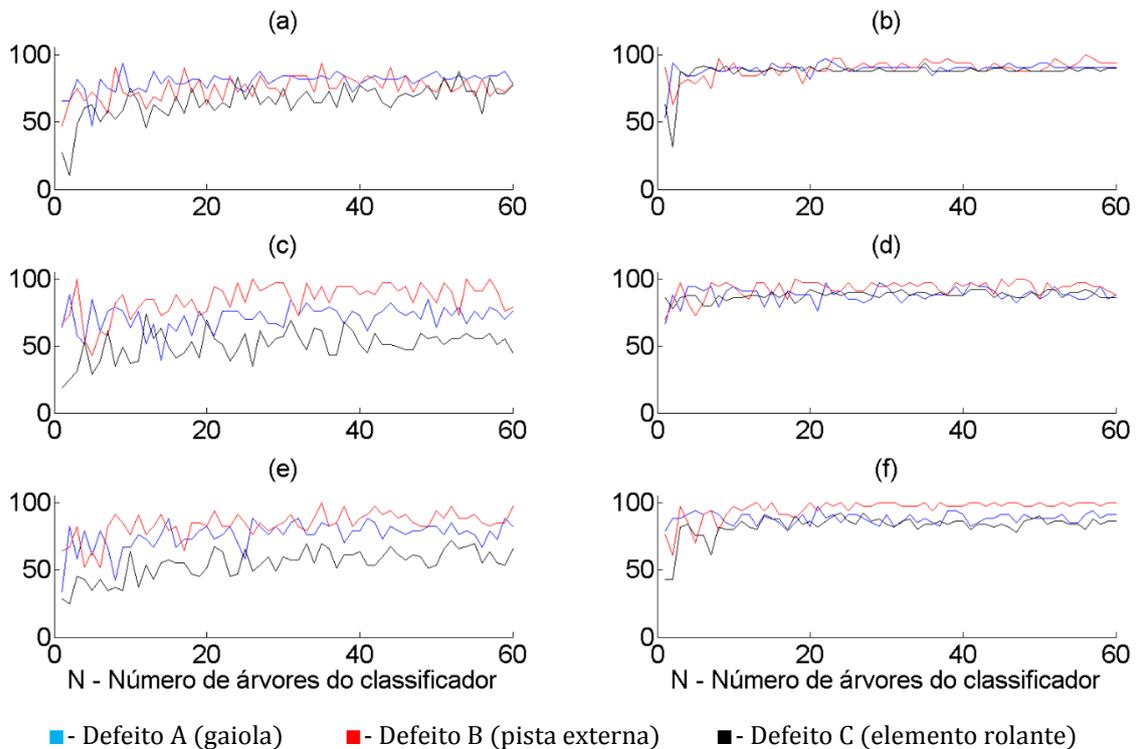


Figura 6.3. Percentual de acertos – SET1, SET2 e SET3 – Mancal invertido.
Primeira coluna – (a), (c) e (e): Sem utilização de variáveis empíricas.
Segunda coluna – (b), (d) e (f): Com utilização de variáveis empíricas.
Primeira linha – (a) e (b): SET1.
Segunda linha – (c) e (d): SET2.
Terceira linha – (e) e (f): SET3.

Nas análises realizadas com o mancal invertido, não se observam significativas mudanças com relação aos resultados obtidos no caso do mancal não invertido. A faixa de acertos também aumenta significativamente com a adição de variáveis empíricas, não há variação significativa na saída com a variação de conjuntos de treinamento (SET1, SET2 e SET3) e os mancais 2 e 3 continuam sendo os representativos das falhas, respectivamente, de mais fácil e mais difícil detecção e podemos confirmar tal conclusão observando o gráfico de acertos médios (figura 6.4) também representado para o mancal não invertido, juntamente com a tabela de percentual de acertos (tabela 6.2) após a utilização de um número significativo de árvores de decisão no classificador.

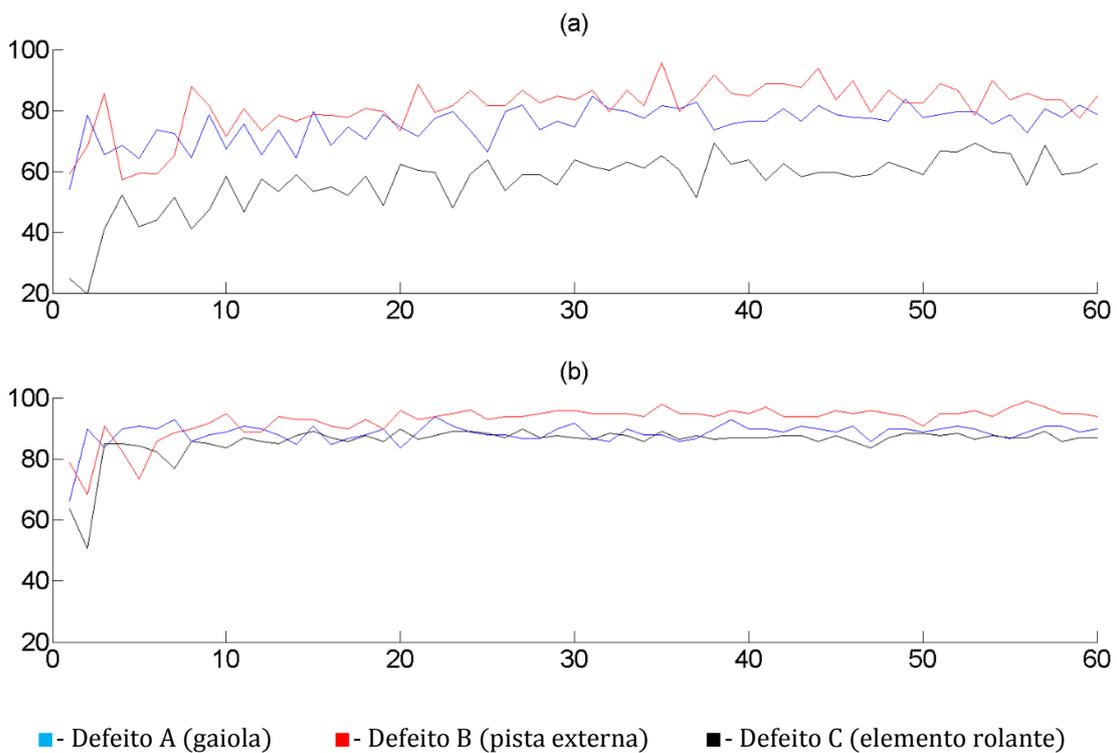


Figura 6.4. Acertos (%) –Comparação – Mancal invertido – Com e sem variáveis empíricas.
 (a) – Acertos médios (média entre SET1, SET2 e SET3) – Sem variáveis empíricas.
 (b) – Acertos médios (média entre SET1, SET2 e SET3) – Com variáveis empíricas.

Tipo de falha	Sem variáveis empíricas - $N \geq 20$	Com variáveis empíricas - $N \geq 10$
Defeito A – Falha na gaiola	78%	88%
Defeito B – Falha na pista externa	81%	92%
Defeito C – Falha no elemento rolante	49%	85%

Tabela 6.2. Percentual de acertos – Média entre SET1, SET2 e SET3 – Com e sem o uso de variáveis empíricas – comparação da faixa de acertos após o uso de um número suficientemente grande de árvores no classificador – Mancal invertido.

Comparando-se a tabela 6.2 à tabela 6.1 podemos observar uma única diferença: no caso em que variáveis empíricas são utilizadas, a taxa de acertos tende a cair. Assim, podemos concluir experimentalmente que a detecção de falhas em mancais de rolamento mais distantes do motor é realizada com maior dificuldade por parte do classificador. Isso coincide com teoria pois o efeito do mancal defeituoso se torna mais evidente em regiões mais próximas do motor.

6.1.3 – Avaliação geral e matrizes de confusão

Determinaremos as matrizes de confusão para os mancais não invertido e invertido relativos ao classificador de número de árvores N que realizou a detecção mais eficaz de erros em cada caso. A determinação desse classificador poderia, num primeiro instante, ser realizada pela observação das médias simples entre os acertos dos três mancais representados nas figuras 6.2 e 6.4.

No entanto, utilização da média aritmética consideraria, por exemplo, que uma árvore com 33.3% de acerto para os mancais 1, 2 e 3 seria tão eficaz quanto uma árvore com 0% de acerto para os mancais 1 e 2 e 100% de acerto para o defeito C. Isso se deve à linearidade da média simples. Por isso, propomos a utilização de uma função convexa, que atribua pesos idênticos aos defeitos de cada mancal. Para isso, recorreremos à média geométrica.

Representamos na figura 6.5 a média geométrica tomada entre os acertos dos três mancais para cada uma das 4 curvas expostas nas figuras 6.2 e 6.4.

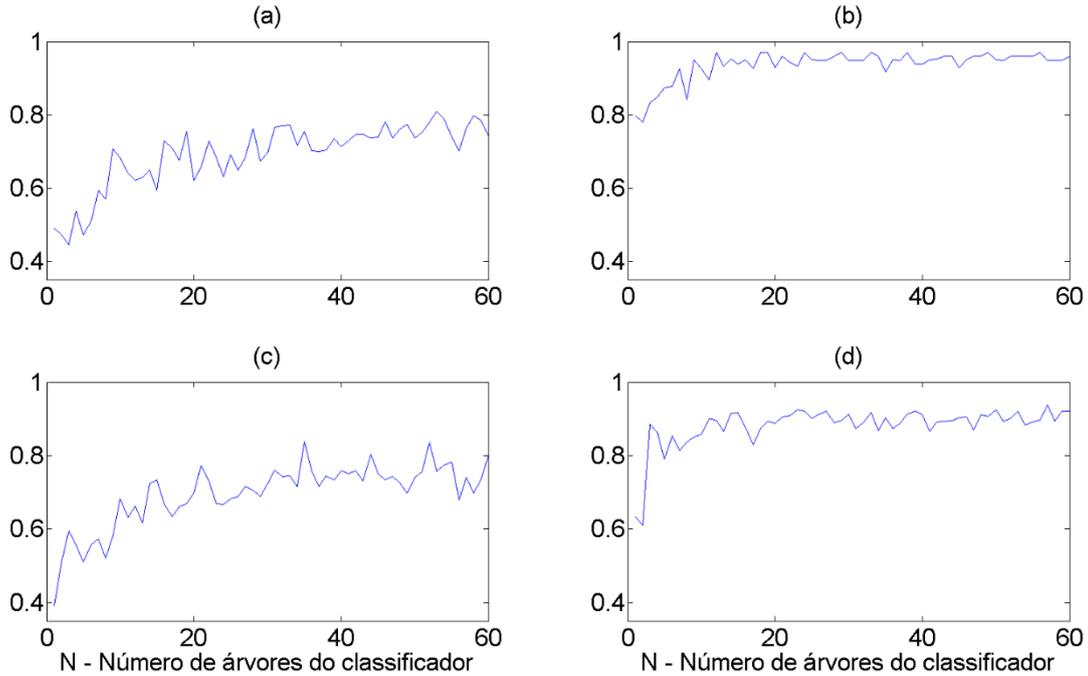


Figura 6.5 – Score encontrado nos casos:
(a) Mancal não invertido e invertido (c), sem variáveis empíricas.
(b) Mancal não invertido e invertido (d), com variáveis empíricas.

As curvas medem uma avaliação do diagnóstico geral para cada caso, considerando que o prejuízo gerado no erro de classificação é idêntico para os três tipos de falhas. Se informações concernentes ao custo de reparo ou à incidência de cada erro forem levantadas futuramente, será possível obter resultados que individualizem cada tipo de falha. O algoritmo de *random forest* admite, como um de seus argumentos, uma matriz de pesos $(a_{ij})_{N \times N} = A$, na qual o termo de índice “ij” indica o custo relativo de se errar o diagnóstico de “j” classificando-se a falha na classe “i” para “i” diferente de “j” e os termos diagonais “ii” indicam o quão importante é o acerto na classificação de “i” em relação às demais falhas. A apresentação da média geométrica seria alterada ponderando-se os acertos por expoentes iguais aos termos diagonais da matriz de pesos: $a_{11}+a_{22}+a_{33} \sqrt{X^{a_{11}} \cdot Y^{a_{22}} \cdot Z^{a_{33}}}$ onde X, Y e Z são iguais ao percentual total de acertos dos defeitos de classe 1, 2 e 3 respectivamente.

Assim, podemos notar que a média geométrica usada no projeto para a avaliação do *score* resultante entre os três tipos de falhas é um caso particular da função de Cobb-Douglas [9] na qual os expoentes de cada termo são iguais a $\frac{1}{3}$. Por isso a média geométrica é uma forma coerente de unir as avaliações de cada defeito em um único

gráfico: na função de Cobb-Douglas com expoentes iguais a taxa de substituição marginal de uma classe de erro i por outra classe de erro j é constante para todas as classes com i e j iguais a 1, 2 ou 3.

Finalmente, representamos as matrizes de confusão utilizando, em cada caso, o classificador com o número de árvores que gerou o maior *score* em cada curva. Os classificadores são exibidos na tabela 6.3 juntamente com a pontuação máxima encontrada em cada situação destacada.

Melhor score (S) e número de árvores respectivo (N)	Sem variáveis empíricas	Com variáveis empíricas
Mancal não invertido	S = 0.7807, N = 57	S = 0.9523, N = 60
Mancal invertido	S = 0.7237, N = 56	S = 0.9040, N = 18

Tabela 6.3 – Número de árvores dos classificadores com melhor *score* e *score* respectivo.

Representando-se as matrizes de confusão para cada um dos 4 casos, obtemos a tabela 6.4. O score calculado na tabela 6.3 também pode ser encontrado calculando-se a média geométrica dos termos da diagonal da matriz de confusão.

Mancal não invertido									
Sem variáveis	N = 57	1	2	3	Com variáveis	N = 60	1	2	3
	1	81%	12%	7%		1	95%	5%	0
	2	4%	87%	9%		2	3%	97%	0
	3	16%	16%	68%		3	1%	5%	94%
Mancal invertido									
Sem variáveis	N = 56	1	2	3	Com variáveis	N = 18	1	2	3
	1	79%	14%	7%		1	92%	8%	0
	2	7%	87%	6%		2	6%	92%	2%
	3	15%	29%	56%		3	5%	7%	88%

Tabela 6.4 – Matriz de confusão – Mancal invertido e não invertido, com e sem o uso de variáveis empíricas.

Assim, conforme já concluído, podemos observar na figura 6.4 que as variáveis empíricas possuem não apenas o efeito de aumentar os índices de acertos: também

reduzem significativamente os erros nos quais o defeito A é reconhecido como o defeito C pelo classificador.

Os dois tipos de erros são ligados entre si, conforme já exposto: as falhas na gaiola geram sinais que modulam os sinais de falhas no elemento rolante. Assim, as variáveis empíricas solucionam significativamente os problemas gerados pela ligação entre esses dois tipos de falhas.

Também podemos observar, novamente, uma sutil queda nos acertos do mancal invertido em relação ao mancal não invertido tanto para o caso que utiliza variáveis externas quanto nos casos que não as utilizam, isso reafirma a conclusão de que sinais amostrados em posições mais distantes do motor tendem a gerar piores resultados no processo de classificação.

Finalmente, vamos realizar uma análise detalhada nas classificações incorretas, procurando identificar o padrão de ocorrência das mesmas.

6.1.4 – Frequências relativas aos erros de classificação

Finalizamos a análise do presente tipo de classificador com a caracterização dos erros encontrados durante os diferentes processos de classificação realizados. Para isso, tomaremos o histograma do percentual de erros em função das frequências de rotação para cada um dos quatro casos tomando-se todas as falhas de classificação obtidas para classificadores com número de árvores de decisão maiores ou iguais a $N = 30$. Esse valor é escolhido pois consideramos que, em todos os casos, a partir desse valor de N , as classificações atingem bons percentuais de acertos de maneira estável.

Primeiramente, analisaremos os histogramas relativos a cada tipo de falha possível (falha da gaiola – defeito A, falha na pista externa – defeito B e falha no elemento rolante – defeito C). Os histogramas são representados em intervalos de 5 Hz e são representados para os casos de mancal não invertido e invertido, com e sem o uso de variáveis empíricas na figura 6.6.

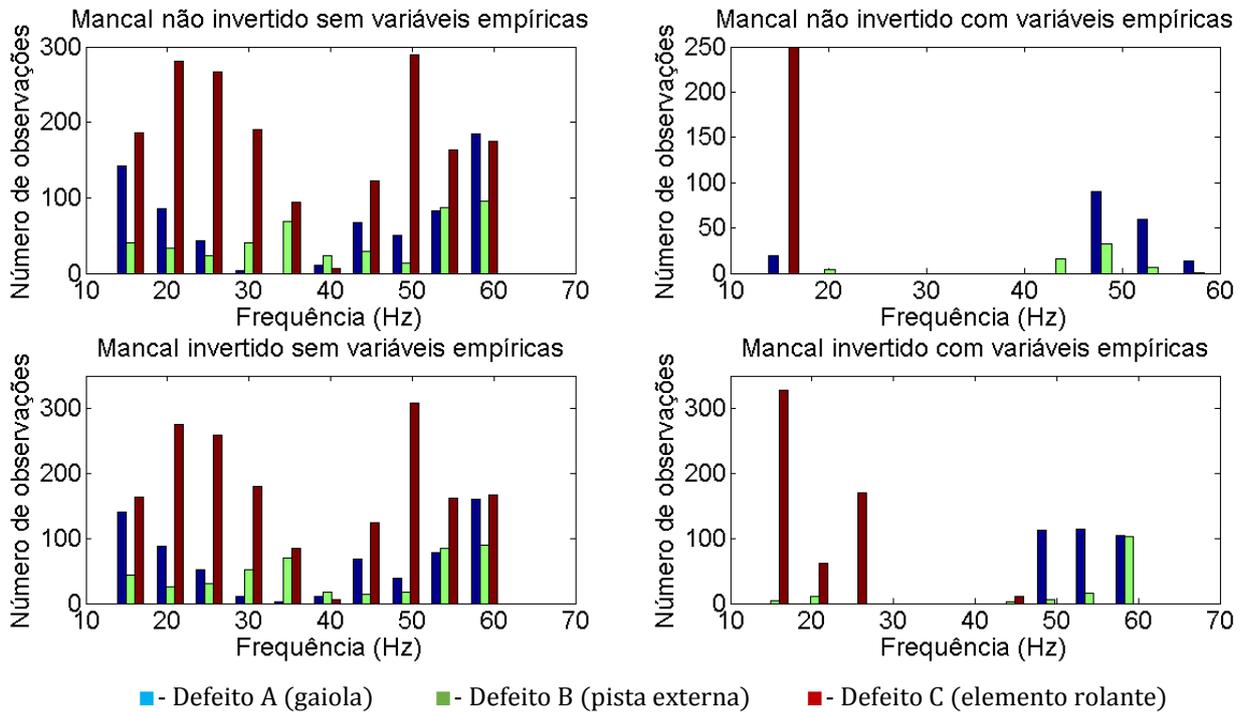


Figura 6.6 – Histogramas com erros obtidos pelo classificador para cada mancal com falha.

A partir do histograma podemos tomar um conjunto de conclusões. Os histogramas obedecem um padrão bem definido e, por isso, podem ser utilizados a nível industrial para se determinar a frequência de operação da máquina rotativa que maximiza a capacidade de diagnóstico do classificador. Tal padrão pode ser justificado de diversas formas:

- Existe uma frequência ideal para a efetividade de classificações em torno de 40 Hz para as quatro análises realizadas, o que é coerente com a existência de um padrão para os erros de classificação. Após a aplicação das variáveis empíricas, a faixa entre 30 Hz e 45 Hz torna-se ideal para a operação da máquina.
- Podemos observar que, antes da utilização de variáveis empíricas, as falhas de gaiola e elemento rolante ocorreram em frequências similares, atingindo máximos ao redor de 20 Hz e 50 Hz. A aplicação de variáveis empíricas ao classificador foi capaz de desacoplar os dois erros de classificação, conforme já exposto

anteriormente. Com efeito, o acréscimo de variáveis estratégicas ao classificador concentrou as falhas de classificação em frequências mais altas, centradas em 50 Hz deixando a faixa de frequências ao redor de 15 Hz como aquela na qual a falha do defeito A (falha na gaiola) tem maior chance de ocorrer.

- Podemos notar que as falhas no defeito B (falha na pista externa) já ocorrem de forma menos acentuada antes da aplicação de variáveis empíricas ao classificador. O padrão de tal falha é relativamente bem distribuído na faixa de frequências analisada, encontrando um leve mínimo em 40 Hz. O aprimoramento do classificador com variáveis empíricas concentra a frequência na qual a falha na pista externa não é bem detectada em regiões próximas de 55 Hz.
- Os erros no diagnóstico de problemas do elemento rolante (defeito C) foram os menos reduzidos após a aplicação de variáveis empíricas e, em todos os casos, apresentou uma concentração nas regiões de baixas frequências do histograma, ao redor de 20 Hz.

As conclusões acima tomadas são constantes tanto para o caso do mancal não invertido quanto para o caso do mancal invertido o que indica a existência de um padrão nos histogramas. Assim, podemos notar, de forma geral, que o classificador *random forest* foi, efetivamente, uma escolha adequada para a boa classificação dos defeitos nos mancais de rolamento. Além disso, em todas as análises, podemos observar de forma clara a melhoria que o acréscimo da curtose, da assimetria, do valor K e do valor de pico ao classificador pode gerar.

Logo, as primeiras análises foram desenvolvidas no sentido de se considerar isoladamente os mancais invertido e não invertido. Sendo positivos os resultados, pode-se prosseguir para a penúltima etapa no intuito de se desenvolver um classificador universal, capaz de distinguir falhas em cada mancal e falhas de desalinhamento. Trata-se de um classificador que, além de distinguir problemas em cada mancal de rolamento específico, é capaz de distinguir quais dos dois mancais (invertido ou não invertido) apresenta falhas.

6.2 – Distinção de falhas nos mancais invertido ou não invertido

Este classificador considera os problemas no mancal invertido e no mancal não invertido de forma conjunta. Assim, existem seis saídas possíveis: falhas na gaiola, elemento rolante ou pista externa para cada um dos dois mancais – invertido e não invertido.

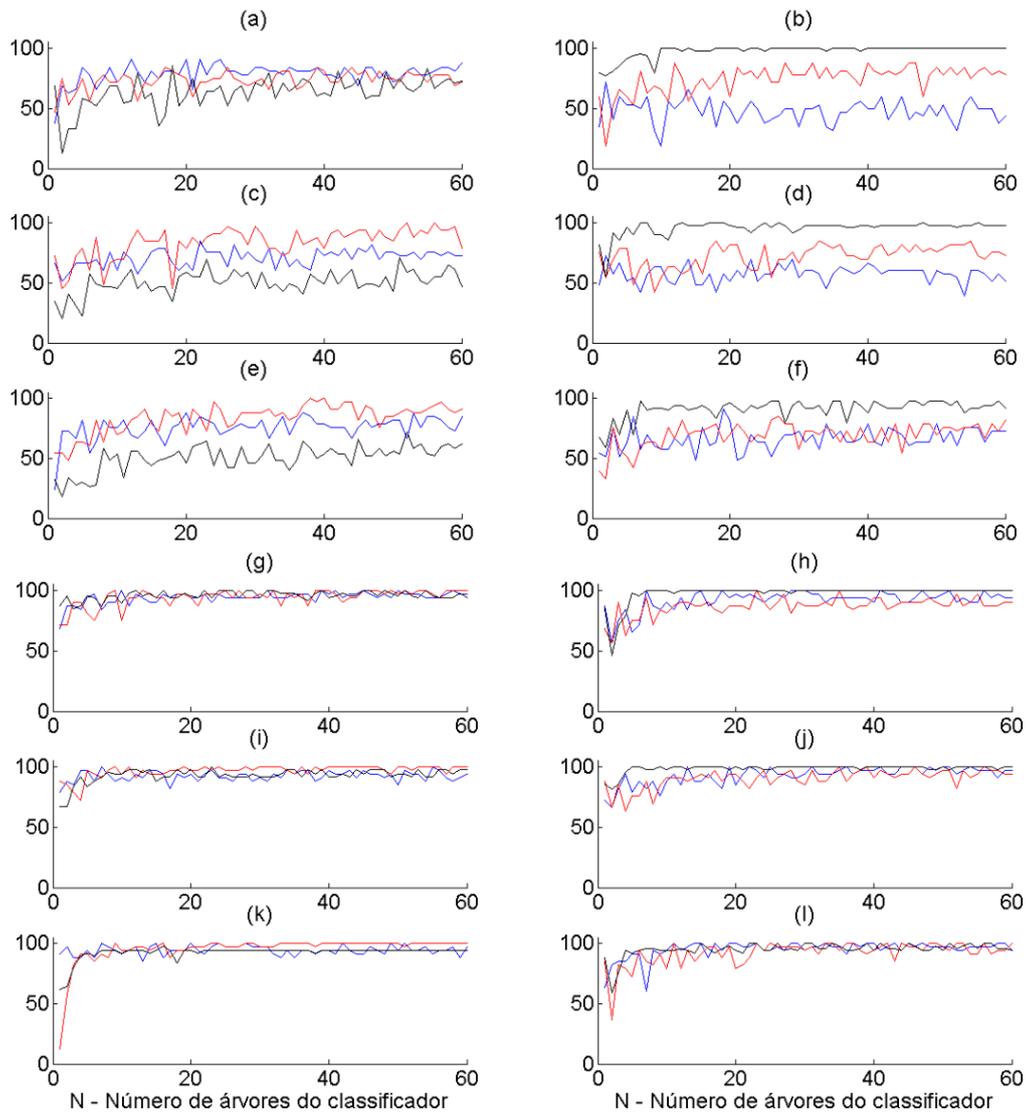
Notemos que, neste caso, utilizamos mais termos na entrada do classificador pois devemos utilizar os parâmetros extraídos de todos os sensores e não apenas dos sensores relativos a um determinado mancal.

6.2.1 – Percentuais de acertos

O segundo tipo de classificador desenvolvido possuirá também a capacidade de localizar o mancal da falha em questão. Assim, a saída do classificador poderá se dividir em 6 casos distintos:

- Defeito A (problema na gaiola) no mancal não invertido
- Defeito B (problema na pista externa) no mancal não invertido
- Defeito C (problema no elemento rolante) no mancal não invertido
- Defeito A (problema na gaiola) no mancal invertido
- Defeito B (problema na pista externa) no mancal invertido
- Defeito C (problema no elemento rolante) no mancal invertido

Na primeira análise realizada, determinamos as curvas de acertos para cada um dos problemas possíveis, demonstrando os três acertos percentuais relativos ao mancal invertido em um gráfico e os três acertos percentuais relativos ao mancal não invertido em outro gráfico para cada um dos três conjuntos de treinamento utilizados (SET1, SET2 e SET3). Neste caso, os três conjuntos são calculados da mesma forma que aquela ilustrada na figura 5.1 e são formados pela união dos conjuntos no caso do mancal invertido e no caso do mancal não invertido. Assim, os primeiros resultados são expostos nas figura 6.7 para os casos, respectivamente, em que variáveis empíricas não são utilizadas e em que variáveis empíricas são utilizadas.



■ - Defeito A (gaiola) ■ - Defeito B (pista externa) ■ - Defeito C (elemento rolante)

Figura 6.7. Acertos (%) –Análise conjunta de mancais.

Figuras 6.7 e 6.8:

Primeira coluna – (a), (c), (e), (g), (i) e (k): Falhas no mancal não invertido.

Segunda coluna – (b), (d), (f), (h), (j) e (l): Falhas no mancal invertido.

Primeira linha – (a) e (b): SET1 – Sem variáveis empíricas.

Segunda linha – (c) e (d): SET2 – Sem variáveis empíricas.

Terceira linha – (e) e (f): SET3 – Sem variáveis empíricas.

Quarta linha – (g) e (h): SET1 – Com variáveis empíricas.

Quinta linha – (i) e (j): SET2 – Com variáveis empíricas.

Sexta linha – (k) e (l): SET3 – Com variáveis empíricas.

Os percentuais obtidos antes sem a utilização de variáveis empíricas e com a utilização de variáveis empíricas são, de fato, similares àqueles obtidos nos classificadores de mancal individuais encontrados na etapa anterior, com uma sutil diferença para o caso em que variáveis empíricas são utilizadas: neste caso, os maiores

acertos de diagnóstico ocorrem para o caso do defeito C (falha no elemento rolante) enquanto os menores índices de acerto ocorrem para o caso do defeito A enquanto o oposto ocorre para os classificadores gerados na seção anterior. No caso em que variáveis empíricas não são utilizadas, os maiores índices de acerto tendem a ocorrer para o defeito A e os menores para o defeito C de forma similar àquela encontrada nos classificadores de mancais individuais.

No entanto, apesar de tais alterações, os resultados são coerentes: conforme já exposto, o sinal de falha na gaiola se confunde com sinal de falha no elemento rolante em todos os casos pois este é modulado por aquele. Notando-se que, para cada um dos casos (com e sem a utilização de variáveis empíricas), não há grandes variações nos percentuais de acerto encontrados, podemos também aqui resumir os gráficos encontrados tomando a média entre os conjuntos SET1, SET2 e SET3 para os três classificadores, conforme podemos observar na figura 6.8 (sem variáveis empíricas) e 6.9 (com variáveis empíricas).

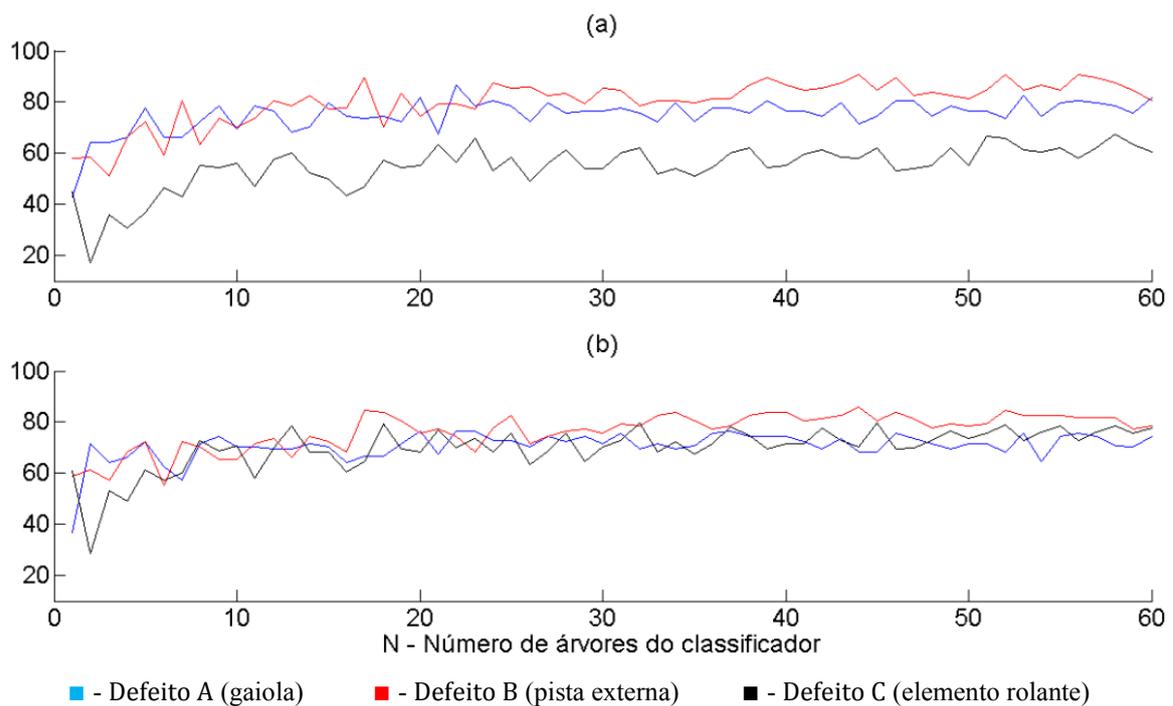


Figura 6.8. Acertos médios no classificador de mancais conjunto (%) – Sem variáveis empíricas.
 (a) – Acertos médios (média entre SET1, SET2 e SET3) – Falhas no mancal não invertido.
 (b) – Acertos médios (média entre SET1, SET2 e SET3) – Falhas no mancal invertido.

Neste caso, apesar de a teoria prever, conforme já mencionado, um maior índice médio de acertos no caso do mancal não invertido, podemos encontrar, nas curvas expostas em 6.8, o oposto: índices de acertos mais altos, notoriamente para falhas

relativas ao defeito C (elemento rolante), são mais baixas e mais estáveis, no sentido de apresentarem, visivelmente, variações menos bruscas. Também neste caso observa-se uma significativa melhora nos acertos médios após a adição de variáveis empíricas ao classificador conforme podemos observar na figura 6.9.

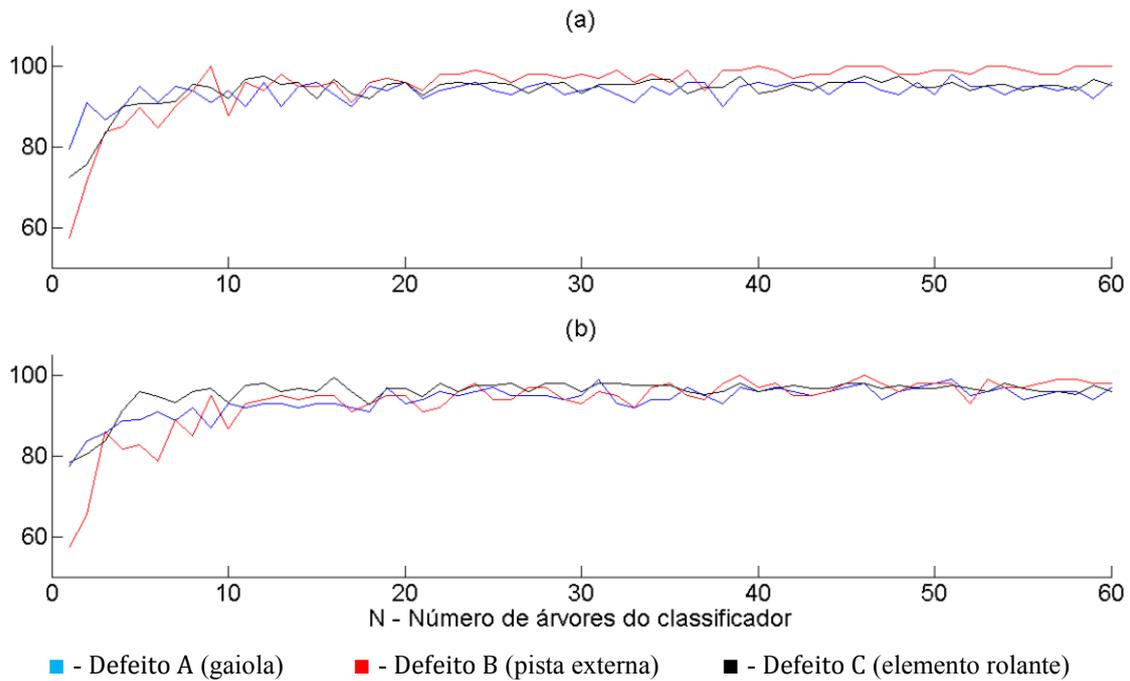


Figura 6.9. Acertos médios no classificador de mancais conjunto (%) – Com variáveis empíricas.
(a) – Acertos médios (média entre SET1, SET2 e SET3) – Falhas no mancal não invertido.
(b) – Acertos médios (média entre SET1, SET2 e SET3) – Falhas no mancal invertido.

As mesmas observações com relação aos acertos para cada mancal podem ser feitas após se observar os gráficos de acertos médios no caso onde se utilizam variáveis empíricas no treinamento do classificador: há uma maior tendência de se diagnosticar o defeito A (falha na gaiola) corretamente nos casos onde se analisa os sinais do mancal não invertido e o oposto ocorre diante das falhas de mancal invertido: os acertos mais frequentes tendem a ocorrer para o defeito C (falha no elemento rolante).

Comparando-se visualmente com o caso anterior (classificador de mancais individuais), podemos inferir que, em todos os resultados, este sistema de classificação possui índices de acerto maiores que o classificador da presente seção (detector de falhas nos dois mancais simultaneamente). Com efeito, existe uma tendência de se obter menores índices de acertos em classificadores mais complexos. No entanto, isso não comprometeu a eficácia do classificador: altos índices de acertos foram encontrados após o acoplamento de variáveis empíricas. Assim, podemos prosseguir para a análise dos

scores e das matrizes de confusão, que permitirá uma comparação qualitativa e formal com o experimento da seção anterior.

6.2.2 – Avaliação geral e matrizes de confusão

A mesma análise realizada em 6.2 é realizada nesta seção. Primeiramente, demonstramos o *score* geral obtido para os dois classificadores gerados (classificador de mancais conjuntos treinado com e sem variáveis empíricas), calculado da seguinte forma:

$$\sqrt{\prod_{k=1}^6 a_{kk} X_1^{a_{11}} \cdot Y_1^{a_{22}} \cdot Z_1^{a_{33}} \cdot X_2^{a_{44}} \cdot Y_2^{a_{55}} \cdot Z_2^{a_{66}}}$$

Onde:

- X_1 e X_2 são os índices de acertos médios para o defeito A (falha na gaiola) no mancal não invertido e invertido respectivamente.
- Y_1 e Y_2 são os índices de acertos médios para o defeito B (falha na pista externa) no mancal não invertido e invertido respectivamente.
- Z_1 e Z_2 são os índices de acertos médios para o defeito B (falha no elemento rolante) no mancal não invertido e invertido respectivamente.
- a_{kk} , para $k = 1, 2, 3, 4, 5$ e 6 , são iguais a 1 (considerando-se o mesmo peso para todas as falhas, conforme argumentado na seção 6.2, onde também se justifica a utilização da função média geométrica ponderada (Cobb-Douglas) na determinação do score).

Os resultados obtidos são exibidos na figura 6.10.

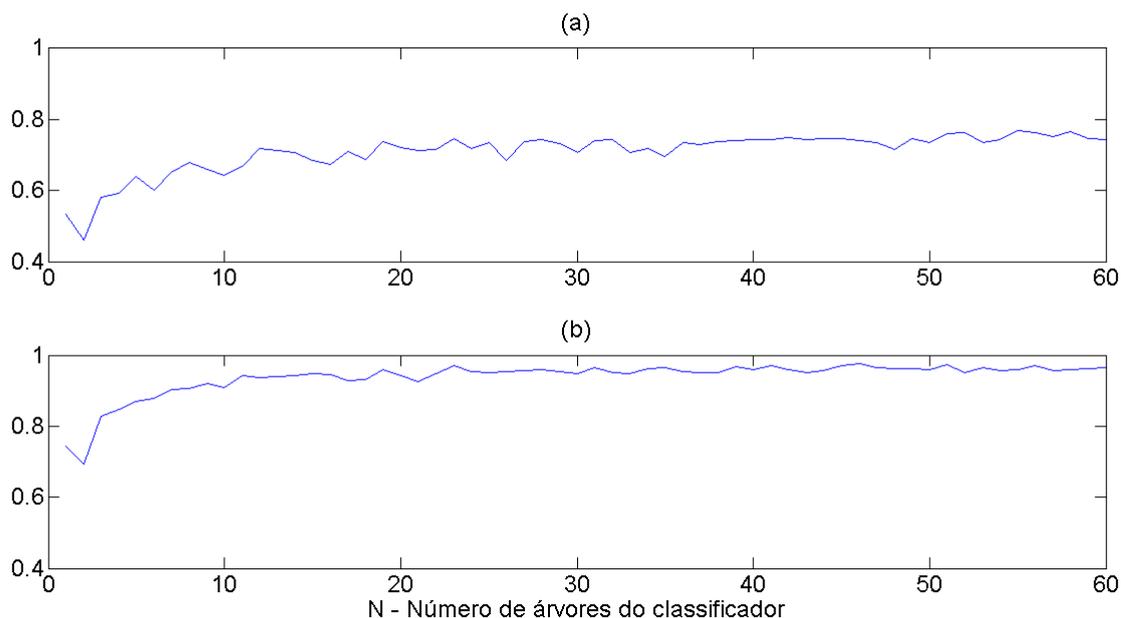


Figura 6.10. Score para cada um dos dois classificadores – dois mancais.
(a) – Sem variáveis empíricas
(b) – Com variáveis empíricas.

A partir da figura 6.10 podemos obter o número de árvores do classificador ideal para cada um dos dois casos e, neste ponto, demonstraremos as matrizes de confusão (tabela 6.5).

- Maior *score* encontrado para o classificador sem variáveis empíricas: 0.77 para 55 árvores no classificador.
- Maior *score* encontrado para o classificador com variáveis empíricas: 0.98 para 46 árvores no classificador.

Os resultados são coerentes: é necessário um maior número de árvores para o classificador que não utiliza variáveis empíricas (estabilização mais lenta) para se obter um *score* máximo significativamente menor (0.77 comparado a 0.98).

As matrizes de confusão respectivas para cada um dos dois classificadores com o número de árvores especificado é demonstrado na tabela 6.5.

Classificador simultâneo dos dois mancais – sem variáveis empíricas							
N = 55 Score = 0.77		Não invertido			Invertido		
		Mancal1	Mancal2	Mancal3	Mancal1	Mancal2	Mancal3
Não invertido	Mancal1	82%	15%	3%	0	0	0
	Mancal2	3%	88%	9%	0	0	0
	Mancal3	20%	24%	56%	0	0	0
Invertido	Mancal1	0	0	0	58%	30%	12%
	Mancal2	0	0	0	18%	79%	3%
	Mancal3	0	0	2%	0	0	98%
Classificador simultâneo dos dois mancais – com variáveis empíricas							
N = 46 Score = 0.98		Não invertido			Invertido		
		Mancal1	Mancal2	Mancal3	Mancal1	Mancal2	Mancal3
Não invertido	Mancal1	91%	9%	0	0	0	0
	Mancal2	0	100%	0	0	0	0
	Mancal3	0	6%	94%	0	0	0
Invertido	Mancal1	0	0	0	97%	3%	0
	Mancal2	0	0	0	0	100%	0
	Mancal3	0	0	2%	0	0	97%

Tabela 6.5. Matrizes de confusão para classificadores que distinguem defeitos dos dois mancais para os casos onde não se utiliza variáveis empíricas no treinamento e para o caso onde tais variáveis são usadas.

As matrizes de confusão também revelam uma significativa melhora no rendimento do classificador após se utilizar variáveis empíricas. Além disso, podemos observar, a partir dos termos das matrizes de confusão em negrito que os classificadores obtidos são capazes de desacoplar, de forma praticamente perfeita, quaisquer erros que relacionem um mancal de rolamento ao outro mancal. Isso corrobora com os altos percentuais de acertos obtidos: o efeito de se unir conjuntos de treino e teste relativos aos mancais de rolamento invertido e não invertido não gera praticamente nenhuma dificuldade de distinção ao classificador.

Apesar de os padrões dos defeitos para os sinais encontrados serem, teoricamente, similares para o mancal invertido e para o mancal não invertido, é possível que a perfeita distinção ocorra devido à diferença de potências de ambos os sinais encontrados, que interfere nos valores de pico fornecidos para o classificador em ambas as análises. De

posse de tal resultado, pode-se prosseguir para a análise do histograma de erros nas frequências, que será realizado na próxima seção.

6.2.3 – Frequências relativas aos erros de classificação

Os histogramas de erros encontrados são exibidos na figura 6.11 e foram também gerados segundo o procedimento descrito em 6.3. Separamos os histogramas para os casos de erros no diagnóstico de mancais não invertidos defeituosos e mancais invertidos defeituosos com a finalidade de facilitar a visualização.

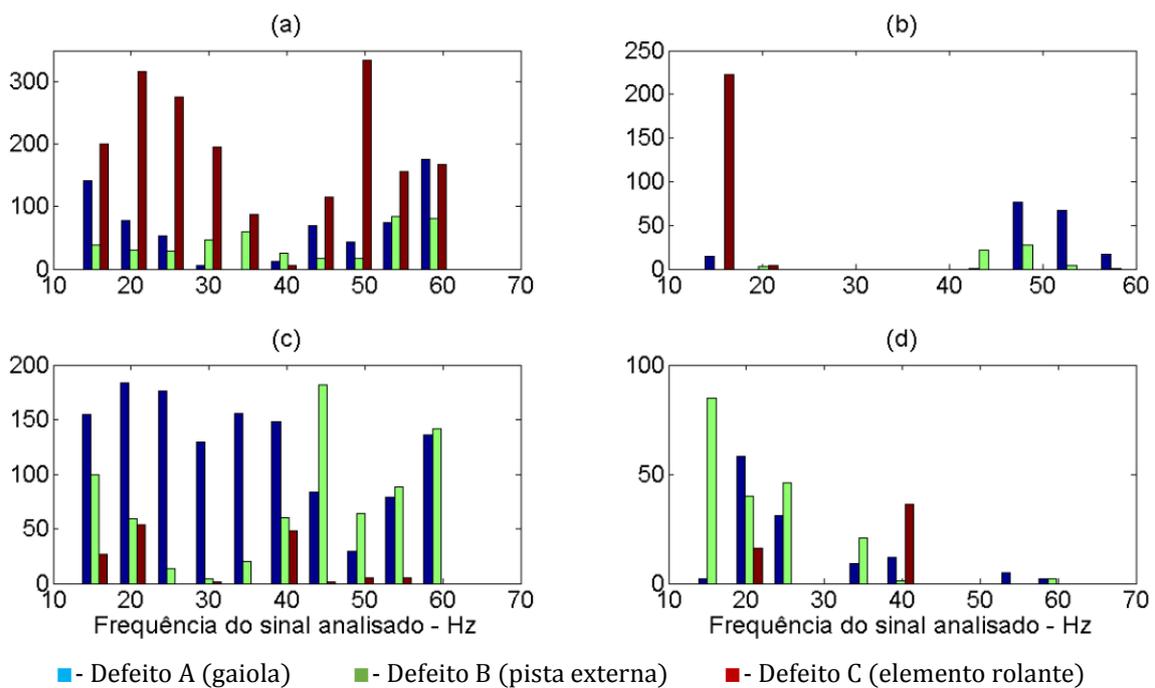


Figura 6.11 – Histogramas com erros obtidos para os dois classificadores.

- (a) Classificador sem variáveis empíricas, erros de classificação no mancal não invertido
- (b) Classificador com variáveis empíricas, erros de classificação no mancal não invertido
- (c) Classificador sem variáveis empíricas, erros de classificação no mancal invertido
- (d) Classificador com variáveis empíricas, erros de classificação no mancal invertido

O histograma também é uma ferramenta que permite a visualização da grande redução de erros obtidas após o acoplamento de variáveis empíricas. Os histogramas relativos aos erros de detecção dos mancais não invertidos possuem os mesmos padrões dos histogramas individuais demonstrados na seção anterior no sentido de que um mínimo de ocorrência de erros para os três tipos de falhas de mancais ocorre centrado na frequência de 40 Hz. Além disso, também encontra-se, para o caso dos histogramas relativos ao mancal não invertido (histogramas (a) e (b)), um padrão de falhas nos mancais

1 e 3 (gaiola e elemento rolante) concentrados em altas e baixas frequências que é reduzido e concentrado em altas frequências após o acoplamento de variáveis empíricas.

Já nos histogramas relativos ao mancal invertido, não se encontra o mesmo padrão: no caso em que não se utilizam variáveis empíricas, uma concentração mínima de erros de classificação é encontrada em 50 Hz e, após a aplicação de variáveis empíricas, o erro passa a se concentrar nas regiões de 30 Hz e 50 Hz.

De todo modo, podemos observar que em torno de 40 Hz, com a utilização de variáveis empíricas, os erros de classificação são minimizados para quase todos os casos e são baixos para o caso em que analisamos o mancal invertido. Assim, tal frequência continua representando um parâmetro de operação ideal para o simulador de falhas no sentido de minimizar os erros de classificação.

Diante dos resultados positivos obtidos, podemos prosseguir para a última etapa do projeto: o desenvolvimento do classificador universal, que considerará, também, as falhas relacionadas aos eixos. Os parâmetros relativos à detecção de tais falhas serão adicionados aos parâmetros utilizados até aqui, e um classificador com mais saídas possíveis será desenvolvido e analisado segundo os mesmos procedimentos.

6.3 – Classificador universal – distinção entre falhas nos eixos e nos mancais de rolamento

Os sinais presentes na base de dados para os casos de desalinhamento e desbalanceamento estão em maior número que aqueles relativos a falhas nos mancais de rolamento. Isso ocorre (conforme pode-se observar na tabela 2.1) porque diferentes distâncias são utilizadas na geração de sinais de desalinhamento e diferentes pesos são utilizados para o desbalanceamento. Para cada distância e para cada peso tem-se à disposição uma quantidade aproximada de 50 sinais (num total maior que 200 sinais) ao passo que, para cada falha de mancal, apenas 50 sinais estão presentes, sem a subdivisão em diferentes casos.

Ocorre que a utilização de todos os sinais de desalinhamento e desbalanceamento no classificador poderia “viciar” o mesmo em não julgar o sinal como uma falha de mancal, pois poucas amostras relativas a esses casos seriam apresentadas ao se comparar com as amostras relativas aos diferentes defeitos nos eixos. Trata-se de uma situação de desbalanceamento de variáveis de treino, que deve ser evitada, restringindo-se os dados

de treino a uma quantidade uniforme para cada tipo de classificação. Assim, os sinais que serão considerados neste classificador são:

- Sinais de falhas relativas ao defeito A (falha na gaiola), na posição não invertida
- Sinais de falhas relativas ao defeito B (falha na pista externa) na posição não invertida
- Sinais de falhas relativas ao defeito C (falha no elemento rolante) na posição invertida
- Sinais de falhas relativas ao defeito A (falha na gaiola), na posição invertida
- Sinais de falhas relativas ao defeito B (falha na pista externa) na posição invertida
- Sinais de falhas relativas ao defeito C (falha no elemento rolante) na posição invertida
- Sinais relativos ao desalinhamento vertical de 1,9 mm
- Sinais relativos ao desalinhamento horizontal de 2 mm
- Sinais relativos ao desbalanceamento de 35 g

O classificador buscará distinguir defeitos de desalinhamento horizontal dos defeitos de desalinhamento vertical. No caso do desalinhamento, tomamos as maiores distâncias disponíveis na base de dados (1,9 mm para o caso vertical e 2 mm para o caso horizontal) e, para o desbalanceamento, tomamos os sinais relativos àquele gerado pela massa de maior magnitude (35 g).

Dessa forma, resumidamente, utilizamos na análise os sinais de falhas mais agudas (maior distância no desalinhamento e maior peso de desbalanceamento) entre a grande quantidade fornecida na base de dados, que não será utilizada integralmente, no intuito de se evitar problemas de vício de classificação.

Demos preferência, inicialmente, ao diagnóstico de falhas de desalinhamento e desbalanceamento mais graves pois todos os classificadores desenvolvidos foram gerados em ordem estritamente crescente de complexidade.

No entanto, a utilização dos sinais de falhas menos significativas da base de dados pode ser realizada progressivamente, tomando-se desalinhamentos em ordem decrescente de distância e desbalanceamentos em ordem decrescente de massa agregada ao rotor no intuito de se verificar os limites do algoritmo desenvolvido. Tal ponto será reforçado no capítulo 7 durante a determinação de possíveis melhorias e trabalhos futuros.

6.3.1 – Percentuais de acerto obtidos

Exibiremos nesta seção os percentuais de acerto obtidos para cada uma das nove falhas listadas anteriormente em dois casos distintos: no caso em que se utilizam as variáveis empíricas no processo de treino e no caso em que tais parâmetros não são considerados. Iniciaremos demonstrando as falhas relativas aos mancais de rolamento nas figuras 6.12 e 6.13.

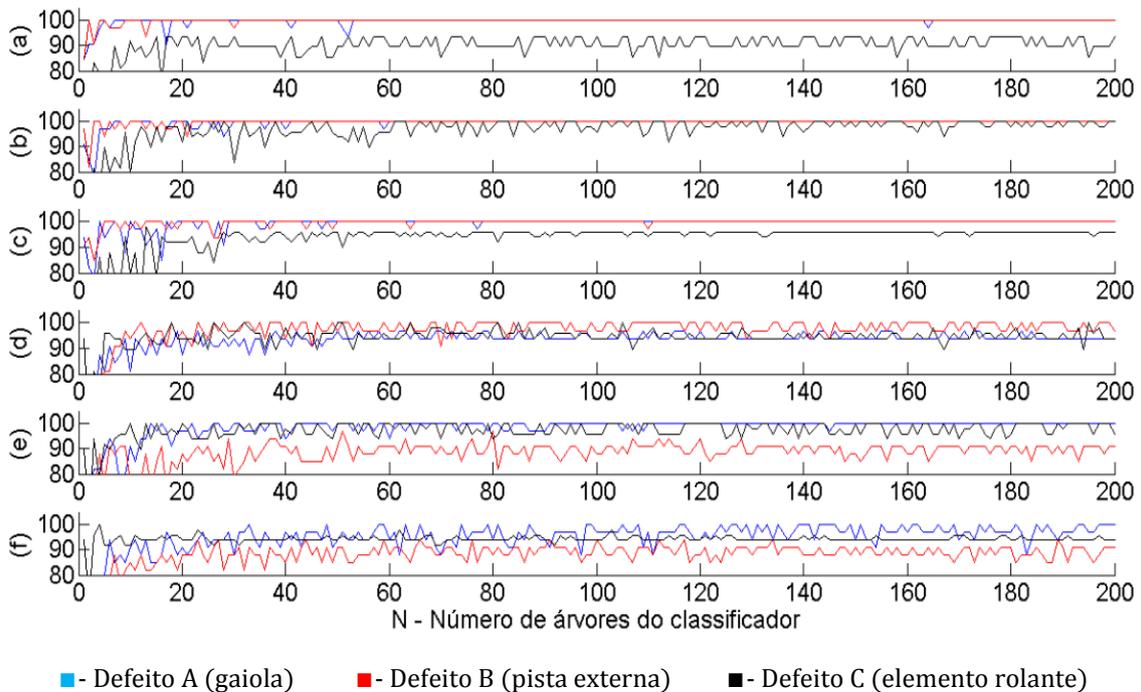


Figura 6.12. Acertos (%) – Classificador universal – mancais de rolamento sem a utilização de variáveis empíricas:

- (a) SET1 – Mancal não invertido
- (b) SET2 – Mancal não invertido
- (c) SET3 – Mancal não invertido
- (d) SET1 – Mancal invertido
- (e) SET2 – Mancal invertido
- (f) SET3 – Mancal invertido

Os resultados são exibidos apenas na faixa de acertos situada entre 80% e 100%. Podemos observar que os acertos das falhas referentes ao mancal invertido são mais instáveis, no sentido de que oscilam mais com as mudanças no número de árvores do classificador. No caso do mancal não invertido, a classificação dos mancais 1 e 2 são praticamente perfeitas e o acerto do defeito C se estabiliza rapidamente em torno de 90% para os três conjuntos considerados para o treino (SET1, SET2 e SET3).

Podemos comparar os acertos obtidos sem a utilização de variáveis empíricas com aqueles obtidos na figura 6.12.

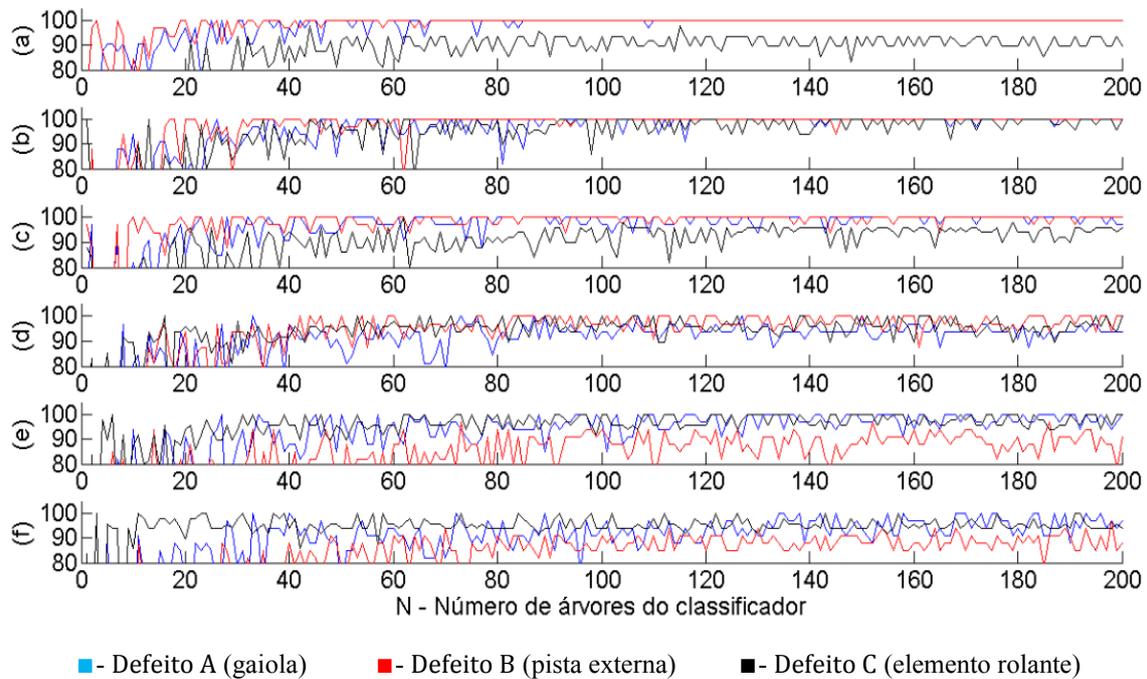


Figura 6.13. Acertos (%) – Classificador universal – mancais de rolamento com a utilização de variáveis empíricas:
 (a) SET1 – Mancal não invertido
 (b) SET2 – Mancal não invertido
 (c) SET3 – Mancal não invertido
 (d) SET1 – Mancal invertido
 (e) SET2 – Mancal invertido
 (f) SET3 – Mancal invertido

Comparando-se a figura 6.12 à figura 6.13, podemos, imediatamente, perceber variações mais bruscas no caso em que as variáveis empíricas são utilizadas sem que haja grandes variações nos percentuais de acertos. Assim, ao contrário do que ocorreu nos dois classificadores anteriormente analisados (classificador de mancais individual e classificador de mancais conjunto) temos que a utilização de variáveis empíricas se demonstrou desfavorável nesta análise.

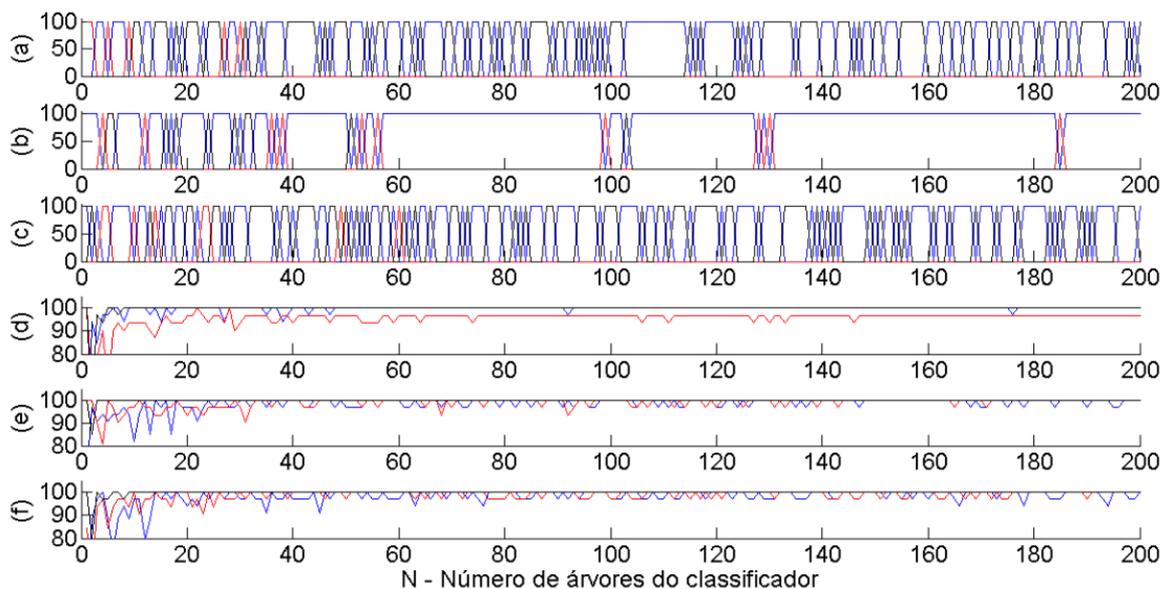
Isso se deve a dois motivos:

- A utilização de classificadores que recebem um número elevado de diferentes parâmetros de entrada tende a gerar quadros nos quais a estabilização dos mesmos é mais dificultosa: as árvores do classificador passam a ter que considerar um maior número de fatores, a variação dos votos (*bagging*) de cada uma dessas

árvores se torna maior e a uniformização dos votos pede um valor significativamente maior de N .

- Podemos comparar os resultados dos mancais sem a utilização de variáveis empíricas obtidos neste classificador com aqueles obtidos nos classificadores das seções 6.2 e 6.1. O percentual de acertos obtidos aqui, apesar da maior complexidade do classificador é maior: a única justificativa capaz de explicar a aparente contradição é a utilização das variáveis propostas em [1] – três maiores picos próximos aos três primeiros harmônicos de cada sinal, em cada um dos seis sensores. Assim, as variáveis propostas em [1] não são eficazes apenas na classificação de falhas em eixos: também são de especial utilidade na classificação de falhas em mancais de rolamento podendo, inclusive, substituir as variáveis empíricas propostas em [2] com um aumento na eficiência da classificação.

Não podemos, no entanto, alegar que a utilização de variáveis empíricas é prejudicial para o classificador como um todo sem observar seus efeitos no diagnóstico das falhas de desalinhamento e desbalanceamento e, com efeito, conforme podemos observar na figura 6.14, a utilização de variáveis empíricas é fundamental para que os problemas no eixo sejam reconhecidos corretamente.



■ - Desalinhamento vertical ■ - Desalinhamento horizontal ■ - Desbalanceamento

Figura 6.14. Percentual de acertos – desalinhamento e desbalanceamento

- (a) SET1 – Sem variáveis empíricas
- (b) SET2 – Sem variáveis empíricas
- (c) SET3 – Sem variáveis empíricas
- (d) SET1 – Com variáveis empíricas
- (e) SET2 – Com variáveis empíricas
- (f) SET3 – Com variáveis empíricas

Conclusões extremamente importantes podem ser tomadas a partir deste ponto da análise:

- A não utilização de variáveis empíricas estabiliza os resultados obtidos para os mancais de rolamento mas comprometem seriamente os percentuais de acertos das falhas, representados em (a), (b) e (c) na figura 6.14.
- Observemos de forma mais detalhada os percentuais de acerto obtidos em falhas de desalinhamento no caso em que variáveis empíricas não são utilizadas; podemos notar que o desalinhamento horizontal e o desalinhamento vertical se confundem fortemente: quando um se encontra em 100% de acertos o outro se encontra em 0 de acertos e vice-versa, os índices de acertos do desbalanceamento são extremamente baixos nesse caso. Assim, as variáveis empíricas são essenciais para que o classificador consiga distinguir os dois tipos de desalinhamento e para que as falhas de desbalanceamento sejam efetivamente reconhecidas.

Assim, daqui em diante, descartamos os resultados obtidos sem o uso de variáveis empíricas: não faz sentido tomar a média entre os conjuntos SET1, SET2 e SET3 assim como não há sentido em se calcular o *score* ou tomar a matriz de confusão para valores determinados de N pois os resultados variam muito e a não uniformidade dos mesmos não geraria conclusões corretas.

A utilização de variáveis empíricas no classificador universal é crucial pois, apesar de aumentar a variação do percentual de acertos no diagnóstico dos mancais de rolamento de forma a não comprometer os bons resultados, ela também atua de forma decisiva na boa predição dos defeitos de desbalanceamento e, principalmente, na distinção entre os desalinhamentos vertical do horizontal.

Logo, os percentuais médios de acertos entre os diferentes classificadores obtidos de diferentes conjuntos de treino e teste na validação cruzada de 3 *folds* são exibidos na figura 6.15 para o caso em que as variáveis empíricas são utilizadas.

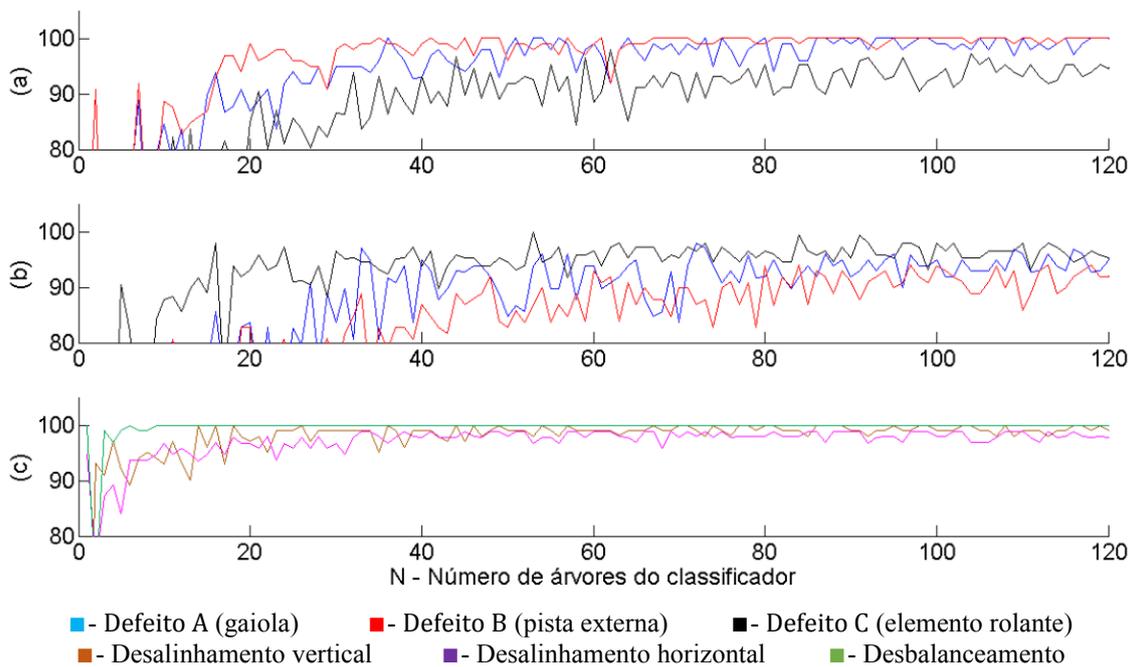


Figura 6.15. Percentual de acertos médios – classificador universal – Com variáveis empíricas
(a) Mancal não invertido
(b) Mancal invertido
(c) Falhas de desbalanceamento e desalinhamento

Podemos notar que, para um número N de árvores de decisão internas ao classificador maior ou igual a 40, os acertos médios passam a se situar na faixa entre 80% e 100% de maneira estável. Novamente podemos notar que a detecção de falhas no mancal não invertido é mais estável e gera maiores percentuais de acertos o que, conforme

já mencionado e constatado nos classificadores das seções 6.2 e 6.3, está de acordo com a teoria.

Também podemos concluir que o percentual de acertos dos problemas de desbalanceamento e desalinhamento são previstos com eficácia consideravelmente mais elevada. Com efeito, os problemas do eixo são menos complexos, por natureza, que aqueles gerados em mancais de rolamentos. Apesar disso, os problemas em mancais são mais custosos e, para se sanar tal diferença, pode-se configurar o classificador, por meio da matriz de pesos mencionada no capítulo 5, de forma a considerar que erros nos mancais são mais cruciais.

No entanto, prosseguiremos esta análise avaliando o *score* do classificador em questão levando em conta um peso idêntico para todos os tipos de falhas por meio de uma média geométrica não ponderada (função de Cobb-Douglas com expoentes iguais, conforme já mencionado nas seções anteriores).

6.3.2. Avaliação geral e matrizes de confusão

O *score* obtido para o classificador universal, com a utilização de variáveis empíricas, é demonstrado na figura 6.16. Nesse caso, todas as possíveis falhas foram consideradas levando-se em conta os mesmos pesos.

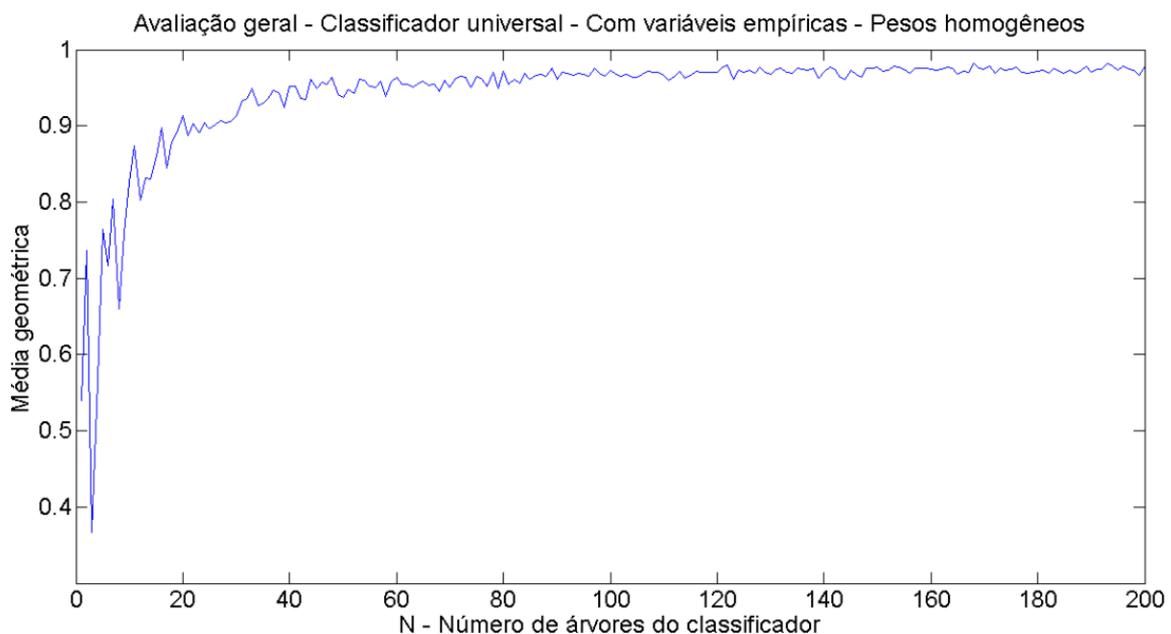


Figura 6.16. Avaliação geral do classificador

A partir de $N = 60$, aproximadamente, o *score* se estabiliza e atinge um valor máximo para $N = 193$ de 0,9824. Notemos que, diferentemente dos classificadores das seções anteriores, trabalhamos aqui com um número de árvores variando de 1 a 200 (nas seções anteriores fizemos N variar apenas até 60). Esse tratamento foi realizado por três razões: pela complexidade maior do presente sistema, pela maior importância que o mesmo apresenta para o projeto em geral e pela maior disponibilidade de dados obtidos nesta etapa (maior variação de N).

A matriz de confusão obtida é exibida na tabela 6.6 e aqui também calculamos a matriz de confusão de forma diferente: tomamos a média das matrizes de confusão para N maior ou igual a 60 ao invés de tomar o classificador com $N = 193$ de maior *score*. Tomar a “melhor matriz de confusão” foi um procedimento útil nas seções anteriores para se comparar o rendimento ótimo entre classificadores distintos. Porém, na presente análise, estamos observando apenas um classificador individualmente.

Matriz de confusão – Classificador universal – Com variáveis empíricas (Em %)											
$60 \leq N \leq 200$			Falha no mancal						Falhas nos eixos		
			Invertido			Não invertido			Desalinhamento		Desb.
			1	2	3	1	2	3	Vertical	Horizonta 1	
Falha no mancal	Não invertido	1	98,7	0	1,2	0	0	0	0	0	0
		2	0	99,4	0	0	0	0,6	0	0	0
		3	5,4	0,4	93,1	0,5	0,4	0	0	0	0
	Invertido	1	1,1	0	1,2	93,3	4,4	0	0	0	0
		2	0,5	0	3	8,7	87,7	0	0	0	0
		3	0	4,3	0	0,2	0,1	95,4	0	0	0
Falhas nos eixos	Desalinhamento	Vertical	0	0	0	0	0	0	98,8	1,2	0
		Horizontal	0	0	0	0	0	0	0,9	99,1	0
	Desbalanceamento	0	0	0	0	0	0	0	0	100	

Tabela 6.6. Matriz de confusão para classificador universal – com a utilização de variáveis empíricas.

Podemos observar, a partir da região em negrito da tabela 6.6, que, numa média de 140 classificadores distintos, praticamente não houve qualquer erro de classificação que confundisse uma falha de mancal com um problema relativo ao eixo (desbalanceamento ou desalinhamento), o que indica que a natureza distinta entre esses dois tipos de falhas é facilmente percebida pelo classificador.

Além disso, podemos notar que a maior incidência de erros são aqueles entre os diferentes problemas de mancais. Conforme já comentado, as naturezas dos diferentes defeitos dos mancais são extremamente próximas entre si, podendo, inclusive, um sinal de defeito ser estar diretamente correlacionado ao outro nesses casos. Isso demonstra a necessidade na realização de esforços concentrados e especializados efetuados em [2] no intuito de se compreender a natureza de cada erro individualmente para a extração dos

parâmetros de detecção de falhas adequados. Também podemos notar que não há, praticamente, falhas na predição de problemas de desbalanceamento.

De todo modo, a utilização conjunta do sistema de classificação proposto em [1], com os parâmetros relativos às falhas de desbalanceamento e desalinhamento e aqueles ligados ao diagnóstico do mancal propostos em [2] se mostrou uma poderosa ferramenta para a predição de falhas em máquinas rotativas de forma mais abrangente.

Finalmente, podemos analisar o histograma de erros de classificação, em função das frequências de rotação das máquinas rotativas na próxima seção.

6.3.3. Frequências relativas aos erros de classificação

As frequências ligadas aos erros de classificação são exibidas na figura 6.17 para os erros nos mancais invertido, não invertido e com relação aos problemas dos eixos (desbalanceamento e desalinhamento).

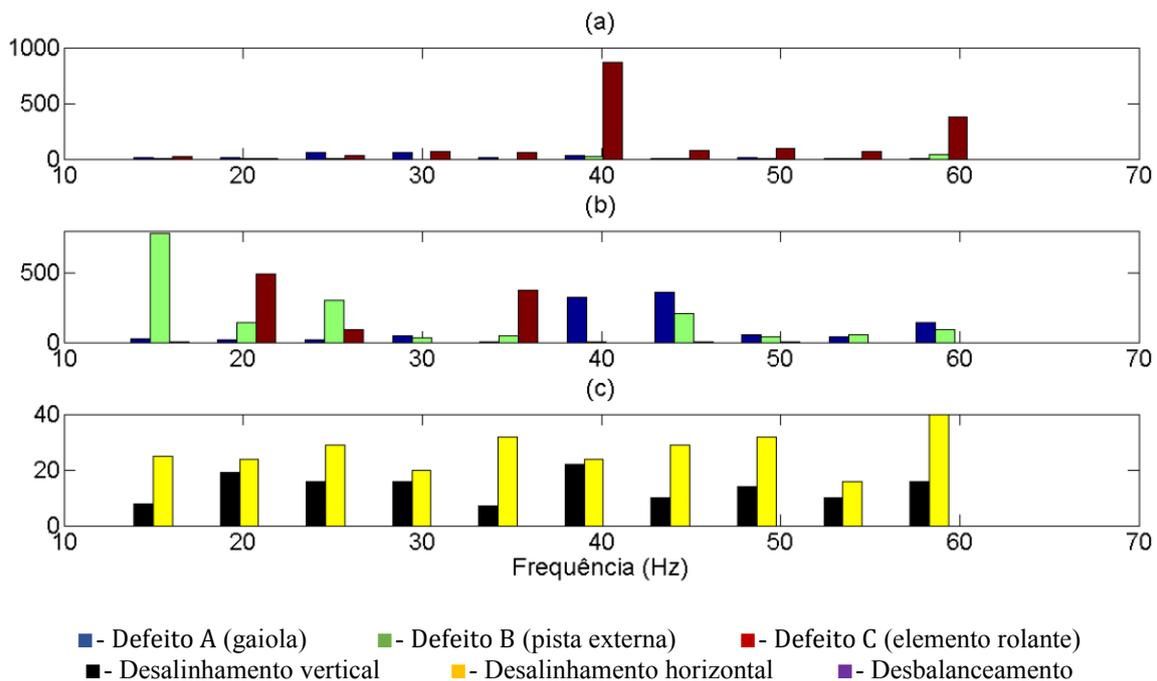


Figura 6.17. Histograma de erros de classificação
(a) Falhas no mancal não invertido
(b) Falhas no mancal invertido
(c) Falhas de desalinhamento e desbalanceamento

Conforme já constatado nas curvas de percentuais de acertos, praticamente não existem erros de classificação concernentes a falhas de desbalanceamento e podemos reafirmar isso pela visualização do histograma. Para o histograma do classificador

universal, as características ligadas à localização das falhas possuem concentrações diferentes daquelas encontradas nas seções anteriores:

- Falhas no diagnóstico de falha no elemento rolante do mancal não invertido altamente concentrada na frequência de 40 Hz.
- Falhas no diagnóstico de falha na pista externa do mancal invertido concentrada em 15 Hz.
- Falhas no desalinhamento horizontal mais frequentes que aquelas ligadas ao desalinhamento vertical.
- Falhas em ambos os desalinhamentos uniformemente distribuídos na faixa de frequências analisada (10 Hz a 60 Hz).

Assim, as conclusões podem variar de acordo com o tipo de classificador utilizado mas podem consistir em método empírico eficaz para se descobrir em qual frequência o sistema funciona de forma ótima para cada tipo diferente de defeito.

Capítulo 7

Conclusões e melhorias futuras

As etapas realizadas até o processo final obedeceram os comportamentos expostos em [2]. A capacidade de realização de boas classificações pelo método *random forest* também estão de acordo com o exposto em [1]. Com relação aos resultados finais, resumidamente, obtivemos os seguintes pontos:

- Não foi possível reproduzir a análise gráfica do sinal após a realização de todas as sequências de passos visualmente realizadas em [2] de forma automática, por meio de um programa. O procedimento de restos relativos proposto no projeto se mostrou ineficaz nesse aspecto.
- A utilização de variáveis empíricas se mostrou extremamente eficaz no aumento do índice de acertos do classificador. Além disso, mostrou-se capaz de separar as frequências típicas de erros de classificação de falhas da gaiola das frequências típicas de erros de classificação de falhas no elemento rolante. O modelo mecânico do mancal de rolamento é tal que essas duas falhas possuem a mesma natureza, sendo a falha da esfera modulada pelo sinal de falha da gaiola.
- Além disso, para o classificador universal, as variáveis empíricas também se revelaram cruciais para o seu bom funcionamento: sem a utilização das mesmas, não haveria uma correta classificação das falhas de desalinhamento e desbalanceamento e, além disso, permitiram a distinção entre falhas de desalinhamento horizontal e falhas de desalinhamento vertical juntamente com uma classificação em acertos próximos a 100% para os casos de desbalanceamento.
 - Resumidamente: podemos afirmar que as variáveis empíricas de diagnóstico de mancais foram também úteis no diagnóstico de problemas de desalinhamento e desbalanceamento e vice-versa: as variáveis propostas em [1] demonstraram uma tendência a auxiliar e aprimorar a classificação dos mancais de rolamento.

- A mudança de conjuntos de treino e teste não variou significativamente os resultados obtidos. Assim, o sistema de *random forest* apresentou um alto grau de robustez em seu funcionamento com relação a uma variação nos conjuntos de treino e teste.
- Existe uma leve queda nos percentuais de acertos ao se analisar o mancal invertido (mais distante do motor).
- A utilização de histogramas permite a obtenção de frequências de operação do rotor nas quais a classificação é otimizada para cada tipo diferente de defeito. No entanto, as informações nele obtidas são empíricas e os padrões obtidos variam para cada tipo diferente de sistema de classificação.
 - Assim, o histograma é uma característica intrínseca ao tipo de classificador ou ao conjunto de classificadores analisados e permite que, numa futura aplicação, seja obtida uma visão prévia das frequências nas quais existe uma maior tendência de falhas na detecção de defeitos.
- O classificador universal foi desenvolvido com altos índices de acertos. Porém, para este classificador, a utilização de variáveis empíricas é estritamente necessária para que as falhas de desalinhamento e desbalanceamento sejam reconhecidas corretamente.

Com base nas conclusões tomadas e no conjunto de fatores verificado durante a realização do projeto, podemos propor melhorias futuras que podem ser realizadas:

- A necessidade de se utilizar um sinal de referência do filtro ANC impediu a inclusão de sinais normais no classificador: seria necessário tomar duas amostras distintas para cada frequência para se incluir a classe “normal” ao *random forest*. Com efeito, um conjunto de amostras internas ao ANC deveria existir de forma separada dos sinais normais incluídos na amostra.
 - A utilização de um filtro que não necessite de sinais de referência é uma possibilidade para a solução deste problema.
 - Uma outra possibilidade é a utilização de um simples filtro passa-alta: os efeitos observados, com o pré-processamento, se resumiram a um destaque de picos localizados em altas frequências. Assim, é possível

que o procedimento complexo de eliminação de ruído e componentes determinísticos do sinal possa ser substituído por um simples filtro individual. Tal tentativa não foi realizada aqui pois, na metodologia, procurou-se manter o procedimento proposto em [2] para o diagnóstico de defeitos em mancais de rolamento.

- O espectrograma não garante um compromisso perfeito entre a resolução de frequências e a resolução temporal em sua representação: pode-se utilizar as transformadas de Wigner-Ville [10] ou a transformada de Wavelet [11] [12] visando uma melhoria no algoritmo de curtose espectral. Informações mais aprofundadas referentes à representação do sinal no domínio do tempo-frequência podem ser constatadas em [13], [14] e [15].
- De posse da incidência ou dos preços relativos dos três tipos de defeitos de mancais, uma função de *score* alternativa na classificação pode ser proposta, juntamente com a alteração da matriz de pesos do classificador *random forest*, visando considerar que certas falhas são mais cruciais que outras.
- Foi possível concluir que a taxa de acertos em mancais não invertidos tendem a ser maiores. Assim, pode-se também desenvolver estudos futuros que relacionem a influência dos desbalanceamentos, encontrada, no escopo do presente projeto, observando-se as diferenças de resultados entre os casos de mancal invertido e mancal não invertido com o percentual de acertos encontrado pelos classificadores.
- Análises futuras que incluam no processo de classificação os sinais obtidos com indução de falhas de desbalanceamento e falhas de mancal simultaneamente podem ser desenvolvidas. Deve-se notar que a complexidade do classificador pode ser aumentada consideravelmente se levarmos em conta a possível coexistência de possíveis falhas: pode-se criar um classificador com até $2^9 = 512$ saídas. Logo, existe muito a se desenvolver na área de classificadores de máquinas rotativas.
- Uma futura análise pode ser realizada, utilizando-se a mesma base de dados obtida em [1], realizando-se um estudo dos limites do classificador universal desenvolvido. Dessa forma, no lugar da aplicação de um classificador baseado apenas nos defeitos de desalinhamento e desbalanceamento mais significativos, pode-se, progressivamente, testar os diferentes casos:

- Testar classificadores que utilizam desbalanceamentos com pesos na ordem de, respectivamente, 30 g, 25 g, 20 g, 15 g, 10 g e 6 g.
- Testar classificadores que utilizam desalinhamentos verticais e horizontais com distâncias de: 1mm, 1,5 mm e 0,5 mm, nessa ordem, diminuindo-se progressivamente o relaxamento das condições de teste.
- Testar a robustez do classificador a partir de diferentes distâncias de desalinhamentos vertical e horizontal e a partir de diferentes pesos de desbalanceamento. Para isso, pode-se mesclar diferentes distâncias e diferentes pesos em um mesmo subconjunto (SET1, SET2 ou SET3) formado por 50 sinais.
 - Deve-se notar, no entanto, que tal procedimento pode desequilibrar o histograma pois erros mais frequentes tenderiam, em teoria, a ocorrer nas frequências ligadas aos sinais relativos às falhas menos significativas de desalinhamento e desbalanceamento (menores distâncias e menores pesos, respectivamente).
- Foram realizados experimentos com amostras balanceadas: um número aproximado de 50 sinais foi utilizado para cada tipo de falha possível. No entanto, pode-se testar a robustez do classificador *random forest* frente um conjunto de dados desbalanceado, incluindo-se todas os sinais relativos à falha de desalinhamento e desbalanceamento presentes na base de dados coletada em [1]. É possível que exista uma alta robustez desse tipo de classificador para o caso no qual amostras não uniformes são utilizadas.

Bibliografia

- [1] LOPEZ, R. Z., *Classificação automática de defeitos em máquinas rotativas*. projeto final de graduação, Universidade Federal do Rio de Janeiro, Dezembro 2014.
- [2] SANTANDER, E. J. O., *Aplicação de curtose espectral na identificação de falhas em mancais de rolamentos*. M.Sc. dissertation, Universidade Federal do Rio de Janeiro, Julho 2014.
- [3] FUJIMOTO, R. Y., *Diagnóstico automático de defeitos em rolamentos baseado em lógica fuzzy*. M.Sc. dissertation, Escola Politécnica da Universidade de São Paulo, 2005.
- [4] Schaeffler Group Industrial, “Rolling Bearing Damage – Recognition of damage and bearing inspection”, Disponível em http://www.rolling.hu/pdf/FAG/FAG_meghibasodas.pdf, (Acesso em 20 de Janeiro de 2015).
- [5] Barden Precision Bearings, “Bearing Failure – Causes and Cures”, Disponível em http://www.schaeffler.com/remotemedien/media/_shared_media/08_media_library/01_publications/barden/brochure_2/downloads_24/barden_bearing_failures_us_en.pdf, (Acesso em 19 de Janeiro de 2015).
- [6] BEZERRA, R., A., *Detecção de Flhas em Rolamentos por Análise de Vibração*. D.Sc. dissertation, Universidade Estadual de Campinas, Julho 2004.
- [7] BLÖDT, M., GRANJON, P., RAISON, B., ROSTAING, G., “Models for Bearing Damage Detection in Induction Motors Using Stator Current Monitoring”, *IEEE Transactions on Industrial Electronics*, v. 55, n. 4, Abril, 2008.
- [8] JOHANSSON, M., *The Hilbert Transform*. M. Sc. Dissertation, Växjö University, 1999.

- [9] COBB, C. W., DOUGLAS, P. H., “A Theory of Production”, *The American Economic Review*, v. 18, pp. 139 – 165, 1928.
- [10] CHI, P., J., RUSSELL., C., T., “Use of the Wigner-Ville distribution in interpreting and identifying ULF waves in triaxial magnetic records”, *Journal of Geophysical Research*, v. 113, 2008.
- [11] RIOUL, O., VETTERLI, M., “Wavelets and Signal Processing”, *IEEE Signal Processing Magazine*, v. 36, 1991.
- [12] FILHO, P., B., A., ARRUDA, E., M., REIS, R., A., FILHO, P., C., M., L., BRITO., J., N., “Detecção de falhas em mancais de rolamento através da técnica de envelope e transformada de Wavelet”. In: *XI Congresso Nacional de Engenharia Mecânica, Metalúrgica e Industrial*, Porto Alegre, Agosto, 2011.
- [13] PINTO, M., F., *Novas abordagens ao estudo de sinais biomédicos: Análise em tempo-frequência e Transformada de Hilbert-Huang*. D.Sc. dissertation, Universidade de Lisboa, 2009.
- [14] MESQUITA, A., L., A., SANTIAGO, D., F., A., BEZERRA, R., A., MIRANTA, U., A., DIAS JR, M., D., PEDERIVA, R., “Detecção de falhas em rolamentos usando transformadas tempo-frequência – comparação com análise de envelope”. *Mecânica Computacional*, v. 21, pp. 1938 – 1954, Argentina, Outubro, 2002.
- [15] SILVA, A., A., MUCHERONI, M., F., “Distribuição pseudo-Wigner-Ville aplicada ao monitoramento de falhas em rolamentos”. In: *XV Congresso Brasileiros de Engenharia Mecânica*, São Paulo, Novembro, 1999.

Apêndice A

Algoritmo de curtose espectral utilizado

O algoritmo utilizado para o cálculo da curtose espectral está disponível na comunidade do MATLAB, podendo ser encontrado em:

http://www.mathworks.com/matlabcentral/fileexchange/48914-welch-s-estimate-of-the-spectral-kurtosis/content/SK_W.m

Autor: J. Antoni,
Última revisão: 12-2014
Algoritmo:

```
function [SK,M4,M2,f] = SK_W(x,Nfft,Noverlap,window)
% [SK,M4,M2,f] = SK_W(x,Nfft,Noverlap,window)
% Welch's estimate of the spectral kurtosis
%     SK(f) = M4(f)/M2(f)^2 - 2
% where M4(f) = E{|X(f)|^4} and M2(f) = E{|X(f)|^2} are the fourth and
% second order moment spectra of signal x, respectively.
% Signal x is divided into overlapping blocks (Noverlap taps), each of which is
% detrended, windowed and zero-padded to length Nfft. Input arguments nfft, Noverlap,
% and window
% are as in function 'PSD' or 'PWELCH' of Matlab. Denoting by Nwind the window length,
% it is recommended to use
% nfft = 2*Nwind and Noverlap = 3/4*Nwind with a hanning window.
% (note that, in the definition of the spectral kurtosis, 2 is subtracted instead of 3
% because Fourier coefficients
% are complex circular)
%
% -----
% References:
% J. Antoni, The spectral kurtosis: a useful tool for characterising nonstationary
% signals, Mechanical Systems and Signal Processing, Volume 20, Issue 2, 2006, pp.282-307.
% J. Antoni, R. B. Randall, The spectral kurtosis: application to the vibratory
% surveillance and diagnostics of rotating machines, Mechanical Systems and Signal
% Processing, Volume 20, Issue 2, 2006, pp.308-331.
% -----
% Author: J. Antoni
% Last Revision: 12-2014
% -----

if length(window) == 1
    window = hanning(window);
end
window = window(:)/norm(window);           % window normalization
n = length(x);                             % number of data points
nwind = length(window);                    % length of window
```

```

% check inputs
if nwind <= Noverlap,error('window length must be > Noverlap');end
if Nfft < nwind,error('window length must be <= Nfft');end

x = x(:);
k = fix((n-Noverlap)/(nwind-Noverlap));      % number of windows

% Moment-based spectra
index = 1:nwind;
f = (0:Nfft-1)/Nfft;
M4 = 0;
M2 = 0;

for i=1:k
    xw = window.*x(index);
    Xw = fft(xw,Nfft);
    M4 = abs(Xw).^4 + M4;
    M2 = abs(Xw).^2 + M2;
    index = index + (nwind - Noverlap);
end

% normalize
M4 = M4/k;
M2 = M2/k;

% spectral kurtosis
SK = M4./M2.^2 - 2;

% reduce bias near f = 0 mod(1/2)
w = abs(fft(window.^2,Nfft)).^2;
wb = zeros(Nfft,1);
for i = 0:Nfft-1,
    wb(1+i) = w(1+mod(2*i,Nfft))/w(1);
end;
SK = SK - wb;

if (nargout == 0),
    figure,newplot;
    subplot(211),plot(f(1:Nfft/2),M2(1:Nfft/2)),grid on,
    xlabel('Normalized frequency'),xlim([f(1) f(Nfft/2)]),title('Power spectrum')
    subplot(212),plot(f(1:Nfft/2),SK(1:Nfft/2)),grid on
    xlabel('Normalized frequency'),xlim([f(1) f(Nfft/2)]),title('Spectral kurtosis')
end

```