

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ – UNIOESTE

CAMPUS DE FOZ DO IGUAÇU

PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA ELÉTRICA E COMPUTAÇÃO

DISSERTAÇÃO DE MESTRADO

**COMPARAÇÃO DE MÉTODOS DE TRATAMENTO DE  
SINAIS APLICÁVEIS AO DIAGNÓSTICO DE DEFEITOS EM  
MANCAIS DE ROLAMENTO**

FILIPE DINIZ DAL MORO BORGES

FOZ DO IGUAÇU

2018



Filipe Diniz Dal Moro Borges

**Comparação de Métodos de Tratamento de Sinais Aplicáveis ao  
Diagnóstico de Defeitos em Mancais de Rolamento**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Computação como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas Dinâmicos e Energéticos.

Orientador: Prof. Dr. Guilherme de Oliveira Kunz

Foz do Iguaçu

2018

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

Dal Moro Borges, Filipe Diniz  
Comparação de métodos de tratamento de sinais aplicáveis  
ao diagnóstico de defeitos em mancais de rolamento /  
Filipe Diniz Dal Moro Borges; orientador(a), Guilherme de  
Oliveira Kunz, 2018.  
164 f.

Dissertação (mestrado), Universidade Estadual do Oeste  
do Paraná, Centro de Engenharias e Ciências Exatas,  
Programa de Pós-Graduação em Engenharia Elétrica e  
Computação, 2018.

1. Sistema Especialista. 2. Envelopamento Tradicional.  
3. Decomposição Média Local. 4. Mancais de Rolamento. I.  
Oliveira Kunz, Guilherme de. II. Título.

# Comparação de Métodos de Tratamento de Sinais Aplicáveis ao Diagnóstico de Defeitos em Mancais de Rolamento

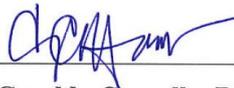
Filipe Diniz Dal Moro Borges

Esta Dissertação de Mestrado foi apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Computação e aprovada pela Banca Examinadora:  
Data da defesa pública: 21/09/2018.



---

Prof. Dr. **Guilherme de Oliveira Kunz** – (Orientador)  
Universidade Estadual Do Oeste Do Paraná – UNIOESTE



---

Prof. Dr. **Geraldo Carvalho Brito Júnior**  
Universidade Estadual Do Oeste Do Paraná – UNIOESTE



---

Dr. **João Maria Marra**  
Usina Hidrelétrica de Itaipu



# Resumo

A escolha da estratégia adequada ao planejamento da manutenção de uma planta industrial é fundamental para assegurar a disponibilidade e a confiabilidade dos seus ativos. Neste contexto, o fato das falhas ocorridas em equipamentos rotativos comumente derivarem de danos existentes nos mancais de rolamento justifica o emprego de uma metodologia de análise confiável e capaz de detectar e diagnosticar defeitos incipientes. Por este motivo, o presente trabalho procurou avaliar a capacidade de diagnóstico de três abordagens distintas, sendo elas o envelopamento tradicional, reconhecida por diversos autores como o estado da arte, e as recentemente publicadas decomposições médias local, LMD, e sua versão otimizada, OELMD, enquanto associadas a um sistema especialista desenvolvido unicamente para este fim. Outras características, tais como o potencial de separação da porção de interesse do sinal, a qualidade do conteúdo espectral gerado e o consumo computacional requerido à formulação do veredito, também foram levadas em consideração. Os algoritmos estabelecidos na literatura foram traduzidos à linguagem do MatLab e testados com sinais reais de vibração de mancais de rolamento expostos a diferentes tipos de danos. A comparação conduzida entre as formas de tratamento disponíveis ao envelopamento tradicional demonstrou que, para o caso em questão, o filtro dimensionado pelo método das médias temporais síncronas, TSA, forneceu a melhor resposta, tanto em termos de qualidade de limpeza quanto de amplificação da curtose. No caso das decomposições médias locais, seja a LMD ou a OELMD, a obtenção desta fração de maior relevância é feita por meio do desmembramento contínuo do sinal em funções ou modos, os quais caracterizam sua melhor representação em termos do produto entre um envelope e um sinal modulado em frequência. Neste sentido, foi observada uma intensa mistura de modos nas respostas oriundas da LMD, demonstrando sua inabilidade em lidar com sinais altamente complexos e modulados, ao passo que sua versão otimizada, OELMD, foi capaz de trazer à tona as características impulsivas dos mancais ora ocultadas pela porção determinística de maior intensidade. Após o término da investigação, concluiu-se que todas as metodologias comparadas obtiveram igual assertividade, no entanto, ressalta-se que a hipótese da completa dispensa da figura do analista é afastada enquanto perdurar o equilíbrio entre o tempo disponível ao processamento e o pleno êxito nos diagnósticos.

**Palavras-chave:** Sistema Especialista, Envelopamento Tradicional, Decomposição Média Local, Mancais de Rolamento.

# Abstract

The choice of the right strategy for a plant maintenance is critical to the availability and reliability of its assets. The fact that most of the failures on rotary machines derive from damages on its rolling element bearings justifies the use of a method capable to detect and diagnose defects while incipient. For this reason, the present work analyzed the diagnose capability of three different methods, among them the envelope analysis, plotted by many authors as the state of the art, and the local mean decomposition, LMD, and its optimized version, OELMD, when associated to an expert system specially designed for this. Other features, such the signal separation potential, the spectral quality and the computational consumption required, was also taken into account. The algorithms from several papers were translated to MatLab and tested with real vibration signals collected from rolling element bearings exposed to different kinds of damages. The comparison between the filter options to the envelope analysis pointed that time synchronous averaging, TSA, was better than the others in terms of cleansing quality and kurtosis amplification. In the case of the local mean decompositions, LMD and OELMD, this relevant content was revealed by the continuous decomposition of the signal into product functions or modes, which are the best representation of the original signal in terms of an envelope and a frequency modulated signal. In this sense, an intense mode mixing was observed in the answers provided by the LMD method, showing its inability to deal with complex and highly modulated signals. On the other hand, the OELMD method was capable to bring to the surface the impulsive features of the bearings previously masked by the more impulsive deterministic content of the signal. At the end the study showed that all three methods were equally assertive, although the hypothesis of the analyst dismissal is not possible while processing time and diagnostics quality are both required.

**Keywords:** Expert Systems, Envelope Analysis, Local Mean Decomposition, Rolling Element Bearing.

Dedico este trabalho a minha pequena  
grande família.



# Agradecimentos

Agradeço, sobretudo, a Deus, cuja luz sempre iluminou meus passos, dando-me força e perseverança para suportar as dificuldades do dia a dia.

À minha esposa Suellen, pela solidariedade e apoio oferecidos sempre que necessários. Sua presença e companheirismo viabilizaram o término deste trabalho.

À minha mãe, Inês, que abdicou de sua vida em prol da criação dos filhos, ao meu pai e inspiração, José Diniz, e aos meus irmãos, Vinícius e Cláudia.

Ao meu orientador e amigo Prof. Dr. Guilherme de Oliveira Kunz, pela compreensão, confiança e disposição em me orientar.

Aos amigos e colegas de trabalho André Holdefer e Hugo Villasanti, por tornarem possível a coleta de dados experimentais, sem os quais não seria possível concluir esta obra.

Aos amigos do Parque Tecnológico de Itaipu – MD, em especial o Diego Gamarra, que gentilmente cederam sua infraestrutura para a realização dos ensaios.

Aos amigos do PGEEC da Universidade Estadual do Oeste do Paraná, Claudia Bozz, Marciel Viapiana e Gionei Gaio, pelo auxílio prestado ao longo do curso de pós graduação.

À Itaipu Binacional, em especial à Superintendência de Manutenção, por flexibilizar a realização do curso durante o expediente laboral.

Ao grande amigo Dr. João Maria Marra, cuja interseção foi fundamental para o tão sonhado ingresso no programa de mestrado.

Aos demais colegas e amigos que não tiveram os nomes aqui citados, mas que de alguma forma colaboraram para a conclusão deste trabalho.

A todos vocês meu muito obrigado.



# Sumário

<b>Resumo</b>	<b>v</b>
<b>Abstract</b>	<b>vi</b>
<b>Agradecimentos</b>	<b>ix</b>
<b>Lista de Figuras</b>	<b>xiii</b>
<b>Lista de Tabelas</b>	<b>xvii</b>
<b>Lista de Quadros</b>	<b>xix</b>
<b>Lista de Símbolos</b>	<b>xxi</b>
<b>Lista de Siglas e Abreviações</b>	<b>xxv</b>
<b>Capítulo 1 Introdução</b>	<b>1</b>
1.1 Tema e Problema .....	1
1.2 Justificativa .....	3
1.3 Publicações do Primeiro Estágio .....	3
1.4 Publicações do Segundo Estágio .....	7
1.5 Publicações do Terceiro Estágio .....	13
1.5.1 Curtose espectral e curtograma .....	13
1.5.2 Cicloestacionários .....	13
1.5.3 Dependentes das WT.....	14
1.5.4 Decomposições EMD, LMD e VMD.....	14
1.5.5 Processamento morfológico .....	17
1.5.6 Busca de correspondência .....	17
1.5.7 Rastreamento de ordens .....	18
1.5.8 Mineração de dados.....	18
1.5.9 Análise Cepstral .....	18
1.6 Objetivo.....	19
1.7 Estrutura do Trabalho .....	20

<b>Capítulo 2</b>	<b>Fundamentação Teórica</b>	<b>21</b>
2.1	Defeitos em mancais de rolamento.....	21
2.2	Métodos de diagnóstico.....	26
2.2.1	Envelopamento tradicional.....	26
2.2.2	Decomposição média local.....	36
2.2.3	Sistemas especialistas.....	46
<b>Capítulo 3</b>	<b>Configuração Experimental</b>	<b>55</b>
<b>Capítulo 4</b>	<b>Operacionalização dos Algoritmos</b>	<b>65</b>
4.1	Envelopamento tradicional.....	65
4.1.1	Rastreamento de ordens.....	65
4.1.2	Filtragem TSA.....	67
4.1.3	Filtragem AR.....	69
4.1.4	Filtragem SANC.....	73
4.1.5	Filtragem DRS.....	75
4.1.6	Comparação dos resultados das filtragens.....	79
4.1.7	Amplificação dos sinais filtrados.....	80
4.1.8	Seleção da banda de demodulação.....	83
4.1.9	Determinação do espectro quadrático de envelope.....	90
4.2	Decomposição média local.....	93
4.2.1	Decomposição por LMD.....	93
4.2.2	Decomposição por OELMD.....	104
4.3	Sistema especialista.....	114
<b>Capítulo 5</b>	<b>Resultados e Discussões</b>	<b>119</b>
5.1.1	Análise dos sinais no domínio do tempo.....	120
5.1.2	Análise dos sinais no domínio da frequência.....	123
5.1.3	Avaliação da capacidade de diagnóstico.....	126
<b>Capítulo 6</b>	<b>Conclusão</b>	<b>129</b>
	<b>Referências Bibliográficas</b>	<b>133</b>

# Lista de Figuras

Figura 1.1: Componentes da manutenção centrada na condição.....	2
Figura 1.2: Diferença na percepção dos termos diagnóstico e prognóstico. ....	2
Figura 1.3: Sinal discreto produzido quando uma falha atravessa a zona de carregamento. ....	4
Figura 1.4: Sinal de um ruído branco, "a", e sua função de autocorrelação, "b".....	6
Figura 2.1: Componentes e grandezas características de um mancal de rolamento.....	22
Figura 2.2: Sinais típicos e respectivos envelopes de defeitos localizados. ....	23
Figura 2.3: Frequências características de um mancal de rolamento. ....	24
Figura 2.4: Espectro característico do primeiro estágio de degradação. ....	24
Figura 2.5: Espectro característico do segundo estágio de degradação.....	25
Figura 2.6: Espectro característico do terceiro estágio de degradação.....	25
Figura 2.7: Espectro característico do quarto estágio de degradação.....	25
Figura 2.8: Fluxograma do algoritmo de envelope tradicional. ....	26
Figura 2.9: Espectro de um sinal antes, "a", e após, "b", o rastreamento de ordens. ....	27
Figura 2.10: Amostra do sinal gerado pelo sensor ótico. ....	28
Figura 2.11: Sinal original e sua versão reamostrada digitalmente. ....	28
Figura 2.12: Exemplo da técnica de separação dos sinais.....	29
Figura 2.13: Características do filtro "pente" gerado pela técnica TSA.....	30
Figura 2.14: Princípio do filtro SANC. ....	31
Figura 2.15: Filtragem inversa do processo MED.....	32
Figura 2.16: Exemplo de aplicação do método AR e MED. ....	33
Figura 2.17: Cálculo da curtose espectral para um sinal simulado; .....	34
Figura 2.18: Filtro passa banda ideal comparado à curtose espectral. ....	34
Figura 2.19: Curtograma para um sinal fraco de defeito em caixa de engrenagens.....	35
Figura 2.20: Análise de envelope utilizando a transformada de Hilbert-Huang. ....	36
Figura 2.21: Exemplo de a) médias locais e suavizadas, e b) envelopes locais e suavizados..	38
Figura 2.22: Fluxograma do algoritmo da LMD.....	40
Figura 2.23: Forma de onda de $x(t)$ justaposta às funções produto da LMD.....	41
Figura 2.24: Forma de onda de $x(t)$ justaposta às funções produto da OELMD.....	45
Figura 2.25: Representação de uma $k$ -tree de cinco regras. ....	48
Figura 2.26: Estrutura de uma árvore de decisão para um conjunto $T$ . ....	49
Figura 2.27: $k$ -tree utilizada para a detecção de defeitos em um mancal de rolamento.....	51
Figura 2.28: Fluxograma para a detecção e identificação do componente defeituoso.....	52
Figura 2.29: $K$ -tree empregada para a detecção e identificação do componente defeituoso....	53
Figura 3.1: Bancada de ensaios. ....	55
Figura 3.2: Resposta em frequência típica dos acelerômetros para fixação por parafuso.....	57
Figura 3.3: Espectros para mancal novo: a) sinal original e b) filtrado.....	58

Figura 3.4: Espectros para defeito na pista externa: a) sinal original e b) filtrado. ....	58
Figura 3.5: Espectros para defeito na pista interna: a) sinal original e b) filtrado. ....	59
Figura 3.6: Comparação entre espectros defeito na esfera: a) sinal original e b) filtrado. ....	59
Figura 3.7: Resposta em frequência do filtro <i>butterworth</i> padronizado. ....	60
Figura 3.8: Faixa de frequências de acordo com a forma de montagem. ....	60
Figura 3.9: Resposta em frequência das pontas de impacto. ....	61
Figura 3.10: Sinais discretos da excitação e espectros nas direções horizontal e vertical. ....	62
Figura 3.11: Exemplo de amostras de sinais. ....	63
Figura 4.1: Comparação entre os sinais a) original e b) reamostrado digitalmente. ....	66
Figura 4.2: Espectros em frequência dos sinais a) original e b) reamostrado digitalmente. ....	67
Figura 4.3: Resposta em frequência do filtro <i>TSA</i> . ....	68
Figura 4.4: Sinais produzidos pelos mancais após filtragem <i>TSA</i> . ....	68
Figura 4.5: Espectros em frequência correspondentes aos sinais após filtragem <i>TSA</i> . ....	69
Figura 4.6: Resposta em frequência do filtro <i>AR</i> para mancal sem defeito (novo). ....	70
Figura 4.7: Resposta em frequência do filtro <i>AR</i> para mancal com defeito na pista externa. .	71
Figura 4.8: Resposta em frequência do filtro <i>AR</i> para mancal com defeito na pista interna. ..	71
Figura 4.9: Resposta em frequência do filtro <i>AR</i> para mancal com defeito na esfera. ....	72
Figura 4.10: Sinais produzidos pelos mancais após filtragem <i>AR</i> . ....	72
Figura 4.11: Espectros em frequência correspondentes aos sinais após filtragem <i>AR</i> . ....	73
Figura 4.12: Sinais produzidos pelos mancais após filtragem <i>SANC</i> . ....	74
Figura 4.13: Espectros em frequência correspondentes aos sinais após filtragem <i>SANC</i> . ....	75
Figura 4.14: Resposta em frequência do filtro <i>DRS</i> para mancal sem defeito (novo). ....	76
Figura 4.15: Resposta em frequência do filtro <i>DRS</i> (mancal com defeito na pista externa). .	77
Figura 4.16: Resposta em frequência do filtro <i>DRS</i> (mancal com defeito na pista interna). ..	77
Figura 4.17: Resposta em frequência do filtro <i>DRS</i> (mancal com defeito na esfera). ....	78
Figura 4.18: Sinais produzidos por meio da filtragem <i>DRS</i> . ....	78
Figura 4.19: Espectros em frequência correspondentes aos sinais após filtragem <i>DRS</i> . ....	79
Figura 4.20: Sinais antes e após <i>MED</i> (mancal sem defeito). ....	81
Figura 4.21: Sinais antes e após <i>MED</i> (mancal com defeito na pista externa). ....	82
Figura 4.22: Sinais antes e após <i>MED</i> (mancal com defeito na pista interna). ....	82
Figura 4.23: Sinais antes e após <i>MED</i> (mancal com defeito na esfera). ....	83
Figura 4.24: Curtograma do sinal de um mancal sem defeito (novo). ....	85
Figura 4.25: Curtograma de um mancal com defeito na pista externa. ....	85
Figura 4.26: Curtograma de um mancal com defeito na pista interna. ....	86
Figura 4.27: Curtograma de um mancal com defeito no elemento rolante. ....	86
Figura 4.28: Resposta em frequência do filtro dimensionado a partir dos curtogramas. ....	88
Figura 4.29: Sinal de um mancal sem defeito (novo) após separação da banda impulsiva. ....	88
Figura 4.30: Sinal de um mancal com defeito na pista externa após separação. ....	89
Figura 4.31: Sinal de um mancal com defeito na pista interna separação. ....	89
Figura 4.32: Sinal de um mancal com defeito no elemento rolante após separação. ....	90
Figura 4.33: Espectro de envelope de um sinal de um mancal novo. ....	91
Figura 4.34: Espectro de envelope de um sinal de um mancal com defeito na pista externa. .	91
Figura 4.35: Espectro de envelope de um sinal de um mancal com defeito na pista interna. ..	92
Figura 4.36: Espectro de envelope de um sinal de um mancal com defeito na esfera. ....	92

Figura 4.37: Resultado de um sinal hipotético tratado pela rotina <i>extremos</i> .....	94
Figura 4.38: Extremos de um sinal hipotético.....	95
Figura 4.39: Valores de amplitudes e envelopes médios locais. ....	96
Figura 4.40: Valores de amplitudes e envelopes suavizados. ....	97
Figura 4.41: Funções produto fornecidas pela <i>LMD</i> (mancal sem defeito). ....	100
Figura 4.42: Funções produto fornecidas pela <i>LMD</i> (mancal com defeito na pista externa). ....	100
Figura 4.43: Funções produto fornecidas pela <i>LMD</i> (mancal com defeito na pista interna). ....	101
Figura 4.44: Funções produto fornecidas pela <i>LMD</i> (mancal com defeito na esfera).....	101
Figura 4.45: Espectro quadrático obtido pela <i>LMD</i> (mancal sem defeito).....	102
Figura 4.46: Espectro quadrático obtido pela <i>LMD</i> (mancal com defeito na pista externa). .	102
Figura 4.47: Espectro quadrático obtido pela <i>LMD</i> (mancal com defeito na pista interna)..	103
Figura 4.48: Espectro quadrático obtido pela <i>LMD</i> (mancal com defeito na esfera).....	103
Figura 4.49: Fluxograma da <i>OELMD</i> .....	105
Figura 4.50: Valores de <i>RRMSE</i> associados às amplitudes do ruído adicionado.....	107
Figura 4.51: Valores de <i>RRMSE</i> associados às larguras da banda de frequência do ruído. ...	108
Figura 4.52: Valores de <i>SNR</i> associados ao número de médias utilizado pela <i>OELMD</i> .....	110
Figura 4.53: Funções produto fornecidas pela <i>OELMD</i> (mancal sem defeito). ....	110
Figura 4.54: Funções produto fornecidas pela <i>OELMD</i> (defeito na pista externa). ....	111
Figura 4.55: Funções produto fornecidas pela <i>OELMD</i> (defeito na pista interna).....	111
Figura 4.56: <i>PF</i> fornecidas pela <i>OELMD</i> (mancal com defeito na esfera).....	112
Figura 4.57: Espectro quadrático obtido pela <i>OELMD</i> (mancal sem defeito). ....	112
Figura 4.58: Espectro quadrático obtido pela <i>OELMD</i> (defeito na pista externa). ....	113
Figura 4.59: Espectro quadrático obtido pela <i>OELMD</i> (defeito na pista interna).....	113
Figura 4.60: Espectro quadrático obtido pela <i>OELMD</i> (mancal com defeito na esfera).....	114
Figura 4.61: Árvore de decisão proposta.....	115
Figura 5.1: Comparação entre os indicadores estatísticos dos sinais. ....	119
Figura 5.2: Sinais produzidos pelos diferentes métodos (mancal sem defeito).....	121
Figura 5.3: Sinais produzidos pelos diferentes métodos (defeito na pista externa). ....	122
Figura 5.4: Sinais produzidos pelos diferentes métodos (defeito na pista interna). ....	122
Figura 5.5: Sinais produzidos pelos diferentes métodos (elemento rolante).....	123
Figura 5.6: Comparação dos espectros produzidos para defeito na pista externa. ....	124
Figura 5.7: Comparação dos espectros produzidos para defeito na pista interna. ....	125
Figura 5.8: Comparação dos espectros produzidos para defeito no elemento rolante. ....	125
Figura 5.9: Índice de acertos dos métodos submetidos ao sistema especialista proposto. ....	127



# Lista de Tabelas

Tabela 1.1: Ferramentas comumente aplicadas ao gerenciamento da saúde de componentes...	3
Tabela 2.1: Classes da árvore de decisão. ....	50
Tabela 2.2: Classes da árvore de decisão para a determinação do componente defeituoso. ....	53
Tabela 3.1: Especificações e características técnicas dos componentes da bancada.....	56
Tabela 3.2: Dimensões e características construtivas dos mancais de rolamento ensaiados. ..	61
Tabela 3.3: Valores assumidos pelas frequências características.....	62
Tabela 4.1: Comparação entre os parâmetros dos filtros.....	80
Tabela 4.2: Características do filtro projetado através dos curtogramas. ....	87
Tabela 4.3: Amplitudes às frequências características de defeito (envelope tradicional). ....	91
Tabela 4.4: Amplitudes às frequências características de defeito (LMD).....	104
Tabela 4.5: Amplitudes às frequências características de defeito (OELMD). ....	114
Tabela 4.6: Indicadores estatísticos dos sinais. ....	115



# Lista de Quadros

Quadro 4.1: Sequência executada pela rotina de rastreamento de ordens.....	66
Quadro 4.2: Sequência executada pela rotina AR.....	69
Quadro 4.3: Sequência executada pela rotina SANC.....	74
Quadro 4.4: Sequência executada pela rotina DRS.....	76
Quadro 4.5: Sequência executada pela rotina MED.....	81
Quadro 4.6: Sequência executada pela rotina SK.....	84
Quadro 4.7: Sequência executada pela rotina envelope.....	90
Quadro 4.8: Sequência executada pela rotina extremos.....	93
Quadro 4.9: Sequência executada pela rotina organiza.....	94
Quadro 4.10: Rotina para determinação das amplitudes e envelopes locais.....	95
Quadro 4.11: Sequência executada pela rotina de suavização e alongamento dos vetores.....	96
Quadro 4.12: Operações realizadas para solução do primeiro laço da LMD.....	98
Quadro 4.13: Operações realizadas para solução do segundo laço da LMD.....	99
Quadro 4.14: Operações realizadas para solução do primeiro laço da OELMD.....	105
Quadro 4.15: Operações realizadas para o cálculo do erro relativo médio quadrático.....	106
Quadro 4.16: Operações realizadas para solução do segundo laço da OELMD.....	107
Quadro 4.17: Operações realizadas para solução do terceiro laço da OELMD.....	109
Quadro 4.18: Matriz de confusão utilizada para a quantificação de diagnósticos.....	116
Quadro 4.19: Algoritmo do sistema especialista.....	116
Quadro 5.1: Número de amostras diagnosticadas pelo método de envelopamento.....	126
Quadro 5.2: Número de amostras diagnosticadas pelo método de decomposição LMD.....	126
Quadro 5.3: Número de amostras diagnosticadas pelo método de decomposição OELMD.....	126
Quadro 5.4: Número de amostras diagnosticadas a partir dos sinais sem processamento.....	127



# Lista de Símbolos

$a_{ij}(t)$	Envelope médio local
$\tilde{a}_{ij}(t)$	Envelope médio local continuamente variado
$B$	Tamanho da banda de filtragem
$C_j$	Conjunto de classes
$c_{max}$	Função produto de maior relação com $x(t)$
$d$	Diâmetro do elemento rolante
$D$	Diâmetro do círculo de passo
$D_i$	Diâmetro da pista interna do rolamento
$D_o$	Diâmetro da pista externa do rolamento
$e(n)$	Sinal hipotético em função de $n$ amostras
$f$	Frequência / filtro MED
$fb$	Largura da banda de frequências do ruído branco adicionado
$fr$	Velocidade do eixo
$fs$	Taxa de amostragem
$f_i$	Velocidade angular da pista interna do rolamento
$f_o$	Velocidade angular da pista externa do rolamento
$h$	Filtro estrutural
$H(f)$	Função de resposta em frequência
$h_{ij}(t)$	Sinal oriundo da subtração de $x(t)$ por $m_{ij}(t)$
$i$	Número de vezes que o segundo laço da LMD é executado / classes de entrada
$j$	Número de vezes que o primeiro laço da LMD é executado
$k$	Número de classes de uma árvore de decisão / funções produto
$k_l$	Índice do extremo local
$L_n$	Amplitude do ruído branco adicionado
$M$	Número total de extremos / amostras

$m_{ij}(t)$	Amplitude média local
$\tilde{m}_{ij}(t)$	Amplitude média local continuamente variada
$\mu$	Coefficiente de convergência
$n$	Número de repetições
$N$	Comprimento do filtro / transformada
$ne$	Número de elementos girantes
$Ne$	Número de médias
$n_{ij}$	Extremo local
$P$	Espectro quadrático
$p_1$	Potência associada à $c_{max}$
$p_2$	Potência associada ao ruído branco
$R$	Constante dependente do motivo da decomposição
$s_{ij}(t)$	Sinal puramente modulado em frequência
$t$	Instante de tempo
$T$	Conjunto de amostras de treinamento
$ T $	Número total de amostras
$u_i(t)$	Versão suavizada de $x(t)$
$v(n)$	Ruído hipotético em função de $n$ amostras
$w$	Número de períodos ideal
$W(f)$	Transformada discreta de Fourier da janela
$x(n)$	Sinal hipotético em função de $n$ amostras
$x(t)$	Sinal hipotético
$x'(t)$	Sinal hipotético reamostrado
$x(k)$	$k$ -ésima amostra de $x(t)$
$\bar{x}$	Média das amostras de $x(t)$
$x_i$	Amplitude de uma dada amostra
$X(t)$	Transformada discreta de Fourier do sinal $x(t)$
$X_i(k)$	Transformada discreta de Fourier da $PF_i(n)$
$X(t,f)$	Transformada de Fourier de tempo curto de $x(t)$
$x_d(t)$	Sinal complexo de $x(t)$
$y(n)$	Sinal hipotético em função de $n$ amostras

$Y(f)$	Transformada discreta de Fourier do sinal $y(t)$
$\Delta$	Atraso / diferença
$\sigma$	Desvio padrão da média de $x(t)$
$\phi$	Ângulo de contato de operação constante
$\phi_I(t)$	Fase instantânea
$\omega_I(t)$	Frequência instantânea



# Lista de Siglas e Abreviações

$A_{2FBPI}$	Amplitude de vibração do primeiro harmônico de defeito na pista interna
$A_{2FBPO}$	Amplitude de vibração do primeiro harmônico de defeito na pista externa
$A_{FBPI}$	Amplitude de vibração à frequência de defeito na pista interna
$A_{FBPO}$	Amplitude de vibração à frequência de defeito na pista externa
AM	Amplitude Modulada
AR	Auto-regressive
BEMD	Bivariate Empirical Mode Decomposition
BPNN	Back Propagation Neural Network
CBM	Condition Based Maintenance
CF	Fator de crista
CSMM	Continuous Scale Mathematical Morphology
CWT	Continuous Wavelet Transform
DRS	Discrete Random Separation
DWT	Discrete Wavelet Transform
EEMD	Ensemble Empirical Mode Decomposition
EKF	Extended Kalman Filter
ELMD	Ensemble Local Mean Decomposition
EMD	Empirical Mode Decomposition
FB	Ball Frequency
FBPI	Ball Pass Inner Race
FBPO	Ball Pass Outer Race
FC	Cage Frequency
FFT	Fast Fourier Transform
FHMM	Factorial Markov Hidden Model
FIR	Finite Impulse Response

FM	Frequência Modulada
FRF	Função de Resposta em Frequência
HFRT	High Frequency Resonance Technique
HHT	Hilbert-Huang Transform
ICA	Independent Component Analysis
IIR	Infinite Impulse Response
LMD	Local Mean Decomposition
LMS	Least Mean Squares
LS	Least Squares
MED	Minimum Entropy Deconvolution
MEKF	Modified Extended Kalman Filter
MHM	Markov Hidden Model
MUDW	Morphological UnDecimated Wavelet
NAKF	Noise Adaptive Kalman Filter
OELMD	Optimized Ensemble Local Mean Decomposition
PE	Permutation Entropy
PF	Função produto
PHM	Prognostics and Health Management
RMS	Valor eficaz
RRMSE	Relative Root-Mean-Square Error
RTF	Representação Tempo-Frequência
SANC	Self Adaptive Noise Cancelling
SDMP	Sparse Discriminant Manifold Projections
SK	Spectral Kurtosis
SNR	Signal to Noise Ratio
STFT	Short Time Fourier Transform
SVD	Singular Value Decomposition
SVM	Support Vector Machine
SWT	Stationary Wavelet Transform
TSA	Time Synchronous Average
VMD	Variational Mode Decomposition

WPT      Wavelet Packet Transform

WT        Wavelet Transform



# Capítulo 1

## Introdução

### 1.1 Tema e Problema

Os mancais de elementos rolantes, usualmente conhecidos como mancais de rolamento, constituem uma classe de organismos de máquinas de excepcional importância e ampla aplicação industrial devido ao seu baixo custo e relativa facilidade de manuseio. Segundo Dowson e Hamrock (1981), apesar da simplicidade, tanto em forma quanto em conceito, os mancais são eficientes na redução do atrito e do desgaste. Ainda segundo os autores, se as cargas suportadas em uma máquina são transmitidas entre superfícies com movimento relativo entre si, a ação pode ser realizada de maneira mais efetiva se os elementos rolantes são interpostos entre elementos deslizantes. A resistência friccional encontrada pelo deslizamento é então substituída por uma resistência muito menor associada ao rolamento dos elementos.

No entanto Randall e Antoni (2011) destacam que, apesar das benesses proporcionadas pelos mancais de rolamento, também representam um dos principais pontos causadores de falha e de interrupção do processo fabril. O fato de 45% a 55% das paralizações serem atribuídas a estes organismos tornam o diagnóstico e quantificação do processo de instalação e propagação de defeitos imprescindíveis. Em seu trabalho, Rai e Upadhyay (2015) destacam que estas atribuições competem à engenharia de manutenção, cujas estratégias são classificadas, segundo a literatura clássica, em três grandes categorias: corretivas, preventivas e preditivas. A manutenção preditiva, ou centrada na condição, cuja sigla em inglês é *CBM* (*Condition Based Maintenance*), é também conhecida como Técnica de Prognóstico e Gerenciamento da Saúde de componentes, ou *Prognostics and Health Management (PHM)*.

Para Rai e Upadhyay (2015), a *CBM* é comprovadamente a técnica que proporciona os menores tempos de paralização e extensão dos danos gerados por falhas, sendo definida como uma metodologia de tomada de decisão que objetiva evitar as falhas catastróficas por meio da detecção de defeitos em sua fase embrionária, permitindo a execução de ações de manutenção necessárias à isolação de suas causas, reestabelecendo, conseqüentemente, a saúde de um equipamento ou sistema. A Figura 1.1 ilustra os três aspectos principais da *CBM* ou *PHM*.

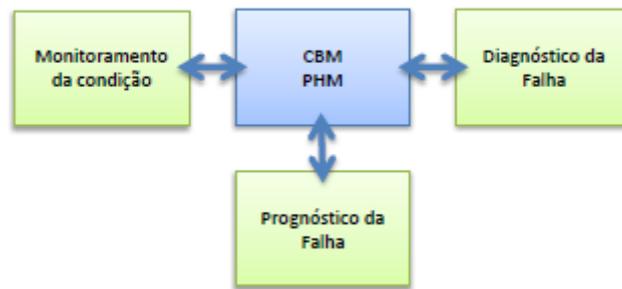


Figura 1.1: Componentes da manutenção centrada na condição.

Fonte: Adaptada de Rai e Upadhyay (2015).

Lee *et al.* (2014) citam que originalmente estas definições eram utilizadas apenas no ramo da medicina, mas acabaram permeando para todas as áreas da engenharia mecânica à medida que novas tecnologias para a execução da manutenção emergiam. Além disso, definem que o diagnóstico procura investigar ou analisar as causas ou a natureza de uma condição, situação, ou problema. Em outras palavras, é o processo de detecção e identificação de uma falha em um sistema ou subsistema. Já o prognóstico consiste na estimação da vida ou desempenho restante até que a falha completa ocorra. Em sua forma mais simples, o prognóstico procura monitorar e detectar indicações incipientes da degradação em um componente, de modo a possibilitar a elaboração de predições consistentes. Esta diferença conceitual é eficazmente ilustrada na Figura 1.2.

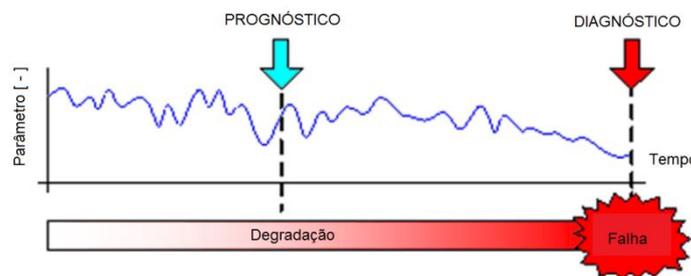


Figura 1.2: Diferença na percepção dos termos diagnóstico e prognóstico.

Fonte: Adaptada de Lee *et al.* (2014).

Neste sentido, Rai e Upadhyay (2015) reconhecem que as ferramentas de análise de condição, das quais se destaca a vibração, devem fornecer dados de maneira precisa para possibilitar o diagnóstico e prognóstico adequados. De acordo com Lee *et al.* (2014), a maior parte destas se concentra em aplicações que envolvem componentes comuns em máquinas rotativas, tais como mancais de rolamento e caixas de engrenagens, como visto na Tabela 1.1.

Tabela 1.1: Ferramentas comumente aplicadas ao gerenciamento da saúde de componentes.

<b>Componente</b>	<b>Falhas</b>	<b>Características</b>	<b>Ferramentas utilizadas</b>
Mancais de rolamento	Pistas externa e interna, elemento rolante e gaiola	Dados brutos não fornecem informações de diagnóstico, baixas amplitudes, elevado ruído	Transformada de Fourier, Transformada Wavelet, Decomposição de Modo Empírico, Biespectro, Autoregressão, Espectro em Frequência, Transformada de Hilbert-Huang, Redes Neurais, Modelos de Markov, Lógica Fuzzy, Suporte Vetorizado, Algoritmos Genéticos, Médias Móveis, Modelos Estocásticos e Análise de Componentes Principais
Engrenagens	Dentes quebrados	Modulação, elevado ruído	Mesmas que a anterior e, adicionalmente, Índice de Energia, Filtros Kalman e Filtros de Partículas

Fonte: Adaptada de Lee *et al.* (2014).

## 1.2 Justificativa

Como as informações fornecidas por estas ferramentas estão sob a forma de sinais contaminados por ruídos e interferências de outros mecanismos, a demanda por métodos de processamento de sinais confiáveis e com menor nível de interferência é crescente.

## 1.3 Publicações do Primeiro Estágio

Devido à grande disponibilidade de métodos de processamento, Rai e Upadhyay (2015) os sumariza em três estágios: o primeiro estágio, que contempla aqueles anteriores ao ano 2001, o segundo estágio, dos compreendidos entre os anos 2001 e 2010, e, por fim, o terceiro estágio, que engloba todo o desenvolvimento realizado após 2010.

Os mesmos autores resumem que os trabalhos desenvolvidos durante os períodos iniciais do primeiro estágio eram bastante simples e dependentes principalmente do cálculo de momentos estatísticos, tais como a média, o desvio padrão, a assimetria e a curtose. Muitos empregavam métodos paramétricos, porém, eram pouco eficazes na remoção dos efeitos do ruído e da interferência de outras fontes, como caixas de engrenagem e variações na velocidade do eixo.

Neste cenário, Randall e Antoni (2010) destacam que um dos primeiros estudos a respeito deste assunto foi realizado em 1969, tendo identificado que os defeitos localizados produzem sinais de elevada frequência quando impactados pelos elementos rolantes na zona de carregamento do mancal, excitando diversas frequências naturais, como visto na Figura 1.3.

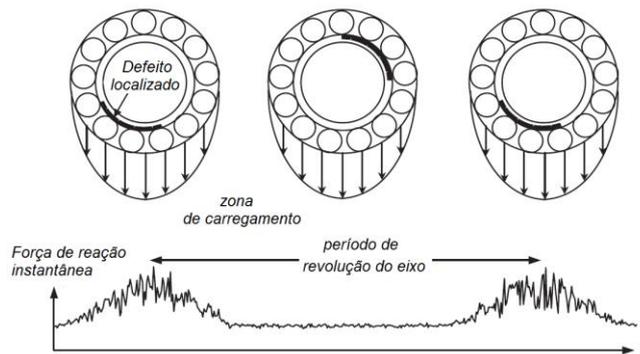


Figura 1.3: Sinal discreto produzido quando uma falha atravessa a zona de carregamento.

Fonte: Adaptada de Randall e Antoni (2010).

O mesmo estudo apontou que os níveis de aceleração mensurados correspondiam a deslocamentos extremamente pequenos, os quais podiam ser acomodados na folga existente entre a superfície externa do mancal e seu alojamento. Desta forma, suas frequências características não seriam influenciadas pela forma como foram montados.

Braun (2011), através da técnica de médias síncronas, comprovou que os sinais produzidos por mancais de rolamento não eram completamente periódicos. Neste ínterim, segundo Randall e Antoni (2010), foi fomentada a técnica de Elevada Frequência de Ressonância – *HFRT*, do inglês *High Frequency Resonance Technique*, ou análise de envelope, que visava deslocar as elevadas frequências portadoras para faixas muito menores, de modo a analisa-las com uma melhor resolução, driblando, desta maneira, as limitações instrumentais da época.

Cempel (1980) discriminou um conjunto de variáveis que poderia ser obtido de qualquer sinal vibro-acústico para detectar instabilidades em máquinas rotativas, sendo duas de natureza dimensional, para fornecer informações a respeito da amplitude e frequência do processo, duas adimensionais, que determinavam o espalhamento espectral e a amplitude, e uma última, também adimensional, que caracterizava as flutuações do processo.

Chaturvedi e Thomas (1981) concluíram que as técnicas de filtragem aplicadas no intuito de amplificar a relação ruído-sinal somente eram eficazes quando da utilização de um sinal de referência externo. Como em muitos casos a obtenção deste sinal não era possível, propuseram um filtro anulador de ruído auto-adaptativo, do inglês *Self Adaptive Noise*

*Cancelling – SANC*. O modelo de filtro proposto possibilitou uma amplificação de 32 dB na relação ruído sinal de um rolamento de teste.

Sturm e Kinsky (1984) estabeleceram um novo parâmetro normalizado à condição zero mais adequado à proposta de diagnóstico que aqueles baseados em variáveis tempo-dependentes absolutas.

McFadden e Smith (1984) desenvolveram um modelo para descrever um defeito pontual e único na pista interna de um mancal de rolamento sujeito a um carregamento radial constante que incorporava os efeitos da geometria do rolamento, da velocidade de rotação do eixo, da distribuição de carga, e das funções de transferência e de decaimento. A técnica modelava a vibração como o produto de uma série de impulsos gerados à frequência de passagem dos elementos rolantes, com condição de carregamento constante, e a amplitude da função de transferência. Os resultados indicaram que os espectros obtidos pelo modelo eram capazes de prever corretamente as frequências e as amplitudes dos defeitos.

McFadden (1986) demonstrou que modelos simples de filtros “pente” não eram capazes de extrair o conteúdo periódico de sinais altamente contaminados por ruídos através de médias temporais. Para tanto, propôs a utilização de segmentos de amostra de sinais associados à aplicação de janela retangular e à transformação de Fourier. Por fim, observou que a escolha adequada do número de médias a utilizar era capaz de remover o ruído periódico do sinal.

Em novo trabalho, Cempel (1988) forneceu uma revisão das técnicas desenvolvidas até então na área da vibro-acústica. Evidenciou o importante papel destas para os métodos de diagnóstico e as correlacionou às falhas comumente apontadas em máquinas rotativas.

Su e Lin (1992) investigaram as frequências de vibração características em um mancal de rolamento sujeito a diversos tipos de carregamento, expandindo as análises realizadas por McFadden e Smith (1984). O modelo desenvolvido utilizou como base um espectro de vibração discreto com um padrão de frequências igualmente distribuídas. Como resultado observaram picos localizados às frequências características no espectro demodulado, com bandas laterais associadas às propriedades do carregamento e ao caminho de transmissão existente entre os sensores e a origem do sinal.

Ho e Randall (1997) avaliaram os efeitos dos parâmetros controladores, tais como o tempo de atraso, a ordem e o fator de convergência, no desempenho do filtro anulador *SANC*. Concluíram que, quando utilizados na análise de caixas de engrenagens, o tempo de atraso aplicado deve ser maior que o usual. Além disso, estabeleceram gráficos que orientam a escolha dos valores ideais da ordem do filtro e do fator de convergência.

Tandon e Choudhury (1997) propuseram um modelo para a predição das frequências de vibração e amplitudes de componentes defeituosos em mancais de rolamento expostos a carregamentos radiais e axiais. O método predizia um espectro discreto contendo picos localizados às frequências de defeito e harmônicas. Nos casos de defeitos na pista interna ou elemento rolante de mancais de rolamento sujeitos a carregamento radial, concluíram haver

bandas laterais associadas a todos os picos. Citam, também, que as amplitudes de vibração para defeitos localizados na pista externa são maiores que aquelas para defeitos localizados na pista interna ou elemento rolante. Além disso, são afetadas tanto pelo carregamento quanto pela forma dos pulsos gerados. Resultados numéricos típicos para um rolamento radial rígido de esferas modelo 6002 foram publicados para comparação.

Randall e Antoni (2010) citam que os sinais aleatórios auscultados em máquinas rotativas e alternativas exibem alguma periodicidade produzida por mecanismo oculto, sendo revelada por meio de transformações não lineares. Esta classe de sinal, segundo os autores, é denominada cicloestacionária. Um exemplo simples desta condição é apresentado na Figura 1.4. Nela, o sinal típico de um ruído branco, isto é, àquele cujo conteúdo energético é idêntico em todas as faixas de frequência, é mostrado em “a” justaposto à sua função de autocorrelação em “b”. Apesar da modulação periódica vista em “a”, deve-se ressaltar que o sinal é puramente aleatório. A função de autocorrelação, mostrada em “b”, devido a não linearidade que introduz, é capaz de revelar a periodicidade oculta.

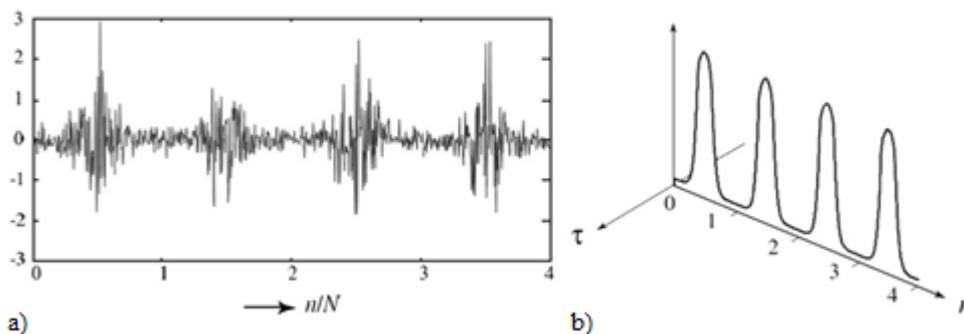


Figura 1.4: Sinal de um ruído branco, "a", e sua função de autocorrelação, "b".

Fonte: Randall e Antoni (2010).

Aproveitando-se deste princípio, Antoniadis e Glossiotis (2001) apresentaram um método alternativo para o estudo dos sinais de vibração oriundos dos mancais de rolamento. De acordo com os mesmos o modelo era mais bem indicado para ressaltar os conceitos de modulação ocultos em condições periodicamente variadas.

Apesar dos caracteres inovadores, Wang *et al.* (2010) citam que as técnicas que empregavam o algoritmo da Transformada Rápida de Fourier, do inglês *Fast Fourier Transform (FFT)*, a análise Cepstral e a análise cicloestacionária não eram adequadas para lidar com os sinais não estacionários, não lineares e de elevada complexidade encontrados na prática. Somado a este fato, seus cerne, ou funções básicas, não eram adaptativos, podendo produzir resultados carentes de interpretação física. Além disso, os métodos eram restringidos pelo princípio da incerteza de Heisenberg, e, portanto, não conseguiriam atingir boas resoluções nos domínios do tempo e da frequência simultaneamente.

## 1.4 Publicações do Segundo Estágio

Uma nova geração de trabalhos, publicados tipicamente entre os anos 2001 e 2010, foi inaugurada com o advento de técnicas modernas como as Transformadas de Wavelet, do inglês *Wavelet Transform (WT)*, a Transformada de Hilbert-Huang, ou *Hilbert-Huang Transform (HHT)*, e processamento morfológico, sendo englobados no segundo estágio de classificação de acordo com Rai e Upadhyay (2015).

Antoni *et al.* (2002) introduziram, a partir de um conceito original que levava em consideração explicitamente a natureza não estacionária dos sinais de vibração de motores à combustão interna, uma metodologia geral baseada em amostragem angular, processamento cíclico, momentos espectrais de Wigner-Ville e cumulantes. De maneira inédita, o trabalho conseguiu evidenciar a necessidade de processamento independente das contribuições periódicas e cicloestacionárias de segunda ordem do sinal de vibração.

Samanta e Al-Balushi (2003) alimentaram uma rede neural artificial com diversos parâmetros temporais, tais como a média quadrática, a variância, a assimetria, a curtose e o momento estatístico central de sexta ordem para realizar o diagnóstico de defeitos em mancais. Comprovaram que a demodulação aplicada aumentava substancialmente a qualidade do sinal, enquanto as *WT* não proviam nenhuma vantagem quando comparadas às filtragens simples.

Li e Qu (2003) reforçaram que os sinais mecânicos com amplitudes moduladas eram caracterizados por estatísticas periódicas compostas e tempo-dependentes, sendo, portanto, considerados cicloestacionários. Por este motivo, propuseram um método para a demodulação do sinal baseado em estatísticas cíclicas de segunda ordem, no qual os moduladores e os portadores eram exibidos em baixa e alta frequência, respectivamente. Como resultado, o modelo fornecia um gráfico que representava a frequência, a frequência cíclica e o espectro cíclico de potência simultaneamente, expressando claramente os resultados da demodulação. Segundo os autores, o método era capaz de obter mais informação que os métodos convencionais, como a *FFT* e o espectro de envelope. Além disso, concluiu que o modelo não necessitava de uma seleção precisa da banda de frequência e do tipo de filtro empregado para a demodulação, diferentemente do que ocorria com a *WT*. Por este motivo sua função de diagnóstico era considerada mais robusta e prática.

Liu (2003) desenvolveu um modelo adaptativo generalizado baseado na *WT* para diagnóstico de defeitos em caixas de engrenagens. O método criava inicialmente uma árvore de partições possíveis para o eixo de frequências do sinal analisado. Posteriormente, o algoritmo procurava nesta árvore a partição que representava o sinal original da forma mais esparsa o possível. Este sinal “base” era então composto para reconstruir o sinal original, revelando suas características. Os resultados mostraram que o modelo proposto superava as Transformadas de Wavelet clássicas e do tipo *Packet (Wavelet Packet Transform – WPT)*.

Kar e Mohanty (2004) discutiram a aplicabilidade do teste estatístico de Kolmogorov e Smirnov como alternativa fácil e rápida às técnicas existentes. Para eles, métodos como a *FFT* e *HFRT* não eram adequados, pois ora introduziam ruídos anômalos, ora eram limitados pelos excitadores de vibração. Além do mais, as Transformadas Discretas de Wavelet (*Discrete Wavelet Transform – DWT*), deveras úteis para o tratamento de sinais não estacionários, requeriam um elevado esforço computacional, logo, não eram aplicáveis em situações reais. O estudo concluiu que todos os defeitos existentes em mancais de rolamento possuíam uma distribuição específica, desta forma, poderiam ser identificados com relativa facilidade. Também demonstraram que o parâmetro oriundo do teste de Kolmogorov e Smirnov, *D-stat*, era pouco suscetível aos atrasos temporais, tornando-o adequado para o diagnóstico de defeitos em mancais de rolamento.

Lee *et al.* (2004) investigaram o potencial dos Modelos Ocultos de Markov, do inglês *Markov Hidden Model (MHM)*, para o diagnóstico de diversos defeitos mecânicos. Os resultados demonstraram que o *MHM* apresentava elevada robustez, precisão e capacidade de predição.

Sheen (2004) construiu um filtro complexo para a Transformada de Hilbert para aplicação em sinais de vibração em tempo real. O filtro era capaz de apresentar o sinal complexo diretamente, como função tanto do tempo quanto da frequência, possibilitando a obtenção do envelope eficazmente a partir de seu módulo. Segundo o autor, três parâmetros fundamentais deveriam ser projetados para possibilitar o atingimento de propriedades satisfatórias: o fator de escala, a frequência central da banda de passagem e a largura da mesma. Ainda de acordo com o autor, o procedimento proposto tinha a vantagem de minimizar a necessidade de intervenção pelo usuário final.

Wang *et al.* (2004) desenvolveram uma nova técnica para monitorar a rotação de sincronização e a incidência de defeitos em dentes de caixas de engrenagens de prensas de impressão de múltiplos estágios. O método utilizava a curtose beta e a Transformada Contínua de Wavelet (*Continuous Wavelet Transform – CWT*) do sinal residual. O algoritmo elaborado foi aplicado aos sinais de vibração extraídos de uma prensa de impressão, tendo sido capaz de isolar precisamente o defeito em alguns dentes das caixas de engrenagens.

Liu (2005) apresentou um método para a seleção de uma base ortonormal para representar os sinais de vibração necessários ao diagnóstico de defeitos em máquinas rotativas. A base selecionada era formada por dois conjuntos de funções básicas, um representando os transientes excitados pelas falhas localizadas e outro pelos demais componentes de interesse do sinal. Desta forma, era capaz de superar a limitação do melhor algoritmo disponível até então na tarefa de detecção de transientes ocultos em intenso ruído de fundo. Além disso, era de fácil implementação e não requeria uma etapa de treinamento.

Antoni e Randall (2005) refutaram as conclusões de Li e Qu (2003) a respeito da superioridade das estatísticas cíclicas sobre o espectro de envelope para a detecção de defeitos em mancais de rolamento. Para eles, o emprego do espectro cíclico de potência no diagnóstico de defeitos em mancais de rolamento não poderia ser justificado a partir de um modelo quasi-

estático dos sinais de vibração. Apontaram, também, que o espectro cíclico de potência estava intimamente relacionado ao espectro quadrático de envelope, o que significava, na prática, que não existiam razões para o primeiro ser superior ao segundo. Do ponto de vista dos autores, em diversos casos as informações de modulação eram mais bem visualizadas no espectro quadrático de envelope.

Shao e Nezu (2005) apresentaram uma técnica para a remoção do ruído de sinais de vibração por meio da aplicação de um filtro anulador *SANC* e um estimador baseado em Transformada de Wavelet. Seus resultados experimentais demonstraram que a técnica proposta era mais eficaz na remoção de ruído que o filtro anulador adaptativo propriamente dito. Contudo, a seleção de parâmetros ideais e essenciais ao método não foi discutida.

Bai *et al.* (2005) utilizaram filtros tipo Kalman e um algoritmo recursivo de mínimos quadrados para extrair a ordem das amplitudes dos sinais de vibração. Os dados eram enviados para um sistema de inferência do tipo difuso que fazia o rastreamento de ordens do sinal, possibilitando a classificação de diferentes tipos de falhas em máquinas rotativas.

Zhan e Jardine (2005) preconizaram três novos modelos para remoção do ruído em sinais de vibração de caixas de engrenagens. Os mesmos derivavam de métodos autoregressivos cujos parâmetros eram estimados a partir de Filtros Ruído-Adaptativo de Kalman (*NAKF – Noise Adaptive Kalman Filter*), Filtros de Kalman Estendidos (*EKF – Extended Kalman Filter*) e Filtros Modificados de Kalman Estendidos (*MEKF – Modified Extended Kalman Filter*). Os resultados obtidos a partir de sinais gerados numericamente sugeriram que os modelos propostos possuíam vantagens consideráveis no processamento de sinais não estacionários, sendo capazes de fornecer informações confiáveis nos domínios do tempo e da frequência.

Peng *et al.* (2007) apresentaram um método de aperfeiçoamento para a Transformada de Hilbert-Huang derivado da Decomposição de Modo Empírico, do inglês *Empirical Mode Decomposition (EMD)*, e da própria Transformada de Hilbert. A técnica utilizava a *WPT* para pré-processar o sinal antes da aplicação da *EMD*. Desta forma, garantiam que todas as funções intrínsecas resultantes seriam efetivamente monotônicas. Os resultados, tanto experimentais quanto simulados, comprovaram que o método aprimorado era superior ao seu predecessor, sendo capaz de apresentar os sintomas com maior clareza.

Smith (2005) descreveu um novo método iterativo para o tratamento de sinais denominado Decomposição Média Local (*Local Mean Decomposition – LMD*). A técnica consistia em decompor os sinais em diversos conjuntos de funções, obtidas a partir do produto entre um sinal de envelope e um sinal modulado em frequência, das quais seria possível extrair as frequências instantâneas. Apesar de outros métodos, tais como o do espectrograma e do sinal analítico, serem capazes de fornecer algumas formas de frequências instantâneas, suas limitações dificultavam suas interpretações, muitas vezes carentes de significado físico. Por outro lado, os resultados fornecidos pela *LMD* eram fisicamente plausíveis e as frequências instantâneas comumente correspondiam aos modos oscilatórios visíveis no sinal. Por fim, as representações tempo-frequência de sinais de eletro-encefalograma calculadas

através da metodologia proposta foram comparadas às aquelas obtidas por meio do espectrograma convencional, da *EMD* e da distribuição de Wigner-Ville. De acordo com o autor, devido à aplicação de formas de decomposição mais suaves, as representações fornecidas pela *LMD* aparentavam reter maior quantidade de informação que as demais.

Li *et al.* (2006) propuseram um método híbrido, denominado *ICA-FHMM*, que combinava a Análise Independente de Componentes (*Independent Component Analysis – ICA*) e o Modelo Fatorial Oculto de Markov (*Factorial Hidden Markov Model – FHMM*), para a extração de informações e reconhecimento de falhas durante os processos de partida e parada de máquinas rotativas. Os resultados experimentais mostraram que o método desenvolvido era superior ao *MHM*.

Qiu *et al.* (2006) avaliaram a capacidade de remoção de ruídos e de extração de características dos sinais de vibração de dois métodos distintos, sendo o primeiro baseado em decomposições de Wavelet, e o segundo em um filtro de Wavelet. Para a calibração do filtro, os autores delinearum um processo de duas etapas: inicialmente era calculado o fator de forma de Morlet da Transformada de Wavelet ideal através da mínima entropia de Shannon; em seguida, o método selecionava a escala apropriada para a Transformada de Wavelet por meio da Decomposição Singular de Valores (*Singular Value Decomposition – SVD*). A comparação revelou que a técnica de filtragem de Wavelet era mais adequada ao propósito de detecção das fracas assinaturas dos impulsos mecânicos existentes em sinais de defeito, enquanto o método de decomposição de Wavelet era capaz de obter resultados satisfatórios quando aplicado em sinais suavizados.

Yu *et al.* (2006) desenvolveram um método para o diagnóstico de defeitos em mancais de rolamento que empregava uma rede neural artificial alimentada por vetores extraídos dos sinais de vibração através da *EMD*. A análise dos resultados dos processamentos dos sinais de vibração de um rolamento radial rígido de esferas modelo 6311 contendo defeitos localizados nas pistas interna e externa revelou que a técnica apresentada era capaz de identificar precisamente os padrões de defeito, sendo mais eficaz que a *WPT*. Contudo, destacaram que a *EMD* apresentava diversos problemas e, por este motivo, era pouco aplicada no diagnóstico de defeitos em mancais de rolamento.

Antoni (2007) discutiu quais ferramentas espectrais cíclicas deveriam ser utilizadas para fins de diagnóstico em mancais de rolamento. Sua investigação apontou que as vibrações produzidas por mancais de rolamento defeituosos são, essencialmente, aleatórias e cicloestacionárias nas faixas de elevada frequência, onde a relação ruído-sinal é máxima, explicando, assim, o motivo pelo qual as técnicas de análise espectral clássicas comumente resultam em falha. Demonstrou, também, que as informações de diagnósticos eram perfeitamente preservadas no domínio da frequência cíclica sob a forma de padrões de linhas espectrais, e que a coerência cíclica era o parâmetro com melhor capacidade de detecção. A conclusão mais importante, no entanto, foi enfatizar que o clássico espectro quadrático de envelope é, na verdade, um caso especial de coerência cíclica, fornecendo resultados igualmente satisfatórios.

Ocak *et al.* (2007) desenvolveram um método para o diagnóstico de defeitos em mancais de rolamento baseado em *WPT* e *HMM*, e abordagem similar ao trabalho de Li *et al.* (2006). Os dados coletados experimentalmente em um teste de degradação acelerada de um rolamento rígido de esferas modelo 6204 mostraram que, ao contrário de outros parâmetros de tendência habitualmente utilizados, as probabilidades apontadas pelo *HMM* continuavam caindo à medida que o rolamento aproximava-se da falha. De acordo com o estudo, uma redução drástica dos parâmetros de tendência foi observada quando a vida remanescente estava próxima de 10%.

Sheen (2007) propôs a aplicação de um filtro com posterior decomposição do sinal contido na banda de passagem como etapa preliminar ao processamento pelo método de envelope por mínimos quadrados (*Least-squares – LS*). Na sequência, utilizava uma transformação logarítmica para realçar as frequências características de defeitos e remover as bandas laterais. Por fim, a técnica foi aplicada aos sinais de vibração provenientes de um rolamento de rolos cônicos modelo 32208 com resultados satisfatórios.

Abbasion *et al.* (2007) apresentaram um método para o diagnóstico de múltiplos defeitos em mancais de rolamento que empregava análise de Wavelet e uma Máquina de Suporte Vetorizado (*Support Vector Machine – SVM*). O sistema estudado era composto por um motor elétrico dotado de dois rolamentos radiais rígidos de esferas, sendo um do modelo 6203 e outro do modelo 6205, um dinamômetro e diversos sensores. Segundo os autores, o modelo proposto alcançou uma taxa de acerto de 100% na classificação dos estados normal, defeito na pista interna, defeito na pista externa e defeito no elemento rolante quando alimentado apenas pelas funções de densidade de probabilidade de Weibull dos sinais tratados por Wavelet.

Sreejith *et al.* (2008) publicaram um modelo para a classificação de defeitos em mancais de rolamento baseado em rede neural artificial. Diferentemente dos demais trabalhos, que requeriam um rígido pré-processamento dos sinais, os autores propuseram alimentar a rede com parâmetros temporais facilmente calculados, como a curtose, o fator de crista, o fator de forma, a média quadrática, o desvio padrão e as funções de densidade de probabilidade de Weibull e Normal. A técnica foi aplicada aos sinais de vibração oriundos de um rolamento rígido de esferas modelo 6205 com uma taxa de acerto de 100%.

Janjarasjitt *et al.* (2008) introduziram uma forma modificada da integral de correlação para aplicações em tempo real, cujo expoente dimensional era utilizado para quantificar a vida remanescente. Foram utilizados os dados vibracionais de um rolamento radial rígido de esferas modelo 6204 sujeito a um ensaio de degradação acelerada. Os resultados comprovaram que o valor assumido pelo expoente dimensional aumentava à medida que a vida remanescente diminuía. Além disso, eram condizentes com o trabalho de Ocak *et al.* (2007).

Zhen *et al.* (2008) sugeriram um modelo para a detecção de defeitos em mancais de rolamento que levavam em consideração a dependência inter e intra-escala dos coeficientes de Wavelet. Os sinais extraídos de um mancal de rolamento defeituoso de 450 mm de diâmetro

foram tratados por meio do método proposto, tendo este revelado claramente as componentes de natureza transiente.

Barszcz (2009) investigou a aplicabilidade do teorema de Wold, o qual considerava a existência de componentes determinísticas e não determinísticas em sinais reais, para a decomposição dos sinais de vibração. A técnica empregava os conhecidos filtro anulador *SANC* e o espectro de envelope. O método foi testado em sinais reais de vibração de uma turbina eólica, os quais foram reamostrados a fim de eliminar as flutuações de velocidade existentes neste tipo de equipamento. Os resultados concluíram que o algoritmo proposto era capaz de revelar os defeitos existentes nos mancais de rolamento.

Hao e Chu (2009) apresentaram um novo método para a decomposição de sinais baseado em Transformações Morfológicas de Wavelet não Decimadas, *MUDW*, do inglês *Morphological UnDecimated Wavelet*, aplicadas estritamente no domínio do tempo. O modelo foi aplicado no tratamento de sinais simulados e experimentais. Os resultados foram comparados às técnicas de envelope tradicional e de Wavelet, tendo demonstrado um desempenho satisfatório na extração das características impulsivas dos defeitos. Devido à simplicidade do algoritmo proposto, os autores fomentaram sua utilização em processos que exijam o monitoramento em tempo real.

Hong e Liang (2009) propuseram o uso dos fatores de complexidade de Lempel-Ziv como parâmetro para a quantificação da severidade dos defeitos em mancais de rolamento. Para evitar a ambiguidade existente entre as partes impulsiva do sinal, correspondente às frequências de defeito, e o ruído, a técnica aplicava uma Transformada Contínua de Wavelet para a seleção da escala que melhor representava as falhas, eliminando, assim, a interferência de componentes irrelevantes. Os resultados obtidos apontaram que o algoritmo alimentado com sinais provenientes de um rolamento autocompensador de esferas modelo 1204 era apropriado à tarefa para a qual foi desenvolvido.

Wang *et al.* (2009) vislumbraram uma metodologia aprimorada para a seleção do número de períodos da média móvel e tratamento dos extremos dos sinais como solução aos conhecidos problemas da técnica de *LMD*. O método foi testado em três tipos de sinais sintéticos, sendo um puramente *AM*, outro híbrido *AM-FM* e o último uma onda oscilatória de Duffing, além de outros sinais experimentais. Os espectrogramas, ou representações tempo-frequência, obtidos demonstraram a superioridade da técnica quando comparadas àquelas que utilizam Transformações Estacionárias de Wavelet (*Stationary Wavelet Transform – SWT*) e *HHT*.

Em sua excelente obra, Randall e Antoni (2010) estabeleceram um roteiro para análise de defeitos em mancais de rolamento de máquinas rotativas por meio do espectro de envelope, englobando todas as suas etapas: rastreamento de ordens, remoção do conteúdo determinístico, extração das bandas impulsivas, amplificação do sinal através da Deconvolução de Mínima Entropia (*Minimum Entropy Deconvolution – MED*), envelopamento e, por fim, o diagnóstico propriamente dito.

Boumahdi *et al.* (2010) desenvolveram uma metodologia para a seleção automática dos atributos de teste para uma árvore de decisão desenvolvida para fins de identificação de defeitos. A partir de dados experimentais de mancais de rolamentos rígidos de esferas modelo 6206 danificados por eletro-erosão os autores identificaram que o fator de crista, o valor eficaz, a curtose e as amplitudes de vibração às frequências características de defeito nas pistas interna e externa são os mais representativos. Além disso, demonstraram que os valores de curtose e fator de crista calculados para o caso de um mancal sem defeito estão perfeitamente alinhados com a literatura.

Randall *et al.* (2011) compararam diferentes técnicas para a separação de componentes determinísticos dos sinais de vibração, tais como as médias síncronas, a separação aleatória-discreta, a predição linear, o filtro anulador *SANC* e a análise Cepstral, que, em suma, é a *FFT* inversa do espectro logarítmico. O estudo não apontou a superioridade de nenhum dos métodos, mas destacou a aplicabilidade de cada um deles em diferentes situações e sinais.

## 1.5 Publicações do Terceiro Estágio

Devido à existência de uma grande quantidade de publicações após o ano de 2011, Rai e Upadhyay (2015) subdividem os trabalhos do terceiro estágio de acordo com o método aplicado. Alguns deles são destacados a seguir.

### 1.5.1 Curtose espectral e curtograma

Tang, Zhou e Liaoi (2016) apresentaram um método para o diagnóstico de defeitos que empregava um curtograma aprimorado para melhorar a qualidade dos sinais reconstruídos. O algoritmo decompunha o sinal utilizando a *WPT*, em seguida gerava o curtograma a partir do sinal decomposto, denominado curtograma melhorado, selecionava o nó que apresentava a maior curtose espectral e, então, reconstruía o sinal também por meio da *WPT*. Logo após, calculava o espectro de envelope empregando o algoritmo da *HHT* que, por sua vez, permitia a realização do diagnóstico desejado. Dados experimentais foram extraídos de uma bancada de teste que abrigava um rolamento radial rígido de esferas modelo 6203. Os resultados obtidos confirmaram a efetividade do processamento proposto.

### 1.5.2 Cicloestacionários

Elbhabah e Sinha (2013) propuseram um conceito de espectro composto, formado a partir da construção de sinais oriundos de diversos sensores instalados nos mancais de

rolamento de uma máquina rotativa. Foram testadas duas categorias de espectro composto, sendo uma coerente e outra não coerente. Apesar de terem apresentado as mesmas características espectrais, o modelo coerente mostrou-se superior devido a sua capacidade de remoção de ruído.

Dong *et al.* (2015) publicaram um método biespectral aprimorado para o diagnóstico de defeitos em mancais de rolamento. A técnica, executada em duas etapas, inicialmente provocava o aumento da resolução através de filtragem e ampliação da banda desejada, e, em seguida, realizava a integração do biespectro de frequência deslocada para produzir uma representação espectral unidimensional. O estudo promoveu as seguintes conclusões: 1) o biespectro de frequência deslocada era superior à técnica de biespectro convencional, 2) o aumento de resolução não requeria um maior esforço computacional, 3) a representação gerada a partir integração do biespectro de frequência deslocada, também interpretada como espectro cruzado, é capaz de indicar claramente os defeitos, e, 4) os parâmetros quantitativos gerados pela técnica aumentavam em módulo de acordo com a evolução do defeito, sendo, por este motivo, adequado para monitorar a tendência.

### 1.5.3 Dependentes das WT

Ding *et al.* (2015) averiguaram as diferenças existentes nos padrões de características locais dos mancais de rolamento em diversas condições de vida para, então, alimentar um sistema de reconhecimento de padrões. Os sinais utilizados eram primeiramente decompostos através de *WPT* para a formação de diversos mapas que, na sequência, eram fundidos e enviados ao classificador. Os resultados experimentais demonstraram que o modelo desenvolvido era adequado e efetivo à classificação de defeitos.

### 1.5.4 Decomposições EMD, LMD e VMD

Yang *et al.* (2011) apresentaram uma metodologia denominada Decomposição de Modo Empírico Bivariada (*Bivariate Empirical Mode Decomposition – BEMD*) que era capaz de lidar com sinais bidimensionais. A técnica foi comparada à tradicional *EMD* e à *EMD* aprimorada pelo rastreamento de energia da *WT*, tendo demonstrado superioridade em termos de preservação de informações e de capacidade de detecção de falhas incipientes.

Yang *et al.* (2012) aplicaram ruído branco aos sinais de vibração coletados em mancais de rolamento para mitigar o problema de mixagem de modos intrínseco da *LMD*, dando origem, assim, à Decomposição Média Local Composta, do inglês *Ensemble Local Mean Decomposition (ELMD)*. Como o ruído branco era adicionado ao sinal antes de seu processamento pela *LMD*, sua relação ruído-sinal aumentava. Porém, como diferentes séries de ruídos eram aplicadas independentemente, sua média tendia a zero à medida que uma

quantidade maior de ruído era empregada. O resultado final era dado, então, pela média de todos os modos, ou funções produto, gerados pela decomposição. Os resultados experimentais confirmaram que o algoritmo era capaz de manter as informações desejadas e eliminar a mistura de modos. Apesar disso, os parâmetros necessários à seleção da amplitude do ruído branco, da largura da banda de frequência e do número de médias a utilizar não foram discutidos.

Guo e Tse (2013) elaboraram um método de compressão de sinais de vibração coletados em processos que exigiam a transmissão dos dados por tecnologia sem fio. O modelo utilizava a Decomposição de Modo Empírico Composto (*Ensemble Empirical Mode Decomposition – EEMD*) para desmembrar as componentes do sinal, sendo seus parâmetros, em particular a amplitude do ruído branco adicionado, controlados com base em um erro relativo médio quadrático. Os resultados experimentais comprovaram que o algoritmo era capaz de alcançar elevadas taxas de compressão e manter as características de defeito dos mancais de rolamento presentes no sinal.

Jiang *et al.* (2014) apresentaram um método para classificação de defeitos mecânicos em máquinas rotativas que empregava os conceitos da *EEMD* e da análise de projeção espacial de auto-zero. Segundo os autores, esta técnica foi desenvolvida para estimar a severidade de uma falha por meio de um vetor de características, cujas projeções resultantes não eram nulas apenas quando um vetor de teste e um vetor de auto-zero possuíam a mesma condição. A partir de dados experimentais, concluíram que o modelo proposto possuía elevada acurácia, mesmo para uma quantidade limitada de características investigadas.

Li *et al.* (2016) desenvolveram uma nova metodologia para o diagnóstico de defeitos em mancais de rolamento que utilizava a *LMD* para o pré-processamento do sinal, a entropia difusa de multi-escala para amplificação, um critério Laplaciano para a escolha das características e uma *SVM* para classificação dos dados. O modelo era capaz de alcançar uma taxa de acerto de 100% quando empregado no diagnóstico de um mancal de rolamento sujeito a múltiplos defeitos.

Tang, Wang e Liu. (2016) combinaram as vantagens apresentadas pelos métodos de Decomposição de Modo Variacional (*Variational Mode Decomposition – VMD*) e da Entropia de Permutação (*Permutation Entropy – PE*) para processar os sinais não estacionários e não lineares característicos em máquinas rotativas. Os dados de um rolamento rígido de esferas modelo 6205 foram utilizados para alimentar um classificador *SVM* responsável pelo fornecimento do diagnóstico. Segundo os autores, esta nova metodologia conseguia superar a técnica de *EMD*.

Žvokelj *et al.* (2016) adicionaram uma metodologia *ICA* multivariada ao conceito da *EEMD* apresentado por Guo *et al.* (2013). De acordo com os autores, a técnica *EEMD-MSICA* oferecia não apenas uma estratégia para a detecção de defeitos em mancais de rolamento, mas também um mecanismo para remoção de ruídos de sinais multivariados e uma potente ferramenta de diagnóstico. Os resultados obtidos demonstraram que o modelo proposto era

capaz de extrair as informações de diagnóstico desejadas, mesmo quando aplicado em grandes conjuntos de dados multivariados.

Xiao e Dong (2016) propuseram a utilização de um coeficiente de decorrelação como mecanismo para a eliminação do problema de mixagem de modos existente na *LMD*. O modelo decompunha o sinal multivariado por meio da *LMD* para obter as funções produto ou modos, e, em seguida, calculava seus coeficientes de decorrelação. Caso o coeficiente de decorrelação do primeiro modo fosse maior que 1 o algoritmo calculava automaticamente o coeficiente de decorrelação entre os modos 1 e 2 para formar um novo modo decorrelacionado que seria, então, subtraído do sinal original. Este novo sinal era novamente decomposto pela *LMD* para formar um novo conjunto de funções produto, sendo o processo repetido até que todos os coeficientes de decorrelação sejam inferiores a um valor de ajuste. De acordo com os autores, este processamento asseguraria a ortogonalidade entre as funções produto. Contudo, não descartaram a existência de outras fontes possíveis para a mixagem de modos, para as quais caberiam novos estudos.

Zhang, C. *et al.* (2017) publicaram, indubitavelmente, uma das principais obras acerca do tema. Inspirado em trabalhos anteriores os autores uniram a técnica de inserção de ruído branco em sinais de vibração, proposta por Yang *et al.* (2012), e o conceito de erro relativo médio quadrático, divulgado por Guo *et al.* (2013), para possibilitar a seleção automática da largura da banda de frequência e amplitude ideais do ruído branco gaussiano que seria adicionado ao sinal, bem como o número de médias adequado, dando origem à Decomposição Média Local Composta Otimizada, ou *Optimized Ensemble Local Mean Decomposition (OELMD)*. O algoritmo realizava as seguintes etapas sequenciais:

- 1) Arbitrava valores máximos para a largura da banda de frequências, para a amplitude e para o número de médias;
- 2) Aplicava a *ELMD* ao sinal original;
- 3) Obtinha um conjunto de funções produto, ou modos, e calculava o erro relativo médio quadrático;
- 4) Repetia os passos 2 e 3 utilizando amplitudes distintas. O valor ideal seria aquele correspondente ao maior erro relativo médio quadrático;
- 5) Com o valor ideal da amplitude, repetia apenas os passos 2 e 3 utilizando larguras distintas. A largura ideal novamente corresponderia àquela cujo erro era máximo;
- 6) Com os valores ideais de amplitude e da largura da banda de frequências, executava novamente os passos 2 e 3 variando apenas o número de médias. O valor ideal era aquele que maximizaria a relação ruído sinal, sem aumentar demasiadamente o número de médias;
- 7) Por fim, executava a *OELMD* utilizando todos os parâmetros melhorados.

Os resultados obtidos a partir de dados experimentais de três equipamentos distintos comprovaram a efetividade da técnica proposta.

### 1.5.5 Processamento morfológico

Li e Liang (2012) introduziram um modelo Matemático Morfológico de Escala Contínua, do inglês *Continuous Scale Mathematical Morphology (CSMM)*, que empregava interpolação e reamostragem como mecanismos para melhorar a resolução do sinal demodulado. A técnica realizava a seleção da banda de escala que melhor representava a característica impulsiva dos defeitos através da curtose espectral e, em seguida, fazia a demodulação do sinal, cujos componentes seriam utilizados posteriormente para detectar a existência de falhas. O estudo concluiu que o método proposto era uma alternativa atraente para a realização de análises no domínio morfológico, sendo capaz de extrair corretamente as características impulsivas do sinal.

Li *et al.* (2018) desenvolveram um novo operador morfológico de convolução para aperfeiçoar a capacidade de detecção das *WT*. Os resultados demonstraram que a nova metodologia era adequada aos propósitos de diagnóstico desejados.

### 1.5.6 Busca de correspondência

Cui *et al.* (2014) introduziram um algoritmo de busca de correspondência adaptativo que utilizava um dicionário de impulsos para o processamento dos sinais de vibração e detecção de defeitos. Inicialmente foi estabelecido um novo dicionário de acordo com as características e mecanismos de falhas dos mancais de rolamento que incorporava os efeitos da velocidade de rotação, das dimensões e das condições dos rolamentos. O modelo realizava a variação progressiva destes parâmetros para melhorar a estabilidade e controlabilidade do algoritmo genético utilizado pela técnica. Os resultados obtidos a partir de dados experimentais confirmaram a efetividade do método.

Em novo trabalho, Cui *et al.* (2016) apresentaram um algoritmo de busca de correspondência que utilizava um dicionário duplo contendo os índices de complexidade de Lempel-Ziv. Em uma primeira etapa os sinais de vibração eram decompostos e, em seguida, processados pela técnica. Os autores comprovaram sua efetividade na tarefa de quantificação da extensão dos desgastes em mancais de rolamento através de dados experimentais.

Chen *et al.* (2017) propuseram uma nova metodologia para detecção de defeitos em mancais de rolamento baseada em Projeções de Manifold Discriminantes Esparsos (*Sparse Discriminant Manifold Projections – SDMP*) e um classificador do tipo *SVM*. Os resultados experimentais apontaram que o método proposto era mais eficiente que os demais algoritmos de aprendizagem disponíveis.

### 1.5.7 Rastreamento de ordens

Guo *et al.* (2012) desenvolveram um modelo para a detecção de defeitos em mancais de rolamento baseado em análise de envelope e rastreamento de ordens. O algoritmo utilizava, em resumo, o passo a passo descrito por Randall e Antoni (2010), no qual o rastreamento de ordens era aplicado para a eliminação dos efeitos da flutuação da velocidade do eixo e as características do filtro definidas a partir de um curtograma. A técnica foi aplicada em sinais de rolamentos de esfera modelo N1007 defeituosos, cujos resultados confirmaram a efetividade deste consagrado método.

### 1.5.8 Mineração de dados

Zhang, L. *et al.* (2016) publicaram uma tecnologia para o diagnóstico de defeitos em mancais de rolamento que utilizava a *LMD* para alimentar uma rede neural de propagação reversa (*Back Propagation Neural Network – BPNN*). A classificação era feita através de um vetor contendo o somatório das amplitudes dos espectros de potência das funções produto às frequências características de defeito. Àquele que apresentava maior valor, conseqüentemente, seria atribuído à falha. O algoritmo foi aplicado em um conjunto de sinais extraído de um rolamento radial rígido de esferas modelo 6205, tendo os resultados atestado sua efetividade. No entanto, os próprios autores citam a dificuldade de se interpretar os resultados obtidos para as situações onde o dano causado ao elemento rolante era mínimo, pois, as amplitudes detectadas à frequência característica de defeito se aproximavam muito daquelas obtidas em condições normais.

Lu *et al.* (2018) desenvolveram um método de mineração de dados baseado em análise de envelope tradicional para o monitoramento de máquinas rotativas auscultadas por sensores sem fio. Devido à limitada capacidade de transmissão desta tecnologia, os autores propuseram a eliminação dos dados discretos situados fora da banda de maior impulsividade, determinada através da curtose espectral. Com isso, concluíram ser possível reduzir em até 80% o tempo de transmissão.

### 1.5.9 Análise Cepstral

Rai e Upadhyay (2015) destacam que a análise cepstral é uma das técnicas mais antigas utilizadas no ramo de processamento de sinais. Os principais métodos são, segundo o mesmo autor, o da variância mínima e o de pré-branqueamento por espectro cepstral.

Dando continuidade ao trabalho de Tandon e Choudhury (1997), Garad *et al.* (2017) testaram o nível de sensibilidade de diversos indicadores estatísticos, tais como a curtose e o

fator de crista, e do espectro logarítmico, Cepstrum, quando calculados para diagnóstico de diferentes tipos de defeitos, velocidades de rotação e direção de carregamento. O estudo concluiu que o valor do fator de crista obtido para a direção radial em um mancal com defeito no elemento rolante supera aqueles das demais condições e que as amplitudes às frequências características de defeito no elemento rolante e pista externa do espectro Cepstral sobrepujam àquelas dos outros tipos de danos. Afirmaram, também, que a curtose e o fator de crista não são bons indicadores para defeitos localizados na pista externa.

Como visto, são inúmeros os métodos disponíveis ao processamento de sinais de vibração e diagnóstico de defeitos em mancais de rolamento. Da pesquisa são derivadas as seguintes conclusões:

- a) Sinais de vibração auscultados em mancais de rolamento são dependentes do tempo, logo, apenas as representações tempo-frequência simultâneas fornecerão as informações requeridas ao diagnóstico. Sendo assim, técnicas simples, como àquelas citadas no primeiro estágio de Rai e Upadhyay (2015), são prontamente descartadas;
- b) As técnicas recentes são dependentes de parâmetros que impactam diretamente seu desempenho, os quais, por sua vez, devem ser estabelecidos por um analista;
- c) As metodologias cujos cerne não realizam a decomposição do sinal, como o envelopamento tradicional, a *EMD*, as *WT*, entre outras, necessitam da *HHT*, que também é paramétrica. Desta forma, a qualidade do resultado residirá novamente na habilidade do operador, e;
- d) Algoritmos de classificação que empregam redes neurais e máquinas de suporte vetorial apresentam a maior acurácia, contudo, o esforço computacional requerido ao processamento os torna inviáveis para aplicações em tempo real.

## 1.6 Objetivo

Tendo em conta estas problemáticas, este trabalho objetiva, de maneira geral, comparar os métodos de tratamento de sinais de vibração baseados em envelopamento tradicional, admitido por diversos autores como o estado da arte, e em decomposição média local quanto à capacidade de diagnóstico de defeitos em mancais de rolamento.

Em termos específicos, pretende-se:

- a) Revisar a literatura disponível acerca de diagnóstico de defeitos em mancais de rolamento;
- b) Estabelecer as bases teóricas dos métodos de processamento de sinais de vibração escolhidos para este comparativo;
- c) Transcrever os algoritmos originais para a linguagem do *MatLab*, empregando, para tanto, códigos autorais;

- d) Programar e calibrar um sistema especialista para avaliação do percentual de diagnósticos assertivos produzidos pelos métodos comparados;
- e) Confrontar os tempos de processamento requeridos à formulação do diagnóstico para cada um dos métodos testados;
- f) Comparar os valores dos indicadores estatísticos calculados para as diferentes condições analisadas com aqueles fornecidos na literatura, e;
- g) Avaliar os sinais e espectros gerados pelos métodos.

## 1.7 Estrutura do Trabalho

Para melhor entendimento e abordagem do tema procurou-se estruturar o trabalho da seguinte forma:

O Capítulo 2 traz a fundamentação teórica, contendo um breve resumo sobre o diagnóstico de defeitos em mancais de rolamento e os métodos de diagnóstico que serão comparados, além de lançar luz sobre os sistemas especialistas.

O Capítulo 3 apresenta o estudo de caso do qual foram extraídos os dados reais de vibração.

O Capítulo 4 discute a implementação dos métodos na linguagem de programação escolhida para este fim.

O Capítulo 5 resume os resultados e discussões, estabelecendo um comparativo entre os métodos detalhados nos Capítulos 2 e 4.

Por fim, o Capítulo 6 revela as conclusões obtidas e oportunidades para pesquisas futuras.

# Capítulo 2

## Fundamentação Teórica

O presente capítulo estabelece um breve resumo a respeito dos defeitos típicos em mancais de rolamento, colocando em evidência as características da vibração auscultada que permitem o diagnóstico e a avaliação do nível de degradação. Apresenta, também, os algoritmos originais dos métodos de tratamento selecionados para este comparativo.

### 2.1 Defeitos em mancais de rolamento

Segundo Harris (2001), existem dois tipos tradicionais de mancais: os de deslizamento e os de rolamento. Nos mancais de rolamento a transferência da carga se dá pelos elementos rolantes, como esferas ou cilindros, montados entre anéis chamados de pistas. O movimento relativo destas pistas faz com que os elementos rolantes rodem com pouco deslizamento e baixa resistência ao giro. Tipicamente, os elementos rolantes são guiados por uma gaiola que garante um espaçamento uniforme e previne o contato mútuo. Os mancais de rolamentos são empregados para permitir o movimento rotativo de, ou sobre, eixos, tanto em dispositivos comerciais simples, como bicicletas, patins e motores elétricos, quanto em mecanismos complexos de engenharia, como turbinas a gás, aeronaves, laminadores, brocas dentárias, giroscópios, entre outros.

A Figura 2.1 apresenta um diagrama esquemático ilustrando os componentes básicos de um mancal de rolamento, sendo eles a gaiola, as esferas, as pistas interna e externa, e outras grandezas características, tais como o ângulo de contato de operação constante ( $\phi$ ), o diâmetro do elemento rolante (esfera ou rolete) ( $d$ ), o diâmetro do círculo de passo ( $D$ ), o diâmetro da pista interna ( $D_i$ ), o diâmetro da pista externa ( $D_o$ ), a velocidade angular da pista interna ( $f_i$ ) e a velocidade angular da pista externa ( $f_o$ ).

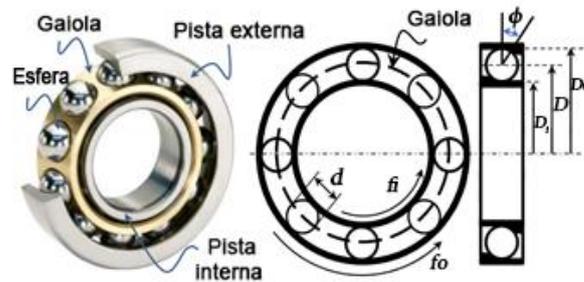


Figura 2.1: Componentes e grandezas características de um mancal de rolamento.

Fonte: Adaptada de Mishra *et al.* (2017).

De acordo com Randall e Antoni (2010), os defeitos em rolamentos iniciam-se normalmente como pequenas falhas ou porosidades, as quais, quando impactadas pelo elemento rolante originam picos acentuados que cobrem uma ampla faixa de frequências.

Para Monavar *et al.* (2008), esses defeitos podem ser classificados como localizados e distribuídos. Defeitos como trincas, poros e *pits* fazem parte do primeiro grupo, sendo gerados devido à fadiga do material das superfícies de rolamento sujeitas às tensões de contato e às forças de atrito. Os defeitos como a rugosidade, a ondulação das superfícies de contato e o desalinhamento das pistas são classificados como distribuídos, e resultam de erros de fabricação ou por ação do desgaste abrasivo.

A Figura 2.2 apresenta exemplos de sinais de vibração produzidos por diversos componentes que apresentam defeitos localizados e seus respectivos sinais de envelope para um carregamento unidirecional. À medida que os elementos girantes impactam uma região danificada, tanto na pista interna quanto externa, um pulso de choque é gerado, excitando diversos modos naturais. O mesmo ocorre quando um elemento rolante defeituoso é impactado contra as pistas.

MacFadden e Smith (1984) explicam que a série de picos criada pelas ondas de choque é posteriormente modulada em amplitude devido aos seguintes fatores:

- a) Taxa de passagem dos elementos girantes sobre a zona de carregamento do rolamento;
- b) Variação da função de transferência do caminho de transmissão da vibração;
- c) Distribuição da carga sobre o mancal, e;
- d) Taxa de decaimento das frequências de ressonância excitadas.

Como o contato entre o defeito e as superfícies de rolamento é essencialmente periódico, o impulso se repetirá a intervalos regulares, portanto, a taxa de ocorrência do impulso é tida como a frequência característica de defeito. Estas frequências, por sua vez, dependem da localização do defeito, sendo definidas pelas equações baseadas nos cinco movimentos básicos usados para descrever a dinâmica dos elementos rolantes. As frequências atribuídas à passagem dos elementos rolantes sobre os defeitos na pista externa, *FBPO* (*Ball Pass Outer Race*), pista interna, *FBPI* (*Ball Pass Inner Race*), gaiola, *FC* (*Cage Frequency*) e

elementos girantes,  $FB$  (*Ball Frequency*) podem ser determinadas através das equações 2.1, 2.2, 2.3 e 2.4, respectivamente.

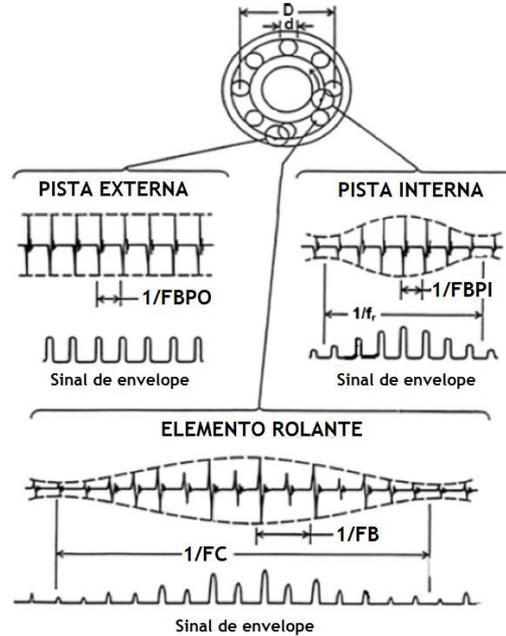


Figura 2.2: Sinais típicos e respectivos envelopes de defeitos localizados.

Fonte: Adaptada de Randall e Antoni (2010).

$$FBPO = \frac{ne \cdot fr}{2} \left\{ 1 - \frac{d}{D} \cos\theta \right\}, \quad (2.1)$$

$$FBPI = \frac{ne \cdot fr}{2} \left\{ 1 + \frac{d}{D} \cos\theta \right\}, \quad (2.2)$$

$$FC = \frac{fr}{2} \left\{ 1 - \frac{d}{D} \cos\theta \right\}, \quad (2.3)$$

$$FB = \frac{D}{2d} \cdot fr \left\{ 1 - \left( \frac{d}{D} \cos\theta \right)^2 \right\}, \quad (2.4)$$

onde  $fr$  é a velocidade do eixo em Hz e  $ne$  o número de elementos girantes do rolamento. Como a frequência característica para defeitos nos elementos girantes diz respeito ao choque existente entre estes últimos e uma mesma pista, seja interna ou externa, em geral, ocorrerão dois pulsos por revolução do eixo. Sendo assim, os harmônicos pares da  $FB$  são dominantes, especialmente no espectro de envelope. Tais frequências estão ilustradas na Figura 2.3.

De acordo com Scheffer e Girdhar (2004), a degradação do mancal de rolamento progride através de quatro estágios. No inicial, caracterizado pela existência de picos unicamente acima de 20 kHz no espectro em frequência, como visto no estágio  $D$  da Figura

2.4, os mancais de rolamento não apresentam defeitos aparentes, os quais, ainda incipientes, somente são detectados por meio de técnicas de elevada frequência de ressonância.

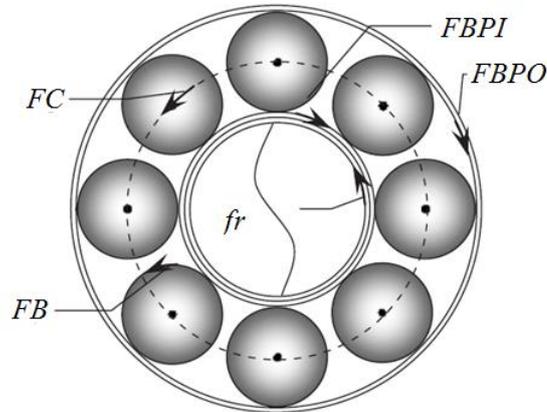


Figura 2.3: Frequências características de um mancal de rolamento.

Fonte: Adaptada de Abbasian *et al.* (2007).

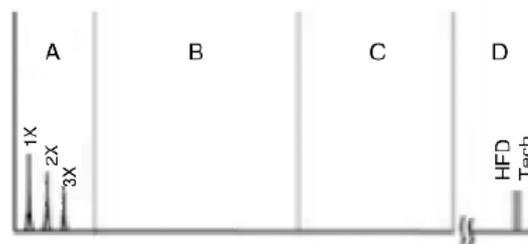


Figura 2.4: Espectro característico do primeiro estágio de degradação.

Fonte: Scheffer e Girdhar (2004).

No segundo estágio as superfícies fatigadas começam a apresentar porosidades, que, quando impactadas pelos elementos rolantes, excitam os modos de ressonância do mancal de rolamento, tipicamente localizados entre 5 e 20 kHz. Dependendo da severidade do dano é possível observar a modulação em amplitude do sinal gerado, caracterizada no espectro por bandas laterais no entorno das frequências características de defeito, como ilustra o estágio C da Figura 2.5.

À medida que a severidade dos defeitos aumenta, as frequências discretas do mancal de rolamento passam a ser visíveis no espectro, visto no estágio B da Figura 2.6. O desgaste nas pistas, desprezível no princípio, se torna evidente. Neste estágio Scheffer e Girdhar (2004) recomendam sua substituição, uma vez que a vida remanescente situa-se entre 1 hora ou 1% de sua vida média, segundo estudos estatísticos.

No estágio final, as porosidades emergem nas pistas, tornando o caminho de rolamento severamente rugoso. As componentes discretas das frequências naturais do rolamento fundem-se sob a forma de um ruído de fundo de elevada frequência, como visto na Figura 2.7.

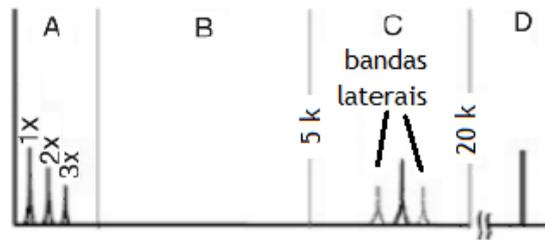


Figura 2.5: Espectro característico do segundo estágio de degradação.

Fonte: Adaptada de Scheffer e Girdhar (2004).

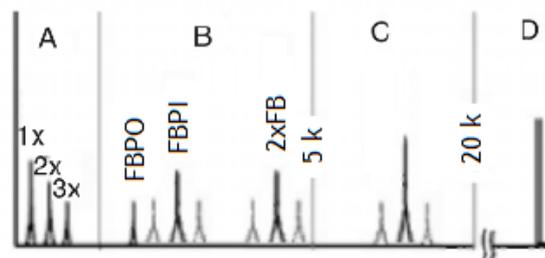


Figura 2.6: Espectro característico do terceiro estágio de degradação.

Fonte: Adaptada de Scheffer e Girdhar (2004).

Neste estágio o mancal de rolamento está perigosamente danificado. Se autorizada sua permanência em operação a gaiola irá se partir, permitindo o contato entre os elementos rolantes e a formação de micro soldas.

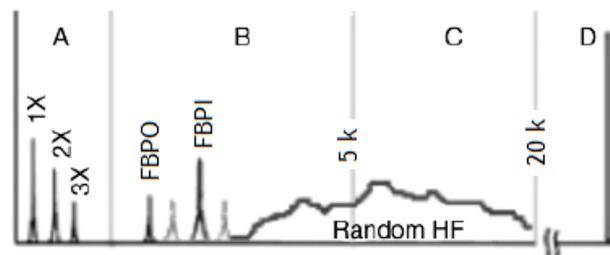


Figura 2.7: Espectro característico do quarto estágio de degradação.

Fonte: Adaptada de Scheffer e Girdhar (2004).

Por fim, Randall e Antoni (2010) destacam que a análise deve reconhecer que os efeitos da modulação são importantes. Em geral, defeitos na pista interna são modulados à velocidade do eixo, e nos elementos rolantes à velocidade da gaiola. Para carregamentos unidirecionais os defeitos na pista externa não são modulados, contudo, alguma modulação na velocidade do eixo pode ocorrer caso existam esforços de desbalanceamento e desalinhamento.

Como a efetividade do diagnóstico é diretamente influenciada pela qualidade do método de limpeza, faz-se necessária a seleção adequada dos mecanismos empregados para este fim. Neste trabalho serão apresentados os métodos da *LMD* e do envelope tradicional baseado na Transformada de Hilbert-Huang compilado por Randall e Antoni (2010).

## 2.2 Métodos de diagnóstico

As seções seguintes exploram as bases teóricas das metodologias de diagnóstico abrangidas por este trabalho com ênfase nos algoritmos originais concebidos pelos respectivos autores.

### 2.2.1 Envelopamento tradicional

Para o desenvolvimento do algoritmo de envelopamento tradicional serão utilizados os mesmos processos previstos em Randall e Antoni (2010), ditos eficientes para uma ampla gama de casos, desde rolamentos de turbinas de alta velocidade a torres de radar com elevado período de revolução. Suas etapas estão listadas na Figura 2.8, as quais correspondem a uma coletânea de diversas técnicas.

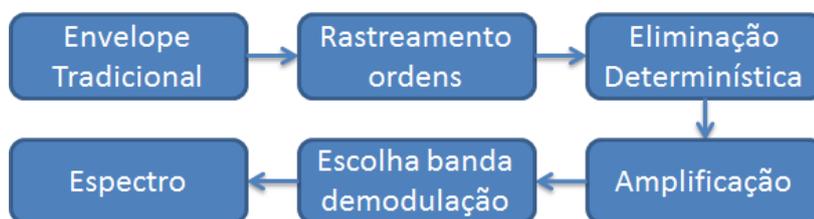


Figura 2.8: Fluxograma do algoritmo de envelope tradicional.

Inicialmente aplica-se a técnica de rastreamento de ordens para eliminação das flutuações de velocidade. Isso é feito, principalmente, para evitar o amontoamento das componentes de frequências discretas demonstrado na Figura 2.9.

Se um sinal de amplitude constante é síncrono à velocidade do eixo, então, um número fixo de amostras é coletado a cada revolução, tornando-as indistinguíveis de um sinal senoidal puro. Caso seja empregada uma amostragem temporal normal, o espectro espalha-se por uma faixa de frequências correspondente à variação da velocidade do eixo, também conhecida como escorregamento.

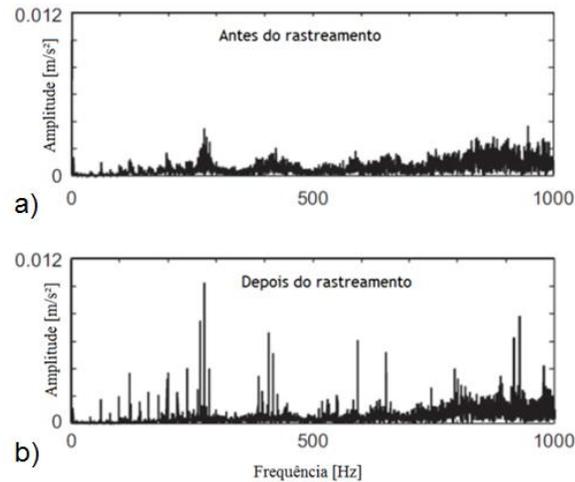


Figura 2.9: Espectro de um sinal antes, "a", e após, "b", o rastreamento de ordens.

Fonte: Adaptada de Randall e Antoni (2010).

A melhor maneira para rastrear ordens consiste em reamostrar digitalmente o sinal com base em uma referência gerada a partir de um sensor ótico síncrono à velocidade do eixo, como a apresentada na Figura 2.10. Com isto, obtém-se um número de amostras equivalente para cada incremento de ângulo.

Para tanto, o algoritmo automaticamente detecta os picos existentes no sinal de referência, armazenando suas respectivas posições em um vetor. Em seguida, faz a determinação do número de amostras existentes entre dois pontos consecutivos deste vetor, o qual será comparado à razão  $fs/fr$ , onde  $fs$  corresponde à taxa de amostragem e  $fr$  à velocidade de rotação do eixo da máquina, ambas em Hz. Caso o valor encontrado seja diferente desta razão, a rotina forçará a reamostragem deste trecho do sinal, de modo que cada ciclo completo possua exatamente  $fs/fr$  amostras.

As versões original, com 100 amostras, e reamostrada digitalmente, de 400 amostras, de um sinal hipotético são apresentadas na Figura 2.11.

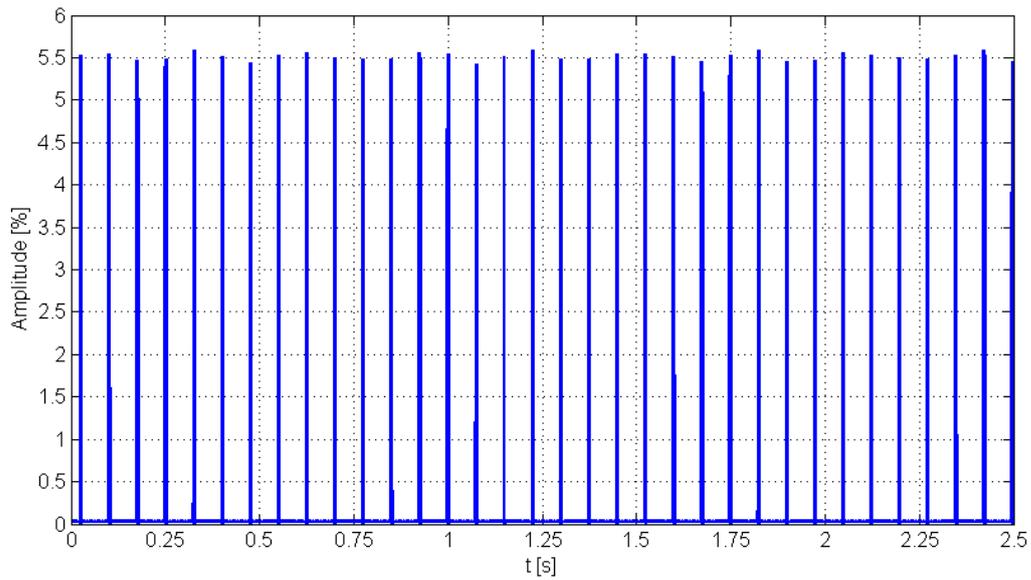


Figura 2.10: Amostra do sinal gerado pelo sensor óptico.

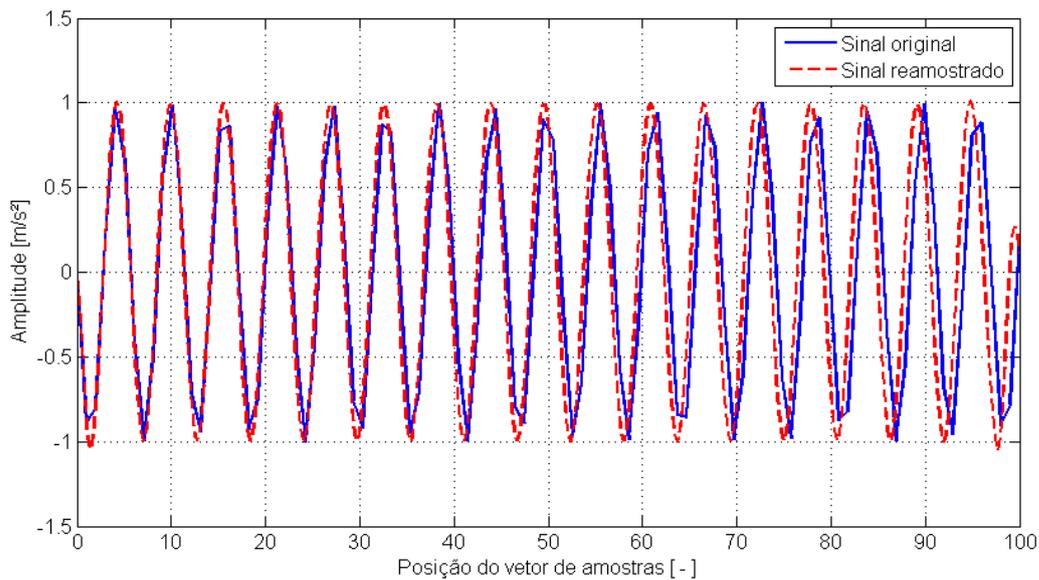


Figura 2.11: Sinal original e sua versão reamostrada digitalmente.

Na sequência o algoritmo inicia uma rotina para eliminação das componentes determinísticas do sinal. Segundo Randall *et al.* (2011), este processamento é necessário devido à dominância espectral exercida pelas mesmas, especialmente no caso de caixas de engrenagens, fazendo com que os sinais provenientes dos defeitos nos mancais de rolamento sejam mascarados. Por este motivo, Randall e Antoni (2010) afirmam ser vantajosa a separação destas componentes do sinal antes da realização da análise de envelope propriamente dita.

A Figura 2.12 ilustra este processamento, trazendo em “a” um sinal original coletado em uma caixa de engrenagens, em “b” o sinal contendo apenas as componentes determinísticas, e em “c” o sinal resultante da subtração de “a” por “b”.

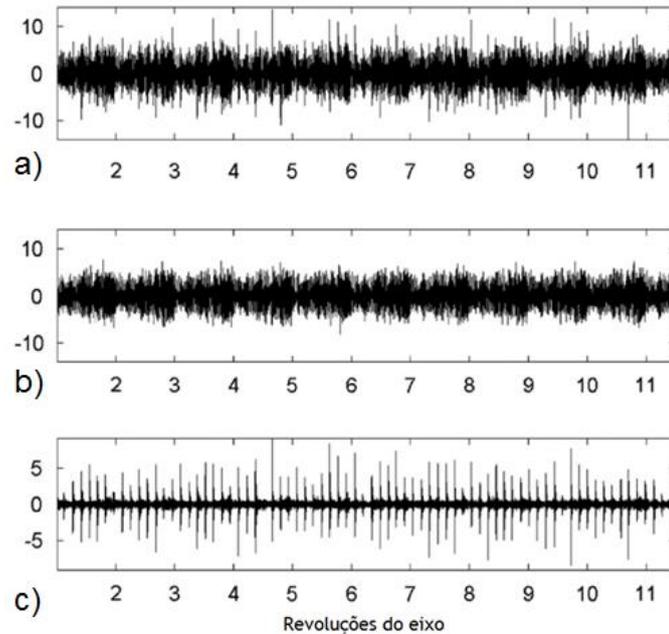


Figura 2.12: Exemplo da técnica de separação dos sinais.

Fonte: Adaptada de Randall e Antoni (2010).

Ainda segundo Randall *et al.* (2011), esta separação é possível por meio de diversos métodos, cada qual com seus respectivos conjuntos de vantagens e desvantagens, dentre os quais destacam-se:

a) Médias síncronas temporais (*Time synchronous Average – TSA*)

Fornecer uma distorção residual mínima e resulta na melhor separação. No entanto, requer uma etapa de separação angular para cada conjunto de harmônicos. Randall e Antoni (2010) destacam que este processo, na prática, é feito por meio da média de uma série de segmentos do sinal  $x(t)$ , cada um correspondendo a um período do sinal de sincronismo.

As características do filtro gerado por meio da técnica são mostradas na Figura 2.13, o qual pode ser interpretado com um “pente” que engloba os harmônicos da frequência periódica. Quanto maior o número de harmônicos, maior a seletividade do filtro e maior a rejeição de componentes não harmônicas.

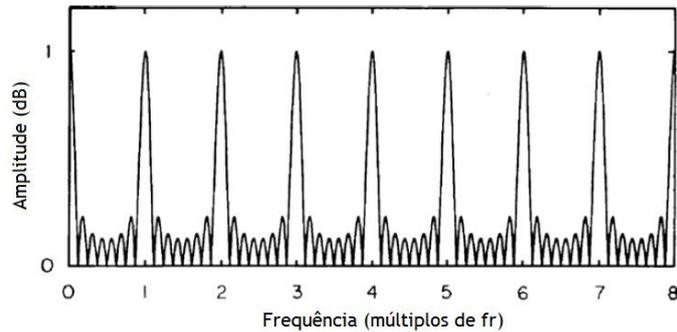


Figura 2.13: Características do filtro "pente" gerado pela técnica TSA.

Fonte: Adaptada de Randall e Antoni (2010).

b) Predição linear (*Auto-regressive – AR*)

Visa separar a parte “previsível”, ou determinística, do sinal. A escolha do conteúdo a ser removido depende do modelo autoregressivo utilizado. De acordo com Randall e Antoni (2010), a função de transferência resultante do processamento caracteriza um filtro de resposta ao impulso finita, *Infinite Impulse Response – IIR*, do tipo “todo-polo”, ou seja, àquele formado apenas por coeficientes do denominador. Ainda segundo os autores, estes coeficientes podem ser obtidos através das equações de Yule-Walker.

c) Cancelamento auto-adaptivo (*Self Adaptive Noise Cancellation – SANC*)

Remove todas as componentes determinísticas e suas bandas laterais. Trata-se de uma variação do método de cancelamento adaptativo, o qual realiza a separação das componentes determinísticas de um sinal primário por meio de um filtro desenvolvido a partir de um sinal de referência. Não é exigido que este último seja idêntico ao primeiro, apenas relacionável por meio de uma função de transferência.

Contudo, esta metodologia depende fortemente da disponibilidade de um sinal de referência não contaminado, o que, na prática, muitas vezes não é possível. Por este motivo foi introduzido o método auto-adaptativo, que utiliza como sinal de referência uma versão atrasada do próprio sinal primário. Randall e Antoni (2010) destacam que isso é possível pelo fato do tamanho do atraso ser superior ao comprimento de correlação do sinal não determinístico.

A técnica fornece como resposta um filtro recursivo com um determinado número de coeficientes e cujo erro, resultante da subtração entre os sinais primário e de referência, é utilizado para atualizar suas variáveis. Este processo emprega um algoritmo baseado em médias mínimas quadráticas (*Least Mean Squares – LMS*) para determinação da função de transferência em uma rotina cujos parâmetros comprimento do filtro,  $N$ , e coeficiente de convergência,  $\mu$ , são variados linear e exponencialmente, respectivamente.

A Figura 2.14 fornece uma interpretação visual da técnica, onde um sinal primário é subtraído da adaptação do sinal atrasado para fornecer o sinal aleatório do rolamento, que, no

caso, corresponde ao erro. Este último irá realimentar o filtro para a minimização do valor eficaz do erro.

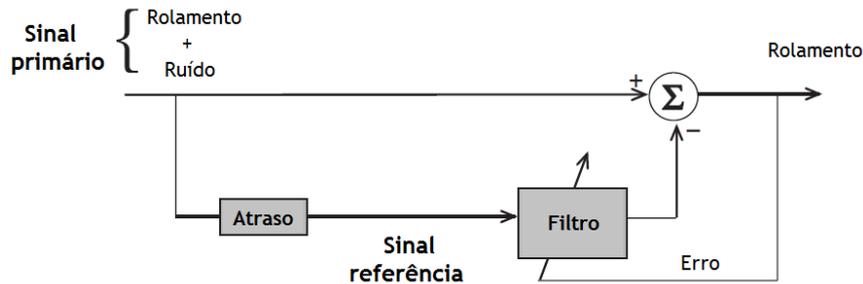


Figura 2.14: Princípio do filtro SANC.

Fonte: Adaptada de Randall e Antoni (2010).

Antoni e Randall (2004) citam que o atraso utilizado deve ser o menor possível, uma vez que o comprimento da correlação não diminui com o aumento do primeiro. Além disso, concluem que a escolha do comprimento do filtro não deve ser inferior ao inverso do tamanho da banda de filtragem  $B$ , isto é,  $N_{mín} = 1/B$ .

d) Separação discreto/aleatório (*Discrete Random Separation – DRS*)

De acordo com Randall e Antoni (2010), fornece resultados mais pobres que no SANC, porém, não requer as etapas de iteração recursiva. Somado a isto, pelo fato de ser realizado no domínio da frequência, torna o processo muito mais ágil.

Ainda segundo Randall e Antoni (2010), neste método a função de transferência é calculada a partir de dois blocos de dados distanciados por um atraso  $\Delta$ . Denotando por  $Y(f)$  e  $Y\Delta(f)$  as transformadas discretas de Fourier de dois blocos de dados de frequência  $f$ , a função de resposta em frequência correspondente é dada pela equação 2.5:

$$H(f) = \frac{E\{Y(f)Y_{\Delta}^*(f)\}}{E|Y(f)|^2}. \quad (2.5)$$

Deve-se ressaltar que os blocos de dados devem ser janelados antes da migração para o domínio da frequência, a fim de se evitar excessivos erros por vazamento espectral.

O tamanho da transformada  $N$  deve ser de 10 a 20 períodos maior que a menor frequência que se deseja remover, e a quantidade de atraso usualmente é a mesma utilizada no processo auto-adaptativo.

Após a remoção das frequências discretas, o sinal dos rolamentos ainda pode estar mascarado em outras faixas de frequência. Como os acelerômetros estão acoplados à carcaça dos equipamentos, pressupõe-se que parte da energia do sinal seja dissipada ao longo do

caminho de transmissão, sendo então detectado de forma menos impulsiva quando comparado à fonte. Para remover os efeitos indesejados do caminho de transmissão é utilizado o método conhecido como *MED*.

De acordo com Randall e Antoni (2010), a *MED* foi desenvolvida para reduzir o espalhamento das funções de resposta ao impulso, de forma a obter sinais mais próximos dos choques que os originaram. Objetiva encontrar um filtro inverso que contrabalanceie os efeitos do caminho de transmissão, assumindo que a excitação original é impulsiva e, portanto, possui elevada curtose. O nome deriva do fato que uma entropia crescente corresponde a uma desordem crescente, assim, a minimização da entropia deve maximizar a estrutura do sinal de origem. Em outras palavras, consiste na maximização da curtose da resposta do filtro invertido.

A Figura 2.15 ilustra a ideia central deste processo, onde um sinal  $e(n)$  passa através de um filtro estrutural  $h$  cuja saída é somada a um ruído  $v(n)$  para fornecer a resposta  $x(n)$ . O filtro *MED*,  $f$ , produz a saída  $y(n)$ , a qual deve ser o mais próximo possível da entrada original  $e(n)$ . Como a entrada  $e(n)$  é desconhecida, assume-se que ela seja a mais impulsiva possível.

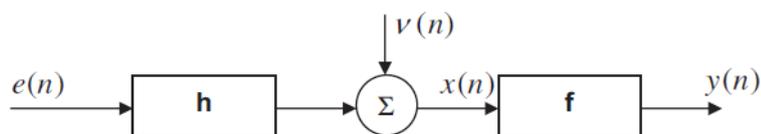


Figura 2.15: Filtragem inversa do processo *MED*.

Fonte: Randall e Antoni (2010).

Um exemplo desta aplicação é dado na Figura 2.16, que representa o sinal de vibração de um rolamento de alta velocidade. O sinal original, mostrado em “a”, apresenta uma curtose de -0,40. Após aplicação da predição linear auto-regressiva para remoção das frequências discretas, cujo sinal resultante é visto em “b”, os pulsos tornaram-se visíveis e a curtose aumentada para 1,25. Em seguida, foi utilizada a técnica da mínima entropia de deconvolução, em “c”, ampliando a curtose para 38,55.

Segundo Diniz *et al.* (2014), o filtro de Wiener determina a melhor relação linear em forma fechada entre as realizações de dois processos conjuntamente. Nesse contexto, o problema de predição linear pode ser visto como um caso especial em que  $y(n)$  representa uma futura amostra  $x(n+1)$  do outro processo. Por sua generalidade, o filtro de Wiener encontra larga aplicação numa série de problemas, como identificação de sistemas, equalização de canal e cancelamento de ruído, além, naturalmente, da predição linear.

Uma vez concluída a etapa de amplificação do sinal, é necessário escolher a banda de demodulação do sinal. De acordo com Randall e Antoni (2010), devido aos elevados valores que a curtose espectral, do inglês *Spectral Kurtosis (SK)*, assume nas regiões das frequências de ressonância, onde o sinal impulsivo de um rolamento defeituoso é dominante, faz sentido

utiliza-la como filtro para extração da faixa com os maiores níveis de impulsividade. De fato, é um valor global que indica como a impulsividade de um sinal, se existente, é distribuída no domínio da frequência, sendo determinada a partir da transformada de Fourier de Tempo Curto, do inglês *Short Time Fourier Transform (STFT)*, calculada em um instante  $t$ , e obtida pela movimentação de uma janela temporal.

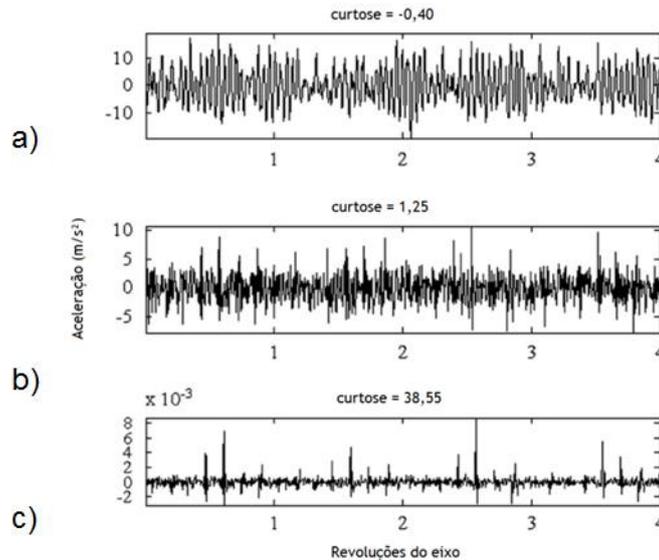


Figura 2.16: Exemplo de aplicação do método *AR* e *MED*.

Fonte: Adaptada de Randall e Antoni (2010).

O cálculo da curtose do envelope complexo de  $X(t,f)$  é feito através da equação 2.6.

$$SK(f) = \frac{\langle |X(t,f)|^4 \rangle}{\langle |X(t,f)|^2 \rangle^2} - 2, \quad (2.6)$$

sendo  $\langle \bullet \rangle$  um operador para extração da média temporal. A equação é subtraída de 2 para forçar uma curtose nula para o caso de  $X(t,f)$  ser uma distribuição Gaussiana complexa.

A Figura 2.17 resume o procedimento empregado para o cálculo da curtose espectral.

Este exemplo torna claro que para obtenção do valor máximo para a Curtose Espectral o comprimento da janela para determinação da *STFT* deve ser menor que o espaçamento existente entre os pulsos, mas, ao mesmo tempo, maior que o comprimento dos pulsos individuais. Como muitas vezes o espaçamento entre os pulsos é desconhecido, a melhor estratégia consiste em calcular a curtose espectral para distintos comprimentos de janela e selecionar aquela que resulte em maior valor global. Randall e Antoni (2010) demonstram

ainda que o filtro ótimo é do tipo passa banda com frequência central localizada no ponto de maior curtose espectral, como visto na Figura 2.18.

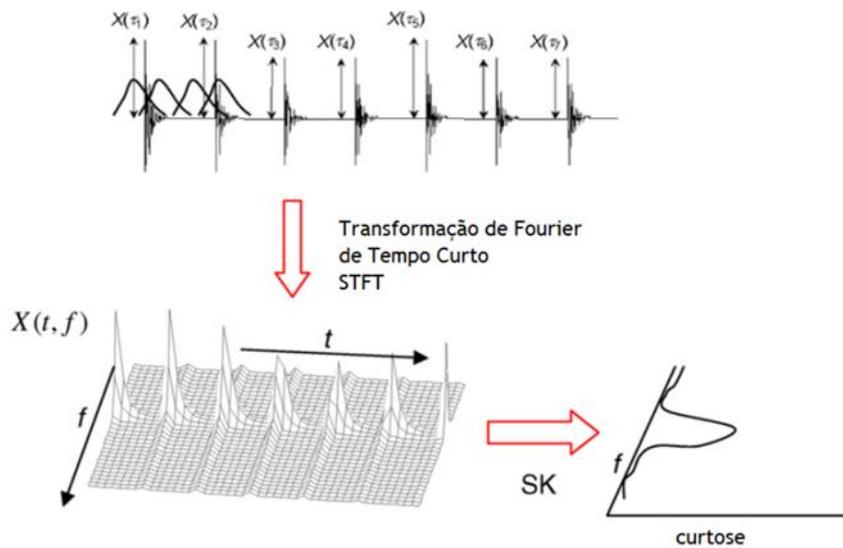


Figura 2.17: Cálculo da curtose espectral para um sinal simulado;

Fonte: Adaptada de Randall e Antoni (2010).

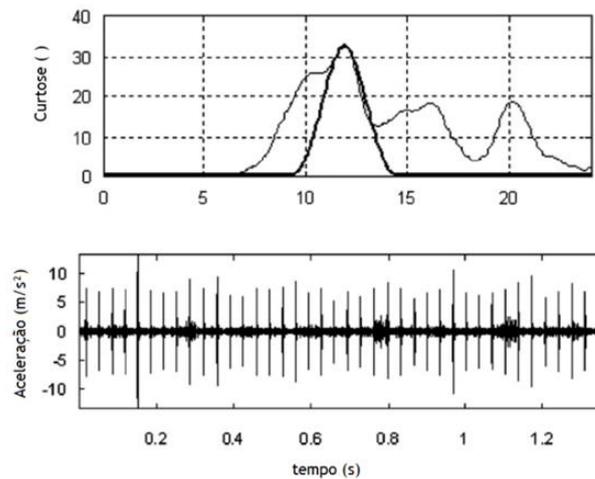


Figura 2.18: Filtro passa banda ideal comparado à curtose espectral.

Fonte: Adaptada de Randall e Antoni (2010).

Quando apresentadas em forma de cascata, as curtoses espectrais calculadas para diferentes comprimentos de janela dão origem ao curtograma, como o apresentado na Figura 2.19.

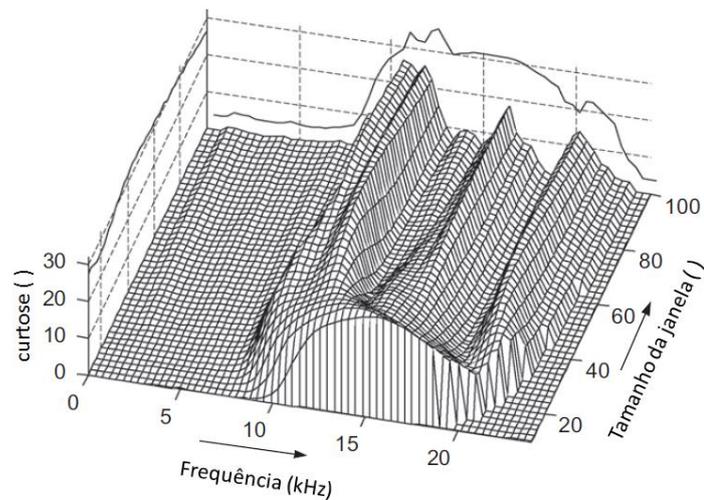


Figura 2.19: Curtograma para um sinal fraco de defeito em caixa de engrenagens.

Fonte: Adaptada de Randall e Antoni (2010).

Após aplicação do filtro dimensionado a partir das frequências e ordem obtidas no curtograma, o sinal é então demodulado em amplitude para formar o sinal de envelope, cujo espectro contém as informações de diagnóstico desejadas em termos tanto da frequência de repetição, para o caso de defeitos no elemento girante, como na frequência apropriada para as demais falhas quando estas atravessam a zona de carga.

Segundo Randall e Antoni (2010), ao invés de seguir o processamento realizado analogicamente por meio de técnicas digitais, é preferível empregar novas metodologias, como, por exemplo, a transformada de Hilbert-Huang. A primeira vantagem é que a extração da seção do espectro a ser demodulado é efetivamente feita por um filtro ideal, capaz de separá-la das componentes adjacentes muito mais fortes, o que não era possível com filtros analógicos.

Com isso gera-se um sinal complexo,  $x_a(t)$ , também conhecido como analítico, cuja parte real corresponde ao sinal original, e a imaginária à transformada de Hilbert da parte real.

A aplicação deste método é ilustrada na Figura 2.20. Nela, o envelope é tido como o módulo do sinal analítico obtido anteriormente.

Todavia, Randall e Antoni (2010) concluem ser preferível analisar a versão quadrática do sinal de envelope em detrimento ao original, pois o emprego da raiz quadrada na obtenção da forma primitiva introduz componentes anormais no espectro, as quais não existiam no sinal, causando um mascaramento da informação desejada. Neste ponto deve-se destacar que, matematicamente, o espectro de envelope de um sinal é a raiz quadrada do envelope quadrático.

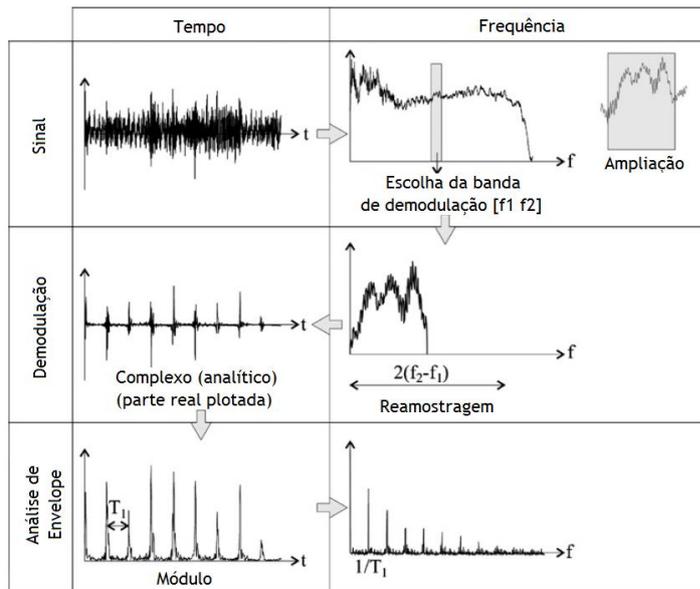


Figura 2.20: Análise de envelope utilizando a transformada de Hilbert-Huang.

Fonte: Adaptada de Randall e Antoni (2010).

No entanto, ao elevar o sinal de envelope ao quadrado, dobra-se seu conteúdo de frequências, sendo assim, a taxa de amostragem deve ser ajustada antes mesmo do processamento. Este ajuste corresponde à reamostragem do sinal analítico.

A outra vantagem deste processo é facilitar a geração do espectro quadrático,  $P$ , o qual é prontamente calculado através da convolução das Transformadas de Fourier de  $x_a(t)$  com seu complexo conjugado, como visto na equação 2.7.

$$P = F\{x_a(t)x_a^*(t)\} = F\{x_a(t)\} * F\{x_a^*(t)\}. \quad (2.7)$$

Quando esta transformação é realizada, apenas as frequências de diferença dos sinais aparecem, como, por exemplo, as bandas de espaçamentos laterais, as quais contêm as informações de modulação desejadas.

## 2.2.2 Decomposição média local

De acordo com Smith (2005), a representação de um sinal qualquer como o somatório de um conjunto de ondas planas, cada qual com uma fase constante, fornece um espectro em frequência cujo conteúdo é deveras revelador. No entanto, sinais altamente modulados, tanto em frequência quanto em amplitude, como àqueles extraídos de mancais de rolamento defeituosos, possuem espectros complicados.

Estes mesmos sinais podem ser representados como o produto de um sinal de envelope e um sinal de frequência modulada, ou, ainda, como a soma de um conjunto finito de funções produto do qual é possível extrair frequências instantâneas bem comportadas e imbuídas de significado físico.

A partir deste conceito, Smith (2005) desenvolveu um algoritmo de decomposição média local que consiste, basicamente, no desmembramento do sinal modulado em diversos conjuntos de funções produto, cujas frequências e envelopes instantâneos poderiam ser apresentados conjuntamente como uma função do tempo, dando origem às representações tempo-frequência (*RTF*).

Ainda de acordo com Smith (2005), o método convencional para obtenção da *RTF* utilizava um sinal analítico que, usualmente, derivava uma frequência instantânea incorreta, até mesmo negativa. Por outro lado, os resultados obtidos por meio da abordagem *LMD* são robustos e fisicamente plausíveis.

Segundo Wang *et al.* (2009), a decomposição pela *LMD* é feita através da separação progressiva do sinal modulado em frequência de um envelope modulado em amplitude contemplando as seguintes etapas:

- a) Obtenção dos máximos e mínimos locais de cada “meia-onda”, isto é, das amostras compreendidas entre máximos e mínimos consecutivos: desta forma, a amplitude média do  $ij$ -ésimo termo,  $m_{ij}$ , do vetor de máximos e mínimos locais pode ser determinada através dos extremos locais,  $n_{ij}(kl)$  e  $n_{ij}(kl+1)$ , como mostra a equação 2.8:

$$m_{ij}(t) = \frac{n_{ij}(k_l) + n_{ij}(k_{l+1})}{2}, \quad (2.8)$$

sendo  $k_l = k_1, \dots, k_{M-1}$  e  $t \in [k_l, k_{l+1})$ .

Estes valores médios locais, visualizados sob a forma de traços na Figura 2.21(a), são, então, suavizados através de médias móveis para dar origem a uma amplitude média local continuamente variada,  $\tilde{m}_{ij}(t)$ , representada pela linha vermelha da mesma figura. Como seu comprimento deve ser idêntico ao do sinal que está sendo processado,  $x(t)$ , é feita uma interpolação do tipo cúbica, ponderada pela distância entre dois valores médios locais consecutivos;

- b) Obtenção da estimativa do envelope local de cada “meia-onda”,  $a_{ij}$ , sendo seu cálculo realizado de maneira análoga ao das amplitudes médias locais, empregando, porém, a equação 2.9:

$$a_{ij}(t) = \frac{|n_{ij}(k_l) - n_{ij}(k_{l+1})|}{2}, \quad (2.9)$$

sendo  $k_l = k_1, \dots, k_{M-1}$  e  $t \in [k_l, k_{l+1})$ .  $k_l$  denota o índice dos máximos e mínimos locais e  $M$  o número total destes extremos.

A estimativa do envelope local, cuja envoltória é representada pela linha negra na Figura 2.21(b), também é suavizada por médias móveis para formar uma função de envelope continuamente variado,  $\tilde{a}_{ij}(t)$ , em verde na figura. Novamente é aplicada uma interpolação do tipo cúbica ponderada para tornar seu comprimento idêntico ao do sinal que está sendo processado;

- c) Em seguida, a amplitude média local continuamente variada,  $\tilde{m}_{ij}(t)$ , é subtraída do sinal original,  $x(t)$ , dando origem a uma função  $h_{ij}(t)$ , como visto na equação 2.10:

$$h_{ij}(t) = x(t) - \tilde{m}_{ij}(t); \quad (2.10)$$

- d) Logo após, a função  $h_{ij}(t)$  é dividida por  $\tilde{a}_{ij}(t)$  com o objetivo de formar um sinal puramente modulado em frequência,  $s_{ij}(t)$ , sem envoltória, do qual serão derivadas as frequências instantâneas, como mostra a equação 2.11:

$$s_{ij}(t) = \frac{h_{ij}(t)}{\tilde{a}_{ij}(t)}. \quad (2.11)$$

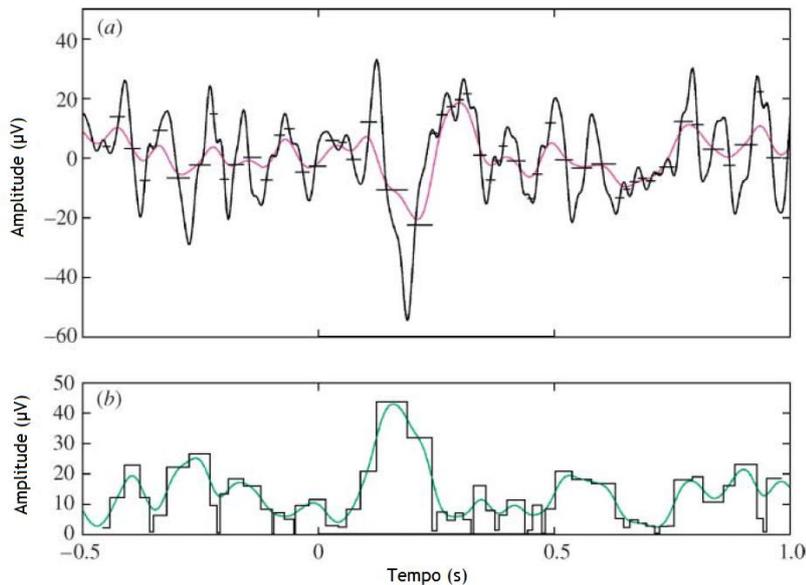


Figura 2.21: Exemplo de a) médias locais e suavizadas, e b) envelopes locais e suavizados.

Fonte: Adaptada de Smith (2005).

Caso o sinal resultante não apresente uma função envelope  $\tilde{a}_{ij}(t)$  unitária, todo o processo deverá ser repetido. O número de vezes em que este laço se repete é denotado pelo índice  $j$ ;

- e) Uma vez obtida uma função de envelope,  $\tilde{a}_{ij}(t)$ , constante, o sinal de envelope correspondente à primeira função produto é obtido através da multiplicação simultânea de todos os vetores  $\tilde{a}_{1j}(t)$ , como visto na equação 2.12:

$$a_1(t) = \tilde{a}_{11}(t) \cdot \tilde{a}_{12}(t) \dots \tilde{a}_{1j}(t) = \prod_{j=1}^n \tilde{a}_{1j}; \quad (2.12)$$

- f) Este envelope final é, então, multiplicado ao sinal puramente modulado em frequência final,  $s_{1j}(t)$ , para dar origem à primeira função produto,  $PF_1(t)$ :

$$PF_1(t) = a_1(t) \cdot s_{1j}(t); \quad (2.13)$$

- g) A partir desta função produto é possível calcular a fase,  $\varphi_1(t)$ , e frequência,  $\omega_1(t)$ , instantâneas por meio das equações 2.14 e 2.15, respectivamente:

$$\varphi_1(t) = \cos^{-1}(s_{1j}(t)), \quad (2.14)$$

$$\omega_1(t) = \frac{f_s}{2\pi} \cdot \frac{d\varphi_1(t)}{dt}; \quad (2.15)$$

- h) Por fim, a função produto  $PF_1(t)$  é subtraída do sinal original  $x(t)$  para formar o sinal  $u_1(t)$ , tratado como a versão suavizada, ou restante, de  $x(t)$ :

$$u_1(t) = x(t) - PF_1(t). \quad (2.16)$$

Caso  $u_1(t)$ , calculado pela equação 2.16, não resulte em uma função monotônica, todo o processamento deverá ser repetido, sendo o número total de iterações necessárias denotada pelo índice  $i$ .

A partir do somatório das funções produto obtidas e do último valor assumido pelo sinal  $u_i(t)$  é possível reconstruir o sinal original através da equação 2.17:

$$x(t) = \sum_{q=1}^i PF_i(t) + u_i(t). \quad (2.17)$$

O algoritmo original proposto por Smith (2005) descrito nesta subsecção é ricamente ilustrado pelo fluxograma da Figura 2.22.

Como citado anteriormente, as representações tempo-frequência obtidas através da decomposição *LMD* guardam as características das componentes que deram origem ao sinal processado, fornecendo, prontamente, uma interpretação física plausível.

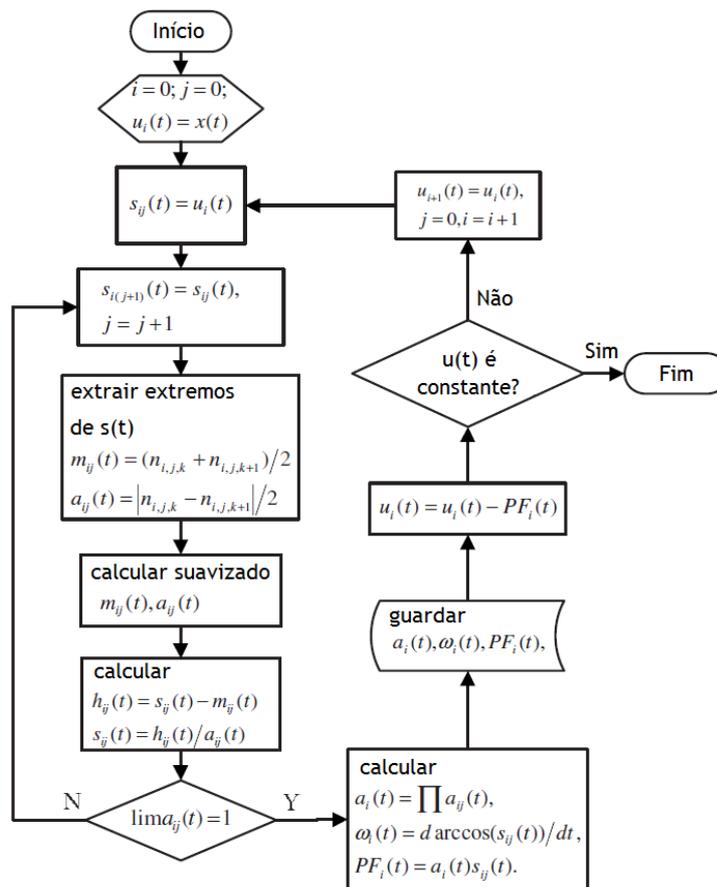


Figura 2.22: Fluxograma do algoritmo da *LMD*.

Fonte: Adaptada de Wang *et al.* (2010).

Esta condição pode ser demonstrada através da aplicação do algoritmo no sinal analítico híbrido  $x(t)$  proposto por Zhang, C. *et al.* (2017), dado pela equação 2.18:

$$x(t) = x_1(t) + x_2(t) + x_3(t), \quad (2.18)$$

sendo  $x_1(t)$  e  $x_2(t)$  calculados pelas equações 2.19 e 2.20, respectivamente:

$$x_1(t) = 1,5 \cdot e^{-800 \cdot t'} \cdot \sin(2\pi \cdot 500 \cdot t), \quad (2.19)$$

$$x_2(t) = 0,2 \cdot (1 + \cos(2\pi \cdot 100 \cdot t)) \cdot \cos(2\pi \cdot 1000 \cdot t), \quad (2.20)$$

e  $x_3(t)$  um ruído branco gaussiano com frequências entre 2 e 4000 Hz. Esta faixa foi escolhida, segundo o autor, devido ao impacto causado pelos ruídos de frequências mais elevadas aos extremos da distribuição. Na equação 2.19,  $t'$  é uma função com período fundamental de 1/160 s.

A forma de onda de  $x(t)$  e suas respectivas componentes são apresentadas na Figura 2.23 justapostas às funções produto. Como é possível perceber, as componentes  $x_1$ ,  $x_2$  e  $x_3$ , à direita, se assemelham em forma e amplitude às funções produto  $PF_1$ ,  $PF_2$  e  $PF_3$ , à esquerda.

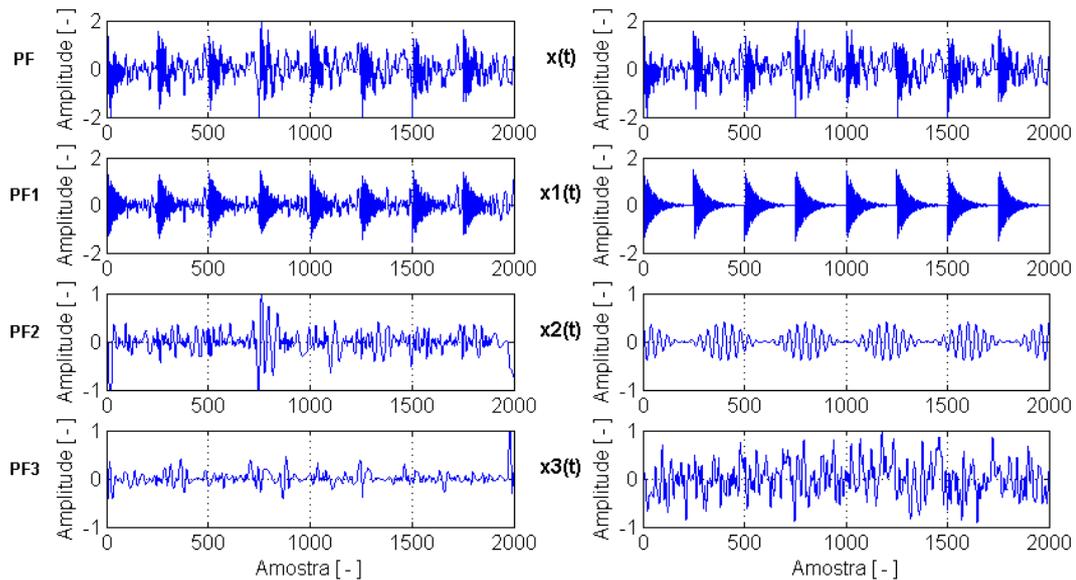


Figura 2.23: Forma de onda de  $x(t)$  justaposta às funções produto da *LMD*.

De acordo com Smith (2005), as funções produto podem ser encaradas como as melhores representações possíveis do sinal original em termos do produto de uma informação modulada e um envelope, enquanto a frequência instantânea rastreia suas oscilações. Wang *et al.* (2009) destacam que as frequências instantâneas são fundamentais para a interpretação de processos não estacionários e não lineares, contudo, ainda são pouco aplicadas.

Apesar da versatilidade e consistência desta nova técnica, Wang *et al.* (2009) alertam que os valores médios e envelopes locais não podem ser calculados através das equações 2.8 e 2.9 sem que o sinal original seja estendido. Como isto nem sempre é possível, são introduzidas divergências nos extremos do sinal que gradualmente influenciam o seu interior, perturbando a decomposição em processamento. Além disso, o uso de médias móveis para a suavização dos valores médios e envelopes locais causa o encurtamento de seus sinais, provocando o mesmo efeito.

Pensando nesta problemática, os autores propuseram um método melhorado para o cômputo destes extremos e seleção do número adequado de períodos para a suavização por médias móveis.

Para o tratamento do primeiro caso, os extremos direito e esquerdo são obtidos através da média ponderada dos três primeiros e últimos valores dos sinais de amplitudes e envelopes médios locais, respectivamente, como visto nas equações 2.21 a 2.24.

$$m_{ij}(t) = \frac{n_{ij}(k_1) + 2 \cdot n_{ij}(k_2) + n_{ij}(k_3)}{4}, \quad (2.21)$$

$$a_{ij}(t) = \frac{|n_{ij}(k_1) - n_{ij}(k_2)| + |n_{ij}(k_2) - n_{ij}(k_3)|}{4}, \quad (2.22)$$

onde  $t \in [k_0, k_1)$ .

$$m_{ij}(t) = \frac{n_{ij}(k_{M-2}) + 2 \cdot n_{ij}(k_{M-1}) + n_{ij}(k_M)}{4}, \quad (2.23)$$

$$a_{ij}(t) = \frac{|n_{ij}(k_M) - n_{ij}(k_{M-1})| + |n_{ij}(k_{M-1}) - n_{ij}(k_{M-2})|}{4}, \quad (2.24)$$

onde  $t \in [k_M, k_{M+1})$ ,  $k_0 = 1$ ,  $k_{M+1} = N$ , sendo  $N$  o comprimento do sinal.

Ainda segundo Wang *et al.* (2009), a escolha do número de períodos a ser utilizado para o cálculo da média móvel deve levar em conta os motivos pelos quais as informações estão sendo extraídas. No caso dos mancais de rolamento, onde se deseja analisar os sinais transientes oriundos dos impactos gerados pelos defeitos localizados, períodos muito longos podem atenuar as características impulsivas do sinal, enquanto períodos muito curtos podem causar o aumento tanto do consumo computacional quanto da contaminação do sinal por ruídos indesejáveis.

Por este motivo, propuseram determinar o número de períodos ideal,  $w$ , através da equação 2.25:

$$w = \frac{\max(\Delta(k_l))}{R}, \quad (2.25)$$

onde  $\Delta(k_l) = k_l - k_{l-1}$ , sendo  $l$  o índice dos máximos e mínimos locais consecutivos, e  $R$  uma constante escolhida também em função dos motivos da decomposição. Quando aplicada para extração de componentes transientes, Wang *et al.* (2009) recomendam a utilização de  $R = 5$ .

Apesar de sua adequabilidade em sinais não estacionários e não lineares, Yang *et al.* (2012) destacam que a principal deficiência da *LMD* é a mistura de modos, observada quando uma função produto é composta de sinais de escalas temporais distintas, ou ainda, quando sinais de escalas temporais similares residem em *PFs* diferentes. Uma vez que uma quantidade significativa de mixagem de modos pode inviabilizar a interpretação física de uma dada função produto, causando distorções na distribuição tempo-frequência do sinal resultante, os autores propõem uma melhoria do algoritmo original por meio da inserção de ruído branco.

A nova técnica, denominada Decomposição Média Local Composta (*Ensemble Local Mean Decomposition – ELMMD*), incorpora as seguintes etapas:

- a) Adição de ruído branco ao sinal original  $x(t)$ , obtendo um novo sinal  $y(t)$ ;
- b) Decomposição de  $y(t)$  em funções produto, *PF*, através da *LMD*;
- c) Repetição dos itens a) e b) por um determinado número de vezes, porém, empregando ruídos com amplitudes e frequências distintas;
- d) Extração da média de todas as *PFs* obtidas para obtenção da *PF* final.

Segundo Yang *et al.* (2012), o ruído branco contamina uniformemente diferentes componentes de escala do domínio tempo-frequência do sinal original, que será posteriormente decomposto pela *LMD*. Devido às características do banco de filtros estabelecido pelos ruídos de características distintas, grande parte da mistura de modos é eliminada. Ao mesmo tempo, quando um número suficiente de ruídos é utilizado, sua média tende a se aproximar de zero, anulando, desta forma, seus efeitos indesejados.

No entanto, Zhang, C. *et al.* (2017) informam que a efetividade da nova técnica proposta por Yang *et al.* (2012) é altamente influenciada pela escolha de seus parâmetros, tais como a largura da banda de frequências do ruído branco, sua amplitude, e o número de vezes que o procedimento será repetido.

Ainda de acordo com Zhang, C. *et al.* (2017), caso as amplitudes dos ruídos adicionados sejam muito superiores àsquelas do sinal original, serão produzidas *PFs* redundantes, exigindo elevado consumo computacional. Em contrapartida, em se tratando de amplitudes muito pequenas, os ruídos poderão não afetar os extremos do sinal decomposto, reduzindo drasticamente a capacidade de atenuação da mixagem de modos.

Ruídos com bandas de frequências mais elevadas também causam maior impacto sobre as distribuições dos extremos do sinal, contudo, o esforço computacional aumenta à medida que as frequências aumentam. Zhang, C. *et al.* (2017) destacam que um incremento computacional similar é observado quando se aumenta o número de vezes em que o processo é repetido, todavia, quando reduzido pode ser insuficiente para eliminar os resquícios do ruído adicionado em cada *PF*.

Para a determinação da amplitude ideal do ruído branco adicionado, os autores propõem a utilização de um índice denominado Erro Relativo Médio Quadrático, do inglês *Relative Root-Mean-Square Error (RRMSE)*. O *RRMSE* é definido como a razão entre o erro médio quadrático da decomposição do sinal original,  $x(t)$ , e seu valor médio quadrático, sendo o erro da decomposição dado pela diferença entre  $x(t)$  e sua *PF* de maior relação,  $c_{max}$ . Matematicamente, o *RRMSE* é definido pela equação 2.26:

$$RRMSE = \sqrt{\frac{\sum_{k=1}^M (x(k) - c_{max}(k))^2}{\sum_{k=1}^M (x(k) - \bar{x})^2}}, \quad (2.26)$$

onde  $x(k)$  é a  $k$ -ésima amostra de  $x(t)$ ,  $M$  o número total de amostras de  $x(t)$  e  $\bar{x}$  o valor médio das amostras de  $x(t)$ .

Um valor de *RRMSE* próximo de zero sinaliza que a *PF* em questão,  $c_{max}$ , é similar ao sinal original e, portanto, contém não apenas a componente principal de  $x(t)$ , mas também ruído e outras componentes fracamente relacionadas. Em outras palavras, é observada a mixagem de modos nesta *PF*. Por outro lado, um valor ótimo de *RRMSE* indicará que a *PF* aproxima-se apenas de um único modo intrínseco de  $x(t)$ , mitigando a mistura. Zhang, C. *et al.* (2017) destacam ainda que o valor ideal assumido pela amplitude do ruído branco independe do número de vezes em que o procedimento é repetido.

A seleção da banda de frequências ideal do ruído branco aplicado também utiliza o conceito de maximização do *RRMSE* apresentado na equação 2.26, todavia, seu procedimento, disposto a seguir, é ligeiramente mais trabalhoso que o anterior, envolvendo as seguintes etapas:

- a) Definição de um conjunto de possíveis bandas de frequências,  $fb$ , determinadas através da equação 2.27.

$$f_b = i \cdot f_s, \quad (2.27)$$

onde  $f_s$  é a taxa de amostragem empregada para a captura do sinal, e  $i = 1, 2, 3, \dots, n$ ;

- b) Reamostragem do sinal original  $x(t)$  através de interpolação cúbica para dar origem a um sinal reamostrado  $x'(t)$ , cujo conteúdo amostral será  $i$  vezes maior que o de  $x(t)$ ;
- c) Decomposição do sinal  $x'(t)$  através da *LMD* para cada banda de frequências possível, calculando o *RRMSE* associado a cada  $fb$ ;
- d) Por fim, a  $fb$  ideal será aquela que apresentar o maior *RRMSE* associado.

Uma vez definidas a amplitude e a banda de frequências ideais, é necessário estabelecer o número de vezes em que o procedimento deverá ser repetido. Em suma, este valor é

proporcional à quantidade de ruído branco que será adicionado ao sinal original. Para isto, Zhang, L. *et al.* (2017) sugerem o emprego da Relação Ruído-Sinal (*Signal to Noise Ratio – SNR*), mostrada na equação 2.28.

$$SNR = 10 \cdot \log_{10}(p_1/p_2), \quad (2.28)$$

onde  $p_1$  é a potência associada à função produto mais próxima do sinal original, dada pelo quadrado do módulo da transformada discreta de Fourier desta *PF*, e  $p_2$  a potência associada ao ruído branco, calculada de maneira semelhante à antecessora, que, por sua vez, é igual à potência associada a  $x(t)$  subtraída de  $p_1$ .

O número de repetições ideal será aquele que produzir a maior *SNR* possível. Contudo, caso este valor seja muito elevado, poderá ocasionar um consumo computacional proibitivamente alto. Por outro lado, um número muito pequeno de repetições poderá ser insuficiente para cancelar os efeitos do ruído adicionado.

Este procedimento descrito por Zhang, L. *et al.* (2017) para obtenção dos parâmetros ótimos à *LMD* foi batizado de Decomposição Média Local Composta Otimizada (*Optimized Ensemble Local Mean Decomposition – OELMD*).

Ao adotar os valores de 0,6; 40 kHz e 100 para a amplitude, largura da banda de frequências e número de repetições, respectivamente, ditos ótimos por Zhang, L. *et al.* (2017), são obtidas as funções produto apresentadas na Figura 2.24 para o mesmo sinal original  $x(t)$  dado pelas equações 2.18, 2.19 e 2.20, e Figura 2.23.

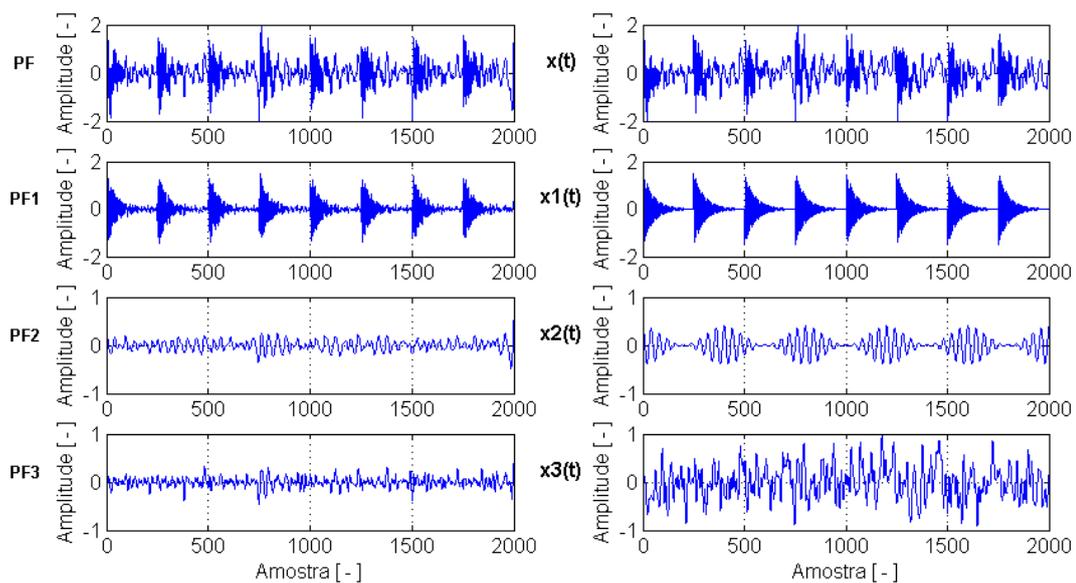


Figura 2.24: Forma de onda de  $x(t)$  justaposta às funções produto da *OELMD*.

De maneira similar à demodulação realizada pelo envelopamento tradicional, é possível obter o espectro quadrático do sinal da *LMD* através da equação 2.29:

$$P = \frac{1}{N} \sum_{k=1}^N |X_i(k)|^2, \quad (2.29)$$

onde  $X_i(k)$  é a transformada discreta de Fourier da  $PF_i(n)$ , e  $N$  o número total de amostras da respectiva *PF*, sendo que para a construção do espectro quadrático completo é necessário somar as funções  $P$  associadas a todas as *PF*.

Uma vez apresentados os métodos de diagnóstico que serão comparados, é necessário estabelecer um meio padronizado para analisa-los. Neste trabalho, assim como em grande parte da literatura revisada, as conclusões serão formuladas a partir da análise dos sinais tratados, dos espectros e do percentual de acertos obtido em um sistema especialista alimentado unicamente pelos sinais de vibração processados pelo respectivo método e as características do mancal de rolamento analisado.

Desta forma, a seção seguinte irá abordar o tema em detalhes, lançando luz sobre o mecanismo de solução embarcado no sistema especialista proposto.

### 2.2.3 Sistemas especialistas

De acordo com Suh e Murray (1994), sistemas de decisão alicerçados em regras, também denominados sistemas especialistas, são amplamente utilizados para a solução de paradigmas baseados em conhecimento. Segundo os autores, neste tipo de sistemas um conjunto de conhecimentos é transformado em uma estrutura “se – então” que concatena um ou mais domínios especialistas que interagem entre si.

Do ponto de vista técnico, todo sistema especialista deve possuir completude, definida como a habilidade de responder a todas as combinações possíveis de informações de entrada, e consistência, para assegurar que as regras estabelecidas estejam corretamente agrupadas e sem redundâncias e conflitos. No entanto, destacam que a completude de um sistema não o capacita a responder todas as questões a partir de informações incompletas.

Ainda segundo Suh e Murray (1994), lógicas complexas são comumente representadas por tabelas, fluxogramas e árvores de decisão. Na primeira, as informações são dispostas de forma tabular para facilitar sua identificação. Já nos fluxogramas, as decisões são testadas cronologicamente à medida que aparecem, contudo, sua visualização pode ser dificultada em problemas complexos. Em contrapartida, as tabelas são de fácil leitura, construção e modificação.

As árvores de decisão constituem outro método gráfico para a representação de sistemas complexos. Nelas, um nó representa um atributo, um ramo, ou arco, o valor do respectivo atributo, e as folhas, por sua vez, as respostas. A conversão de uma árvore de decisões em um conjunto de regras é bastante intuitiva, uma vez que cada ramo da árvore representa um teste “se – então”.

Uma forma alternativa de se representar uma lógica complexa é através da árvore- $k$ , do inglês *k-tree*. Por definição, uma *k-tree* é uma árvore  $n$ -ária cujas folhas são a consequência de outras regras, e cujos nós antecedem as regras propriamente ditas. Em suma, um nó de uma árvore tradicional corresponde a um ponto de decisão, enquanto em uma *k-tree* um nó representa uma decisão particular.

O uso das *k-tree*, em detrimento às árvores de decisão tradicionais, é indicado, pois, além de facilitar o entendimento da estrutura de um conjunto de regras inter-relacionado, reduz o volume de comparações necessárias. Este fato pode ser exemplificado da seguinte maneira: seja um conjunto de cinco regras,  $R1$  a  $R5$ , e cinco condições unitárias,  $A$ ,  $B$ ,  $C$ ,  $D$  e  $E$ , idênticas para todas as regras. Caso as regras sejam postas em ordem segundo uma árvore de decisões tradicional, o número de comparações necessárias será  $5 + 5 + 5 + 5 + 5 = 25$ . Por outro lado, se dispostas de acordo com uma árvore *k-tree*, o número de comparações será  $4+5 = 9$ , das quais quatro comparações serão de profundidade e cinco de superfície. Quanto maior a quantidade de parâmetros compartilhados pelas regras, maior o benefício oferecido pelas *k-tree*. A Figura 2.25 completa o entendimento do exemplo apresentado.

Por fim, Suh e Murray (1994) concluem que a construção de uma árvore *k-tree* plena, em termos de completude e consistência, requer o atendimento das seguintes premissas:

- a) As regras devem ser particionadas em conjuntos articulados. Deste modo, os testes de completude e consistência são feitos em cada articulação, onde as regras possuem um final comum;
- b) Conexões disjuntivas, “ou”, não são permitidas. Em árvores do tipo *k-tree* as ramificações são usadas apenas como conexões conectivas, “e”;
- c) Uma determinada regra em um conjunto articulado deve possuir conclusão única;
- d) Uma regra não pode conter cláusulas “senão”, devido aos seus efeitos indesejados, como confundir o real significado de uma regra. Toda regra contendo cláusulas “senão” devem ser reescritas, e;
- e) Um determinado parâmetro, seja de condição ou de conclusão, deve assumir apenas valores conhecidos de um conjunto finito de possibilidades. Por este motivo, as árvores *k-tree* são mais indicadas para lidar com parâmetros discretos.

Apesar das premissas não imporem limitações estreitas aos conjuntos de regras, muitas vezes não é possível cumpri-las adequadamente em sistemas reais. Nestes, persevera o equilíbrio entre a simplicidade e o completo atendimento às premissas, sendo a primeira obtida comumente à custa da segunda.

**CONJUNTO DE CINCO REGRAS**

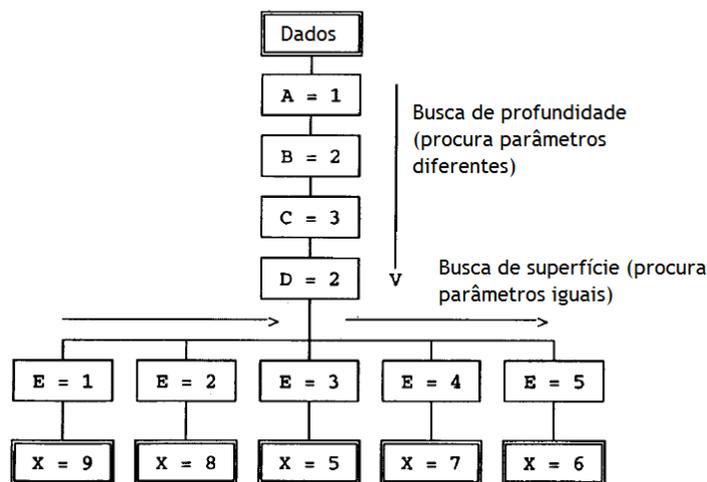
R1: Se A=1 e B=2 e C=3 e D=2 e E=1 ENTÃO X=9

R2: Se A=1 e B=2 e C=3 e D=2 e E=2 ENTÃO X=8

R3: Se A=1 e B=2 e C=3 e D=2 e E=3 ENTÃO X=5

R4: Se A=1 e B=2 e C=3 e D=2 e E=4 ENTÃO X=7

R5: Se A=1 e B=2 e C=3 e D=2 e E=5 ENTÃO X=6

**K-tree construída a partir das regras**Figura 2.25: Representação de uma *k-tree* de cinco regras.

Fonte: Adaptada de Suh e Murray (1994).

Como citado no Capítulo 1, os diversos componentes de uma máquina rotativa produzem vibrações elevadas quando parcial ou completamente degradados. A manutenção executada de acordo à condição baseada em análise de vibração permite o aumento da disponibilidade do equipamento e evita a paralisação não programada devido à quebra. Neste modelo de manutenção, a interpretação dos dados vibracionais é de responsabilidade de um técnico, cuja tomada de decisão tem sido apreciavelmente auxiliada por sistemas especialistas na atualidade.

Um sistema especialista, segundo Boumahdi *et al.* (2010), pode ser estabelecido sempre que a experiência individual, ou de um grupo de especialistas, pode ser traduzida sob a forma de regras. No entanto, em diversas situações não é possível extrair um conjunto aplicável à manutenção. Nestes casos, os mesmos são gerados por métodos de mineração de dados, como as redes neurais e as árvores de decisões. Ainda de acordo com Boumahdi *et al.* (2010), as árvores de decisão são usadas para o tratamento de problemas de classificação, e consiste em assignar classes a objetos utilizando um modelo formado por outro conjunto de objetos. Deste modo, os dados são apresentados sob a forma de uma árvore que permite a escolha dos

valores por meio de uma decisão tomada a partir de atributos preditivos. Assim, cada conjunto de dados é constituído de uma lista de atributos preditivos e de decisões a predizer.

A escolha dos atributos de teste existentes na árvore de decisão é feita com base nas informações contidas nos dados vibracionais e algoritmos de classificação. Boumahdi *et al.* (2010) cita alguns, tais como: algoritmo CART (1984), algoritmo ID3 (1986), algoritmo C4.5 (1993) e sua extensão J48, que é efetivamente empregado em seu trabalho e descrito a seguir:

- Seja um conjunto de atributos  $X$ ,  $\{X = X_1, X_2, \dots, X_i, \dots, X_n\}$ , onde  $n$  é o número total de atributos, um conjunto de classes  $C$ ,  $\{C = C_1, C_2, \dots, C_k\}$ , sendo  $k$  o número total de classes,  $|C_j|$ ,  $j = 1, 2, \dots, k$ , o número de amostras que pertencem ao conjunto  $C_j$ ,  $T$  o conjunto de amostras de treinamento e  $|T|$  o número total de amostras, então, a escolha do atributo de teste  $X_i$  dependerá dos seguintes critérios:

- a) Entropia: dada pela equação 2.29 e definida como a quantidade de informação necessária à identificação da classe de um elemento  $T$ .

$$info(T) = - \sum_{j=1}^k \frac{|C_j|}{|T|} \cdot \log_2 \left( \frac{|C_j|}{|T|} \right); \quad (2.29)$$

- b) Entropia condicional: caso  $T$  seja subdividido em subconjuntos  $T_i$  com base em um atributo preditivo  $X_i$ , como visto na Figura 2.26, deverá ser utilizada a entropia condicional, calculada pela equação 2.30. É descrita como a quantidade de informação necessária à identificação da classe de elemento  $T$  uma vez obtido o valor do atributo  $X_i$ .

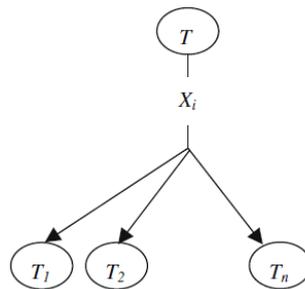


Figura 2.26: Estrutura de uma árvore de decisão para um conjunto  $T$ .

Fonte: Boumahdi *et al.* (2010).

$$info(X_i, T) = - \sum_{i=1}^n \left( \frac{|T_i|}{|T|} \sum_{j=1}^k \frac{|C_j|}{|T|} \cdot \log_2 \left( \frac{|C_j|}{|T|} \right) \right); \quad (2.30)$$

- c) Ganho de entropia: também denominada ganho de informação devido ao atributo  $X_i$ , representa a diferença entre a quantidade de informação necessária à identificação da classe de um elemento  $T$  e a quantidade de informação necessária à identificação de um elemento  $T$  uma vez obtido o valor do atributo  $X_i$ .

Este critério, calculado através da equação 2.31, permite a escolha do atributo de maior importância.

$$ganho(X_i, T) = info(T) - info(X_i, T); \quad (2.31)$$

- d) Taxa de ganho, ou ganho de entropia normalizado: obtida através da equação 2.32:

$$TG(X_i, T) = \frac{ganho(X_i, T)}{-\sum_{i=1}^n \frac{|T_i|}{|T|} \cdot \log_2 \left( \frac{|T_i|}{|T|} \right)}. \quad (2.32)$$

A taxa de ganho é utilizada para corrigir a brusca variação da entropia quando considerados o número de amostras e a proporção destes valores contidos nos dados. Somado a isto, evita o desbalanceamento da árvore, causado pela maior incidência de nós em um de seus lados. O atributo escolhido será aquele com maior taxa de ganho. Com base nas premissas de completude e consistência de Suh e Murray (1994), e levando em consideração os critérios para a escolha dos atributos de teste, Boumahdi *et al.* (2010) estabeleceram, a partir 54 amostras de sinais, a árvore tipo *k-tree* ilustrada na Figura 2.27, capaz de detectar a existência e indicar o componente defeituoso em um mancal de rolamento. Para esta árvore foram escolhidas as classes mostradas na Tabela 2.1, sendo seus atributos a curtose, o fator de crista, *CF*, o valor eficaz, *RMS*, e a severidade de vibração em dB, vistos a seguir:

Tabela 2.1: Classes da árvore de decisão.

Classe	Símbolo
Mancal de rolamento sem defeito	<i>Good</i>
Mancal de rolamento com defeito na pista interna	<i>Dir</i>
Mancal de rolamento com defeito na pista externa	<i>Dor</i>
Mancal de rolamento com defeito em ambas as pistas	<i>Dor_ir</i>

Fonte: Adaptada de Boumahdi *et al.* (2010)

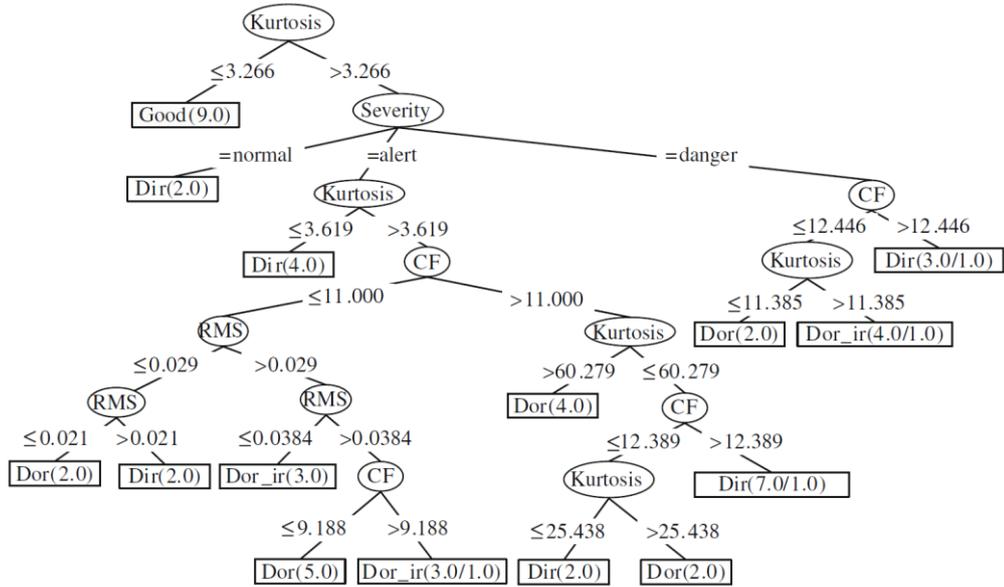


Figura 2.27: *k-tree* utilizada para a detecção de defeitos em um mancal de rolamento.

Fonte: Boumahdi *et al.* (2010).

- a) Valor Eficaz (*RMS*): raiz média quadrática de um sinal contendo  $N$  amostras, determinado pela equação 2.33:

$$RMS = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N x_i^2}; \quad (2.33)$$

- b) Curtose (*kurtosis*): medida de dispersão que caracteriza o "achatamento" da curva da função de distribuição, sendo calculada através da equação 2.34:

$$curtose = \frac{\frac{1}{N} \cdot \sum_{i=1}^N (x_i - \bar{x})^4}{\sigma}, \quad (2.34)$$

onde  $x_i$  é a amplitude de uma dada amostra  $i$ ,  $\bar{x}$  a média das amplitudes das amostras e  $\sigma$  o desvio padrão;

- c) Fator de Crista (*Crest Factor – CF*): corresponde à razão entre o valor máximo de um sinal e seu valor efetivo, como mostra a equação 2.35:

$$CF = \frac{\max|x_i|}{RMS}; \quad (2.35)$$

d) Severidade de vibração ( $RMS(dB)$ ): calculada em função do valor eficaz por meio da equação 2.36:

$$RMS(dB) = 20 \cdot \log\left(\frac{RMS}{RMS_{ref}}\right), \quad (2.36)$$

sendo  $RMS_{ref}$  o valor eficaz calculado para um mancal de rolamento novo.

Os valores de referência para cada atributo testado são apresentados nos ramos da árvore de decisão. Estes, por sua vez, podem ser definidos a partir de normas, da experiência dos especialistas, ou, ainda, a partir dos parâmetros vibracionais do mancal de rolamento.

O fluxograma proposto por Ebersbach e Peng (2008) apresentado na Figura 2.28 e adaptado por Boumahdi *et al.* (2010) sob a forma da *k-tree* ilustrada na Figura 2.29, também é utilizado com a finalidade de detecção e identificação de componentes defeituosos. A árvore em questão emprega as classes apresentadas na Tabela 2.2, tendo como atributos a curtose, o valor eficaz e as amplitudes de vibração às frequências características de defeito na pista interna,  $A_{FBPI}$ , e harmônica,  $A_{2FBPI}$ , e pista externa,  $A_{FBPO}$ , e harmônica,  $A_{2FBPO}$ , do espectro quadrático.

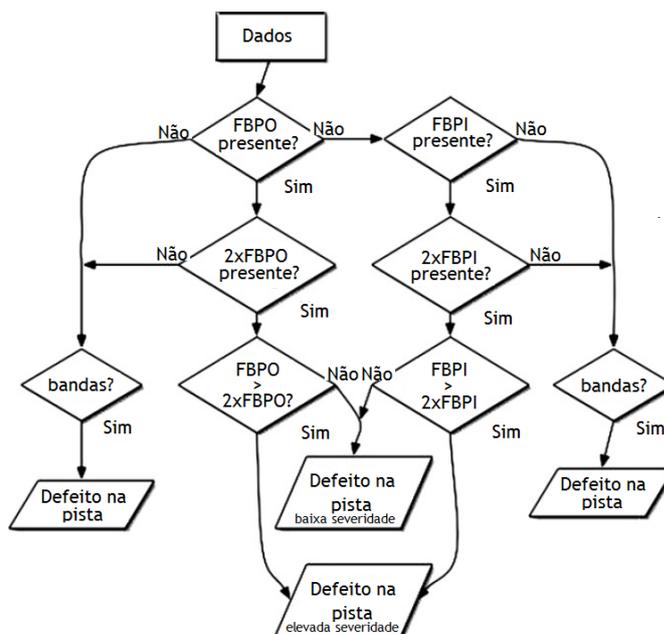


Figura 2.28: Fluxograma para a detecção e identificação do componente defeituoso.

Fonte: Adaptada de Ebersbach e Peng (2008).

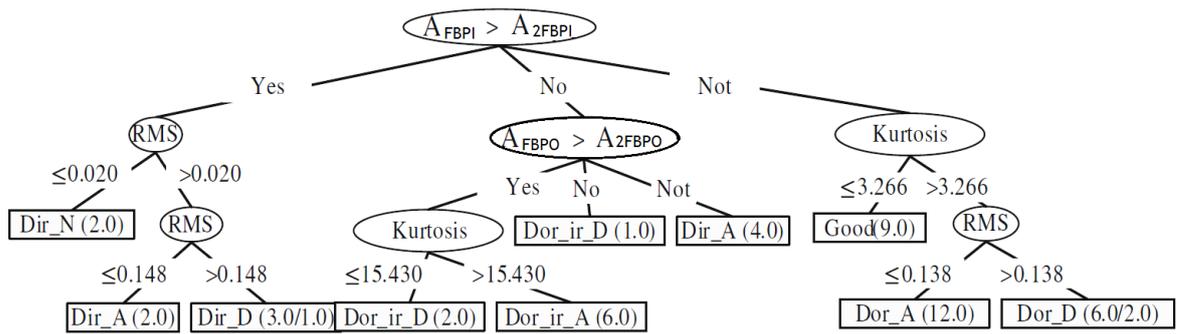


Figura 2.29: *K-tree* empregada para a detecção e identificação do componente defeituoso.

Fonte: Boumahdi *et al.* (2010).

Boumahdi *et al.* (2010) enfatizam que os sistemas especialistas propostos por meio de ambas as metodologias superam àqueles desenvolvidos unicamente a partir da experiência de especialistas, sendo capazes de alcançar uma taxa de acertos de 92 e 97%, respectivamente.

Tabela 2.2: Classes da árvore de decisão para a determinação do componente defeituoso.

Classe	Símbolo
Rolamento sem defeito	<i>Good</i>
Rolamento com defeito na pista externa e estado normal	<i>Dor_N</i>
Rolamento com defeito na pista externa e estado de alerta	<i>Dor_A</i>
Rolamento com defeito na pista externa e estado de perigo	<i>Dor_D</i>
Rolamento com defeito na pista interna e estado normal	<i>Dir_N</i>
Rolamento com defeito na pista interna e estado de alerta	<i>Dir_A</i>
Rolamento com defeito na pista interna e estado de perigo	<i>Dir_D</i>
Rolamento com defeito em ambas as pistas e estado normal	<i>Dor_ir_N</i>
Rolamento com defeito em ambas as pistas e estado de alerta	<i>Dor_ir_A</i>
Rolamento com defeito em ambas as pistas e estado de perigo	<i>Dor_ir_D</i>

Fonte: Adaptada de Boumahdi *et al.* (2010)

Somado a isto, destacam-se pela simplicidade como foram projetados e pela velocidade de processamento, dispensando o uso de algoritmos de classificação mais complexos, como as redes neurais e as máquinas de suporte vetorizado.

Contudo, as árvores de decisão apresentadas negligenciam a existência de defeitos nos elementos rolantes, diferentemente de outros trabalhos. Para transpor este imbróglgio fomenta-se uma adaptação à árvore de decisão, de modo considerar as conclusões extraídas do trabalho de Garad *et al.* (2017) de que:

- a) O fator de crista calculado na direção radial para o caso de um mancal com defeito no elemento rolante é superior àquele obtido para as demais condições analisadas, e;
- b) O fator de crista e a curtose são insensíveis a defeitos exclusivos na pista externa.

Desta forma, em se tratando de mancais de rolamento analisados sob o ponto de vista de defeitos únicos, isto é, nos casos onde não há coexistência de elementos defeituosos, sempre que o fator de crista calculado superar os valores obtidos para as demais condições, sem que haja aumento da curtose, será possível atestar a ocorrência de defeito no elemento rolante.

Zhang, L. *et al.* (2016), alertam, no entanto, que devido à complexidade do movimento de rotação das esferas, a detecção de defeitos nestes componentes somente é possível quando o dano é extenso. Enquanto ténue, a amplitude de vibração à frequência característica de defeito é pequena e próxima àquela observada em mancais de rolamento novos.

Estando delineados o sistema especialista e os algoritmos de tratamento que serão utilizados para sua alimentação, resta agora discutir a metodologia empregada para a coleta dos dados experimentais, que será objeto do capítulo subsequente.

## Capítulo 3

# Configuração Experimental

Com a finalidade de validar experimentalmente os métodos de diagnóstico apresentados e o sistema especialista que será proposto, serão utilizados sinais reais de vibração de mancais de rolamento sujeitos a diferentes tipos de danos. O procedimento de coleta foi realizado na bancada de teste mostrada na Figura 3.1, sendo suas especificações e características técnicas e instrumentais dadas na Tabela 3.1.

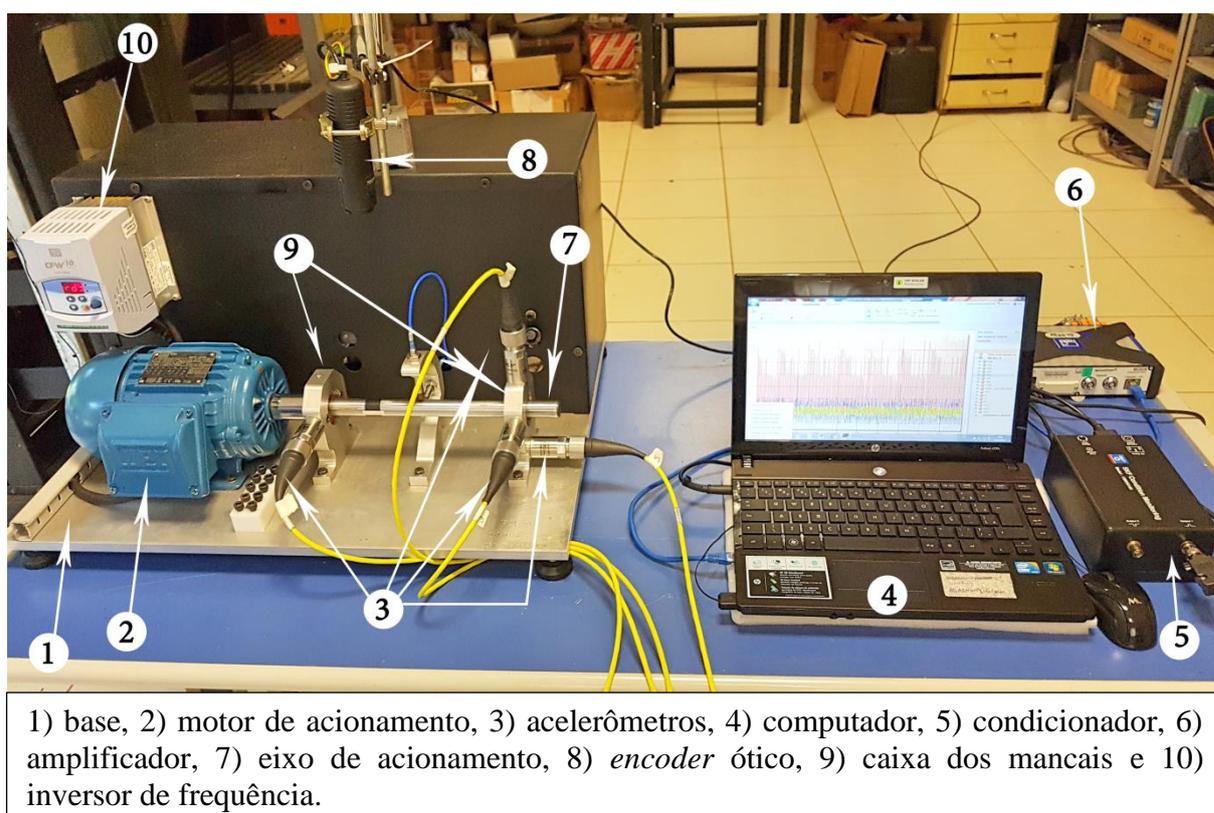


Figura 3.1: Bancada de ensaios.

Visando cercear a influência dos parâmetros de coleta sobre os sinais mensurados, serão discutidas a seguir as contribuições individuais da taxa de amostragem escolhida, da resposta

em frequência, da ressonância interna, da massa e da forma de fixação dos acelerômetros utilizados.

Tabela 3.1: Especificações e características técnicas dos componentes da bancada.

<b>Equipamento</b>	<b>Especificações</b>
Motor de acionamento	Marca: Weg W22 – TFVE Rotação nominal: 2985 rpm (49,75 Hz) Número de polos: 2 Frame: 90S Potência: 1,0 kW
Caixa do mancal de rolamento	Tipo: <i>Pillow block</i> Material: alumínio
Eixo de acionamento	Material: AISI 304 Diâmetro: Ø 20 mm Comprimento: 500 mm
Inversor de frequência	Marca: Weg CFW10 Potência: 1,5 kW
Encoder ótico e condicionador	Marca: SKF
Computador	Marca: HP 4320S
Amplificador	Marca: HBM Quantum X Número de canais: 16 Suporte: transdutores piezoelétricos IEPE e ICP Taxa de amostragem: 19200 Hz
Acelerômetro	Marca: SKF 793L Tipo: piezoelétrico ICP (amplificação interna) Sensibilidade: 500 mV/g $\pm$ 5% (24 °C) Faixa de aceleração: 10 g-pico Resposta de frequência: 5%: 0,6-700 Hz; 10%: 0,4-1000 Hz; 3 dB: 0,2-2300 Hz Frequência de ressonância: 15 kHz Fixação: parafuso roscado Massa: 142 g Quantidade: 4 unidades

Como a máxima frequência observável com os acelerômetros utilizados é de 2300 Hz, a taxa de amostragem deve ser de, no mínimo, 4600 Hz, segundo o teorema de Nyquist. Logo, conclui-se que taxa escolhida, de 19200 Hz, muito superior à mínima recomendada, é suficiente para a minimização dos erros de *aliasing*.

Apesar disso, deve-se destacar que a faixa utilizável da curva de resposta em frequência dos acelerômetros empregados, mostrada na Figura 3.2, situa-se entre 0,4 e 1000 Hz, considerando um desvio máximo de 10% e fixação por parafuso roscado. Consequentemente, o erro introduzido no sinal para além destes limites inviabiliza a análise precisa das amplitudes de vibração. Devido a este fato, os espectros apresentados neste trabalho, como aqueles das Figuras 3.3 a 3.6, estarão limitados à frequência máxima de 1000 Hz, atitude que, na prática, é análoga à aplicação de um filtro ideal.

Os indicadores estatísticos, por sua vez, também levarão em conta esta limitação instrumental e, por este motivo, seus cálculos estarão precedidos de uma etapa filtragem. Para fins de padronização, utilizar-se-á um filtro *butterworth* ideal passa-baixa de quarta ordem, cuja resposta em frequência é mostrada na Figura 3.7.

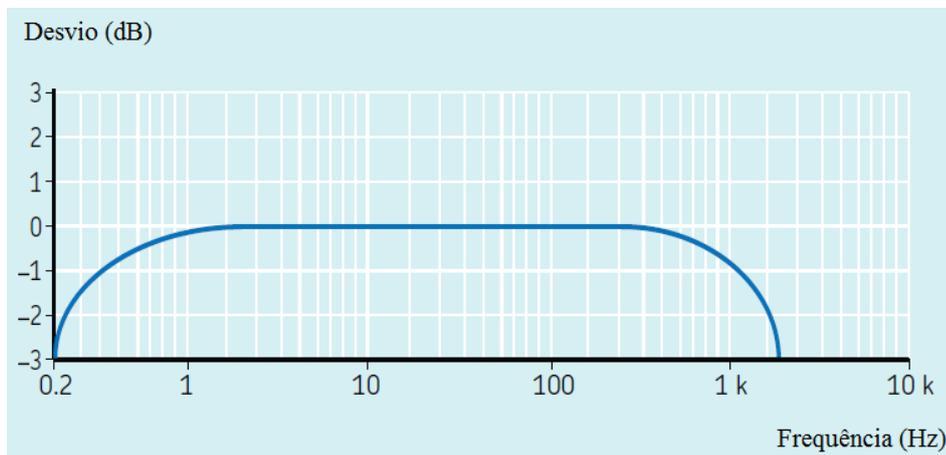


Figura 3.2: Resposta em frequência típica dos acelerômetros para fixação por parafuso.

Fonte: Adaptada de Skf (2018).

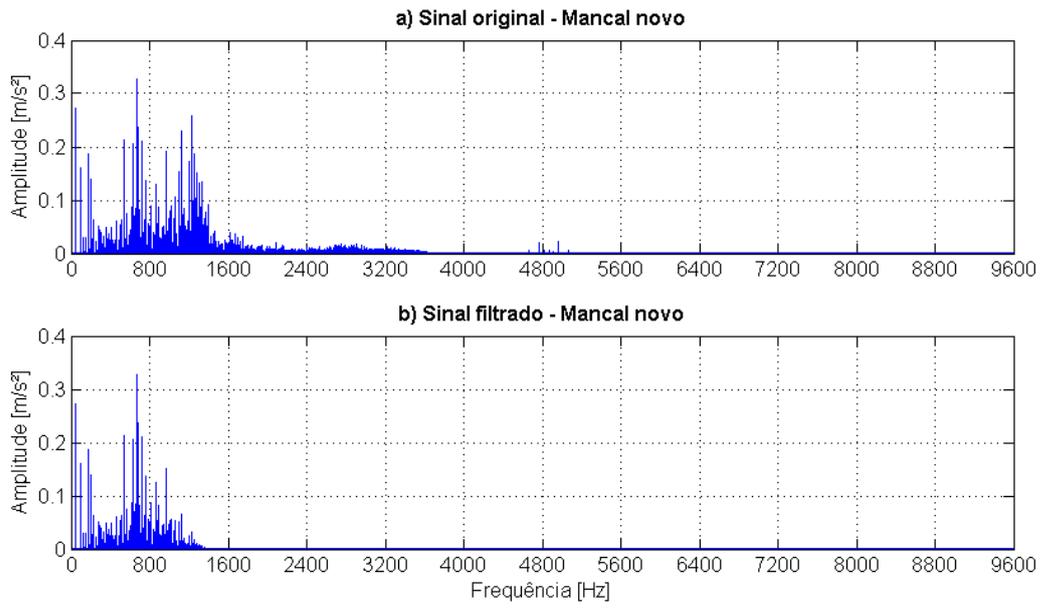


Figura 3.3: Espectros para mancal novo: a) sinal original e b) filtrado.

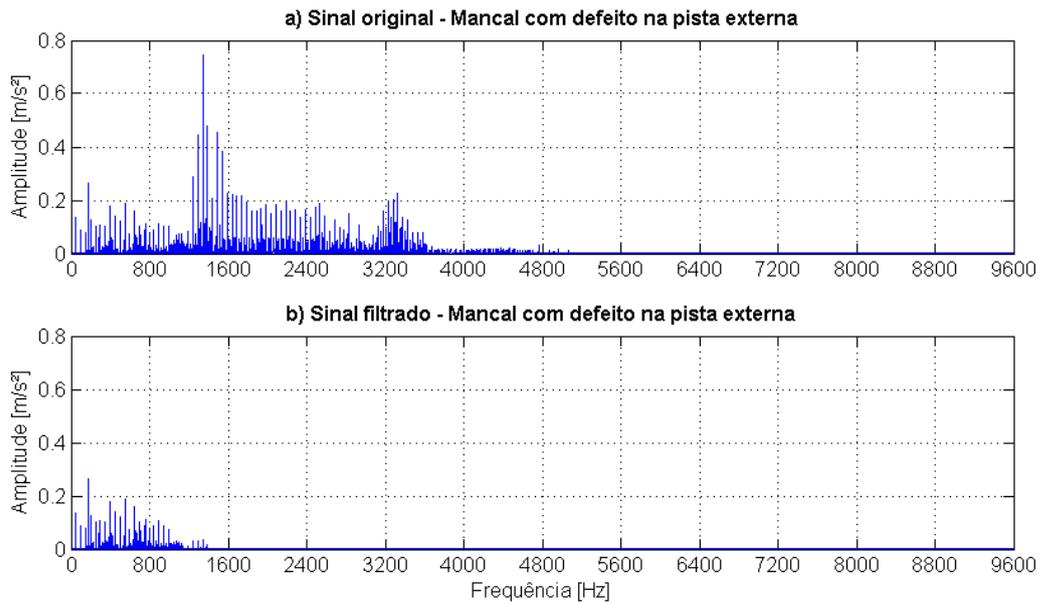


Figura 3.4: Espectros para defeito na pista externa: a) sinal original e b) filtrado.

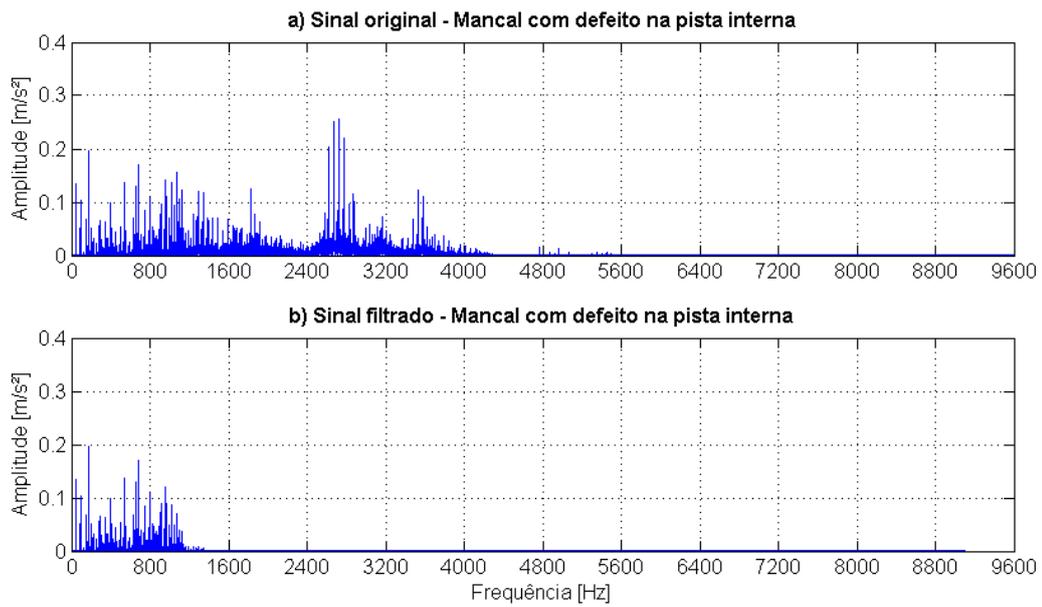


Figura 3.5: Espectros para defeito na pista interna: a) sinal original e b) filtrado.

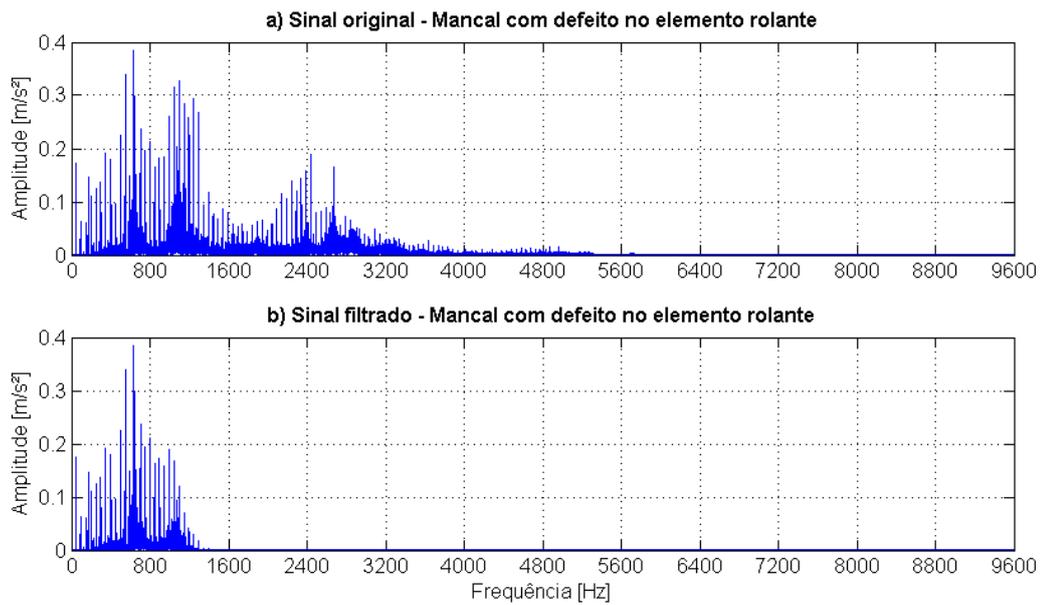


Figura 3.6: Comparação entre espectros defeito na esfera: a) sinal original e b) filtrado.

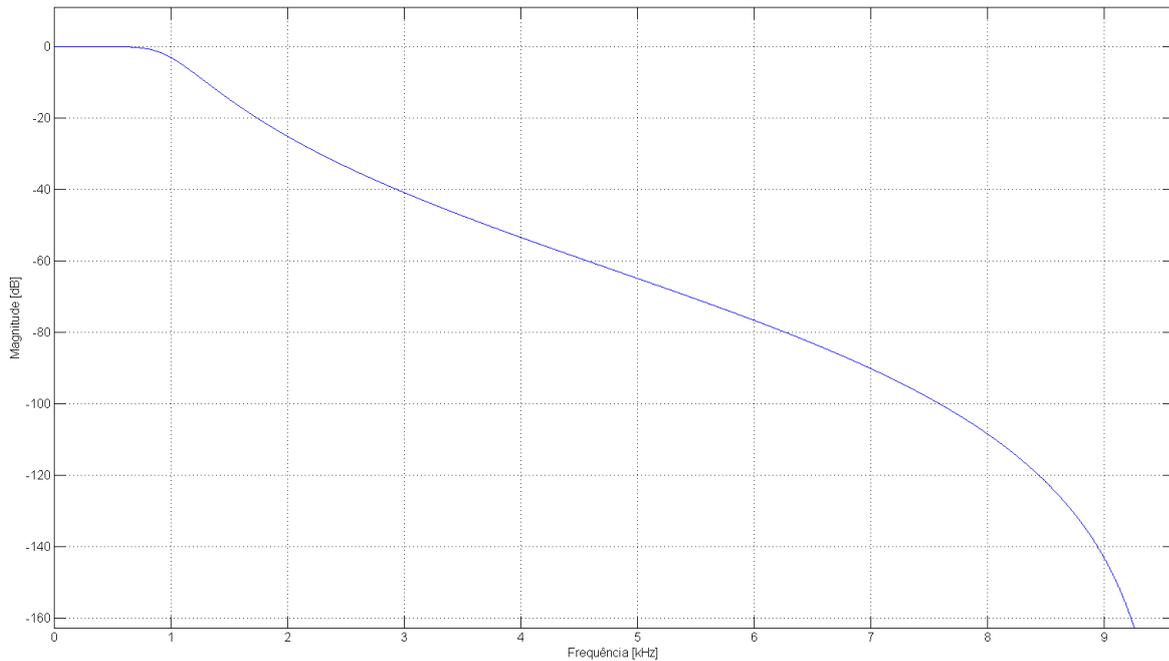


Figura 3.7: Resposta em frequência do filtro *butterworth* padronizado.

Como a frequência de ressonância dos acelerômetros situa-se na faixa de corte do sinal, a amplificação interna causada por este fenômeno pode ser desprezada.

Da mesma forma, podem ser negligenciados os desvios resultantes da sua forma de fixação, pois em um arranjo parafusado a sensibilidade relativa é de 0 dB entre 0 e 1000 Hz, como demonstra a Figura 3.8.

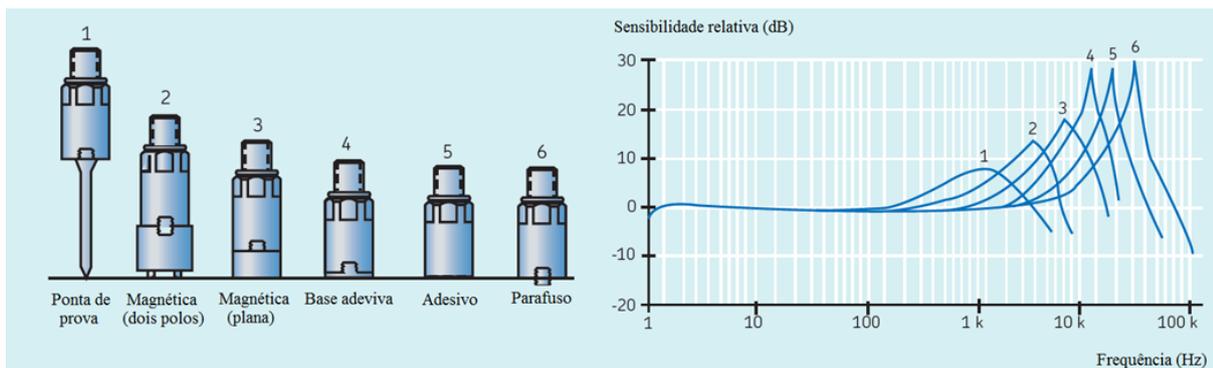


Figura 3.8: Faixa de frequências de acordo com a forma de montagem.

Fonte: Adaptada de Skf (2018).

Para verificar a influência da massa dos acelerômetros sobre os modos naturais dos mancais foi realizado um ensaio de impactação das caixas de montagem com o auxílio de um martelo modal Kistler modelo 9726A acoplado a uma ponteira de impacto de plástico duro modelo TIP-9914 capaz de excitar frequências, segundo a Figura 3.9, de até 700 Hz. Os sinais

discretos de excitação nas direções horizontal e vertical, bem como suas respectivas respostas em frequência, são apresentados na Figura 3.10 para as condições antes e após a montagem dos acelerômetros. Como visto, não houve alteração da resposta modal.

Além dos componentes citados na Tabela 3.1, foram utilizados dois mancais de rolamento modelo 6004-2RS1 (SKF) com blindagem bilateral, estando suas dimensões e dados construtivos expressos na Tabela 3.2.

A partir destes dados foram calculadas as frequências características de defeito na pista externa, na pista interna, na gaiola e nos elementos rolantes através das equações 2.1, 2.2, 2.3 e 2.4, respectivamente. Os valores particulares assumidos por estas frequências à rotação nominal do motor de acionamento são mostrados na Tabela 3.3.

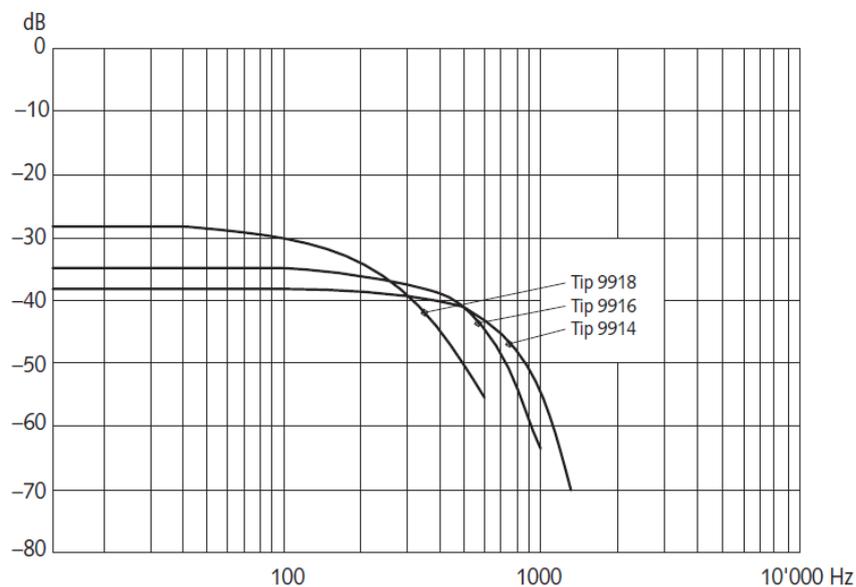


Figura 3.9: Resposta em frequência das pontas de impacto.

Fonte: Kistler (2015).

Tabela 3.2: Dimensões e características construtivas dos mancais de rolamento ensaiados.

<b>Característica construtiva</b>	<b>Dimensão</b>
Diâmetro externo ( $D_o$ )	42,00 mm
Diâmetro interno ( $D_i$ )	20,00 mm
Diâmetro do círculo de passo ( $D$ )	31,00 mm
Largura da gaiola ( $B$ )	12,00 mm
Diâmetro da esfera ( $d$ )	6,35 mm
Número de esferas	9
Ângulo de contato	0°

Fonte: SKF (disponível em <http://webtools3.skf.com/engcalc/calculator/freqcalc/bearing/index.jsp>).

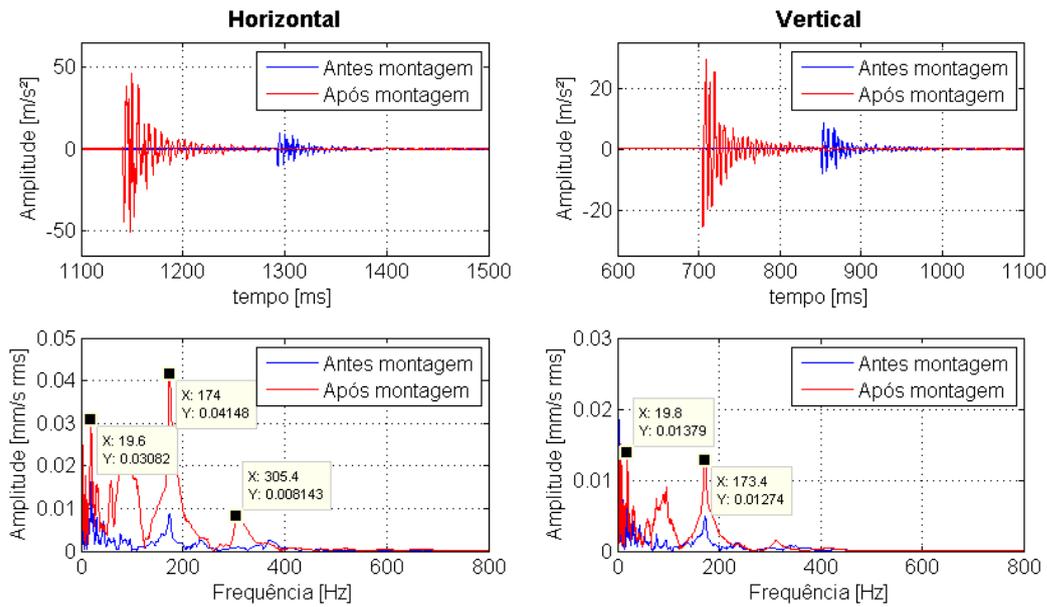


Figura 3.10: Sinais discretos da excitação e espectros nas direções horizontal e vertical.

Tabela 3.3: Valores assumidos pelas frequências características.

Frequência característica	Valor assumido (Hz)
<i>FBPI</i> (defeito na pista interna)	269,7
<i>FBPO</i> (defeito na pista externa)	178,0
$2 \times FBPI$ (harmônico de <i>FBPI</i> )	539,4
$2 \times FBPO$ (harmônico de <i>FBPO</i> )	356,0
<i>FC</i> (defeito na gaiola)	19,78
<i>FB</i> (defeito no elemento rolante)	116,3 (232,6*)

\* frequência característica de defeito no elemento rolante ( $2 \times FB$ ).

A análise dos valores apresentados na Tabela 3.3 permite concluir que a faixa de resposta linear dos acelerômetros será suficiente para visualizar, com precisão, até o terceiro harmônico da maior frequência característica de defeito. Portanto, a restrição das frequências visualizáveis não implicará em redução do potencial de acertos do sistema especialista proposto. No entanto, é evidente a proximidade das frequências características de defeito na gaiola, de 19,78 Hz, e na pista externa, de 178 Hz, dos modos naturais de 19,8 Hz e 174 Hz, vistos na Figura 3.10. Portanto, as amplitudes de vibração a estas frequências, caso detectadas, serão amplificadas por efeito da ressonância das próprias caixas de montagem.

A danificação dos mancais foi feita por meio de uma broca de ponta diamantada com diâmetro de 1 mm montada em uma mini furadeira elétrica de bancada. O dano localizado possui dimensões, aproximadas, de 1,2 mm de diâmetro e 1 mm de profundidade. Após a imposição do defeito era feita a remoção das limalhas de aço, provenientes dos componentes danificados, a replicação adequada de lubrificante e a remontagem das blindagens.

Concluídas as etapas de preparação dos mancais foi iniciado o processo de aquisição dos dados, por meio do qual foram coletadas dez amostras para cada uma das quatro condições analisadas. Um exemplo das mesmas é apresentado na Figura 3.11.

O Capítulo 4, a seguir, irá abordar a maneira como os algoritmos dos métodos selecionados para este comparativo foram traduzidos para a linguagem de programação escolhida.

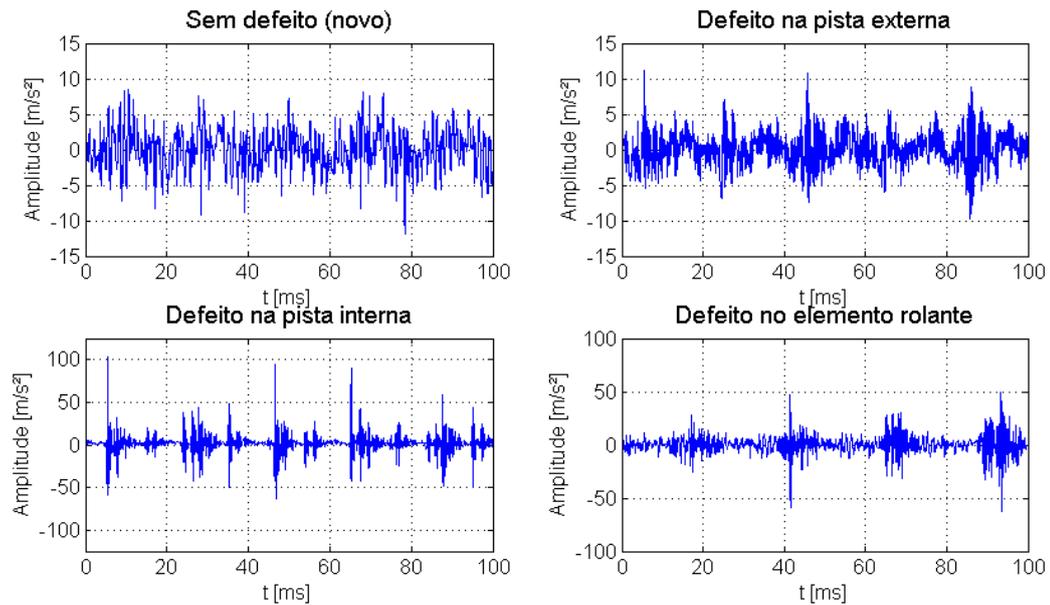


Figura 3.11: Exemplo de amostras de sinais.



# Capítulo 4

## Operacionalização dos Algoritmos

Este capítulo apresenta em detalhes a operacionalização dos algoritmos dos métodos de tratamento e do sistema especialista empregados no desenvolvimento deste trabalho.

Todavia, antes do início da interpretação dos mesmos é necessário realçar a forma como os sinais foram coletados e guardados. A captura ocorreu através de um sistema de aquisição *Quantum-X* de 16 canais, de fabricação *HBM*, a uma taxa de amostragem,  $fs$ , de 19200 Hz. Os dados foram armazenados em arquivos que correspondem a 5 s de medição, ou 96000 pontos. As rotinas foram implementadas em *MatLab* e os testes realizados em um computador tipo workstation com processador *Intel Xeon* de quatro núcleos 2.4 GHz e 16 GB de memória de acesso randômico.

### 4.1 Envelopamento tradicional

#### 4.1.1 Rastreamento de ordens

A primeira rotina executada pelo algoritmo de envelopamento tradicional, segundo Randall e Antoni (2010), é a de rastreamento de ordens, cujo conjunto de operações, apresentado no Quadro 4.1, é repetido sucessivamente até o término do sinal de vibração. A função *resample* emprega um filtro polifásico para reamostrar digitalmente o sinal e, assim, tornar o comprimento entre picos do sinal de referência constante.

O sinal de um rolamento sem defeito reamostrado digitalmente, presente na porção inferior da Figura 4.1, praticamente não sofreu distorções, quando comparado ao original, e assegurou um número exato de 386 amostras por revolução, equivalente à razão entre  $fs$  e  $fr$ . Além disso, seu início foi deslocado, de modo a coincidir com o ângulo de 0°. No entanto, as principais contribuições da técnica foram evitar o excessivo amontoamento das frequências no espectro em frequência e tornar o primeiro pico coincidente com a velocidade nominal do motor, como pode ser visto na Figura 4.2.

Quadro 4.1: Sequência executada pela rotina de rastreamento de ordens.

```

function [sinal] = rastreamento_ordens(sinal_coletado, sinal_amostragem);

[valor_picos, pos_picos] = findpeaks(sinal_amostragem(i));
for i=1:length(pos_picos)-1
    if pos_picos(i+1)-pos_picos(i) ~= fs/fr
        sinal(pos_picos(i):pos_picos(i+1)) = ...
... resample(sinal_coletado(pos_picos(i):pos_picos(i+1)), fs/fr, pos_picos(i+1)-pos_picos(i));
    end
end
end

```

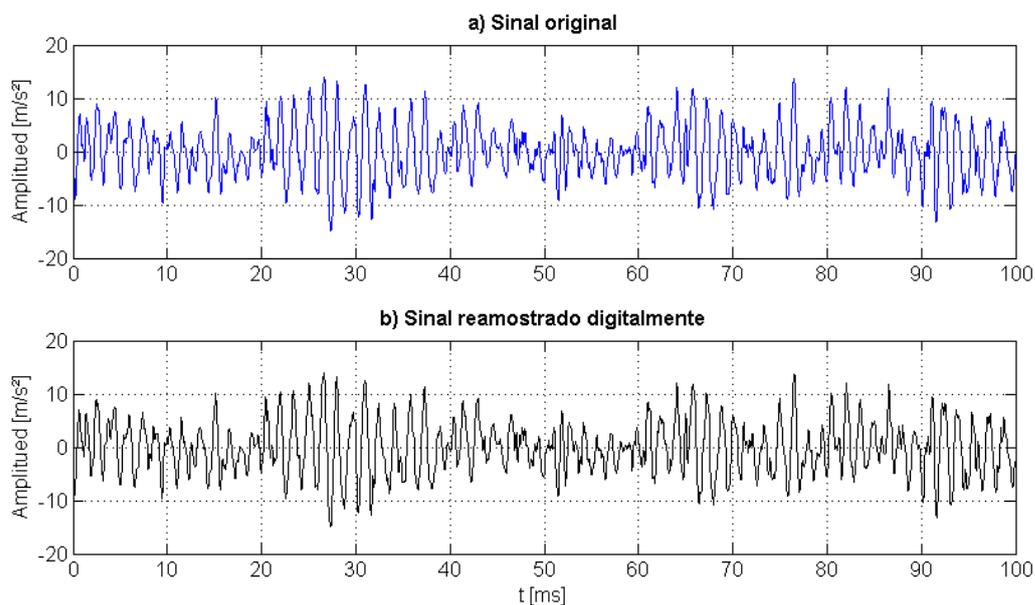


Figura 4.1: Comparação entre os sinais a) original e b) reamostrado digitalmente.

Na sequência, o algoritmo inicia a etapa de separação das componentes discretas dos sinais capturados através dos métodos estabelecidos no Capítulo 2, sendo eles a *TSA*, a *AR*, o *SANC* e a *DRS*. A técnica efetivamente escolhida será aquela que propiciar o maior incremento na curtose do sinal.

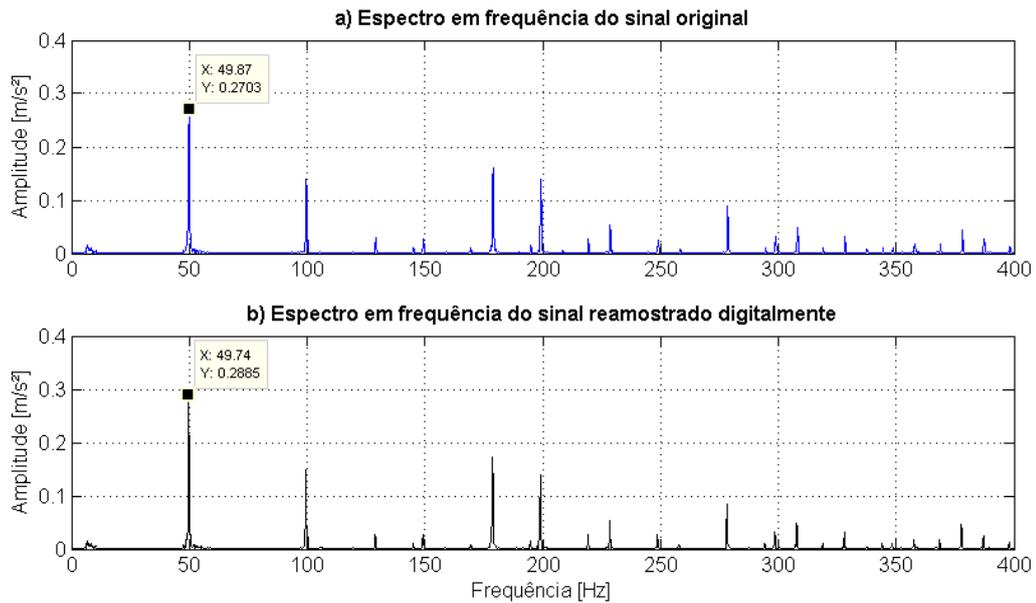


Figura 4.2: Espectros em frequência dos sinais a) original e b) reamostrado digitalmente.

#### 4.1.2 Filtragem TSA

Como os sinais avaliados neste trabalho possuem apenas uma frequência determinística e respectivos harmônicos, gerados pelo movimento de rotação do eixo, a *TSA* foi modelada no algoritmo como um filtro de picos de resposta ao impulso infinita, *IIR*, com ordem igual a  $fr/fs$  e largura da banda de filtragem igual a  $fs/fr$ , ou seja, equivalente ao inverso do valor estabelecido para seu comprimento.

Na linguagem escolhida, a rotina resume-se a:

$$TSA = iircomb(fr/fs, fs/fr, 'peak').$$

A Figura 4.3 apresenta a resposta em frequência do filtro pente resultante do método *TSA*. Já as Figuras 4.4 e 4.5 mostram os sinais no domínio do tempo e os espectros em frequência correspondentes após a aplicação do filtro, respectivamente.

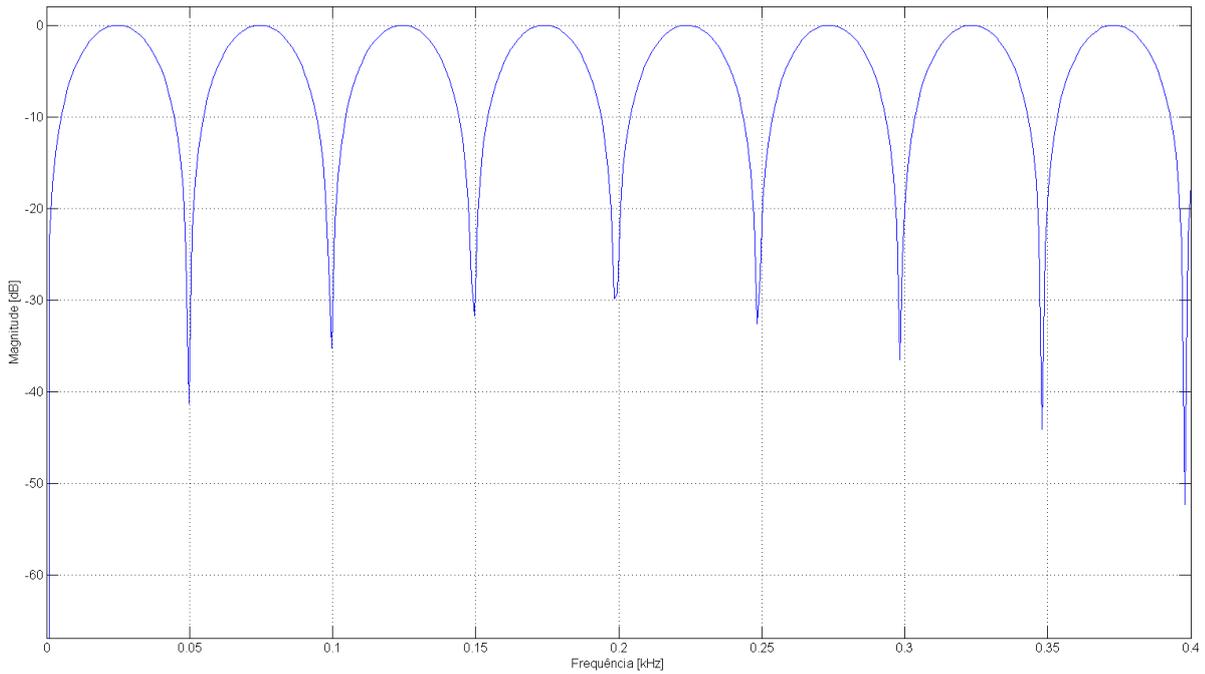


Figura 4.3: Resposta em frequência do filtro *TSA*.

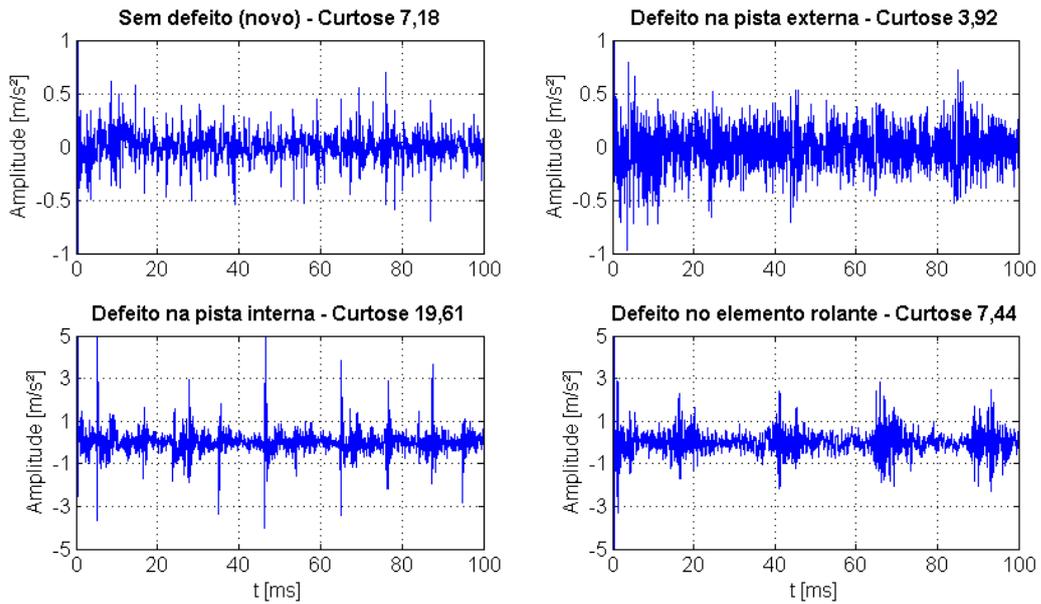


Figura 4.4: Sinais produzidos pelos mancais após filtragem *TSA*.

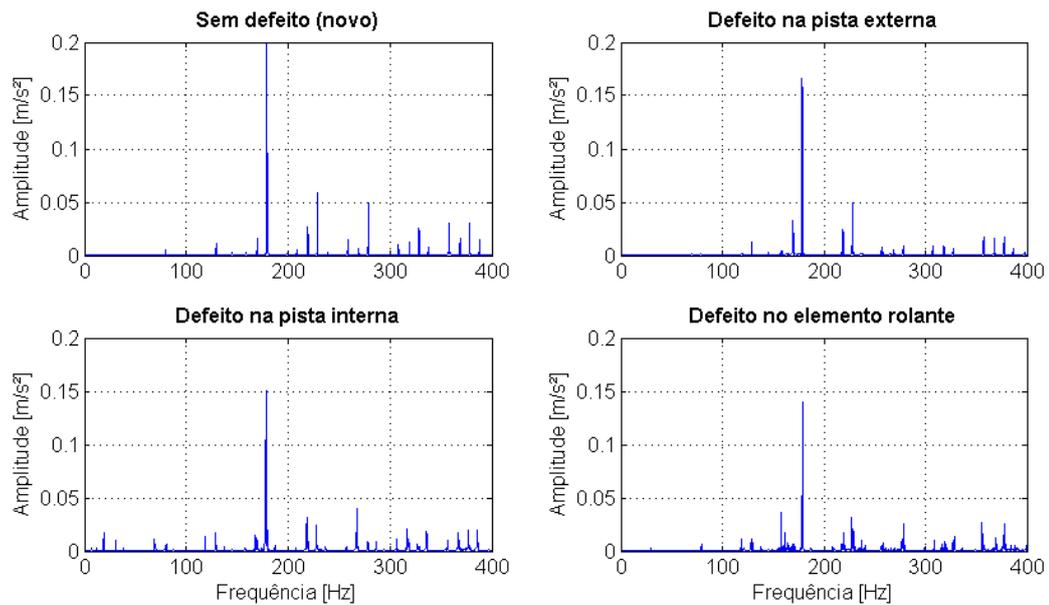


Figura 4.5: Espectros em frequência correspondentes aos sinais após filtragem *TSA*.

Como visto, a filtragem *TSA* foi capaz de remover o conteúdo determinístico do sinal, mantendo apenas as demais frequências. Deve-se observar que a curtose foi reduzida na maioria dos casos.

### 4.1.3 Filtragem AR

O próximo método a ser comparado é o da predição linear. A *AR* é, basicamente, uma maneira de se obter um modelo para a porção determinística do sinal através de certa quantidade de amostras passadas. A parte de interesse do sinal é, então, obtida pela subtração do sinal original.

O Quadro 4.2 ilustra a sequência de comandos executada no algoritmo para a determinação dos coeficientes do filtro supracitado.

Quadro 4.2: Sequência executada pela rotina *AR*.

```
function [AR] = AR(sinal_coletado);

nfiltro = 300;
AR = aryule(sinal_coletado, nfiltro);
```

No *MatLab*, a função *aryule* fornece os coeficientes de um filtro todo-polo através do método de Yule-Walker. Nele, a saída atual de um modelo *AR* de ordem  $p$  é a combinação linear da saída anterior à  $p$  somada a um ruído branco de entrada. Os coeficientes das  $p$  saídas

passadas minimizam o erro médio quadrático da predição *AR*. A escolha do tamanho do filtro, ou ordem, foi feita por meio da análise qualitativa da função de resposta em frequência do mesmo. Como o projeto do filtro depende da própria amostra do sinal, foram produzidos filtros distintos para cada uma das condições ensaiadas. As respostas em frequência dos filtros *AR* calculados pelo algoritmo são dadas nas Figuras 4.6, 4.7, 4.8 e 4.9, respectivamente para os casos de um mancal sem defeito, com defeito na pista externa, com defeito na pista interna e com defeito no elemento rolante.

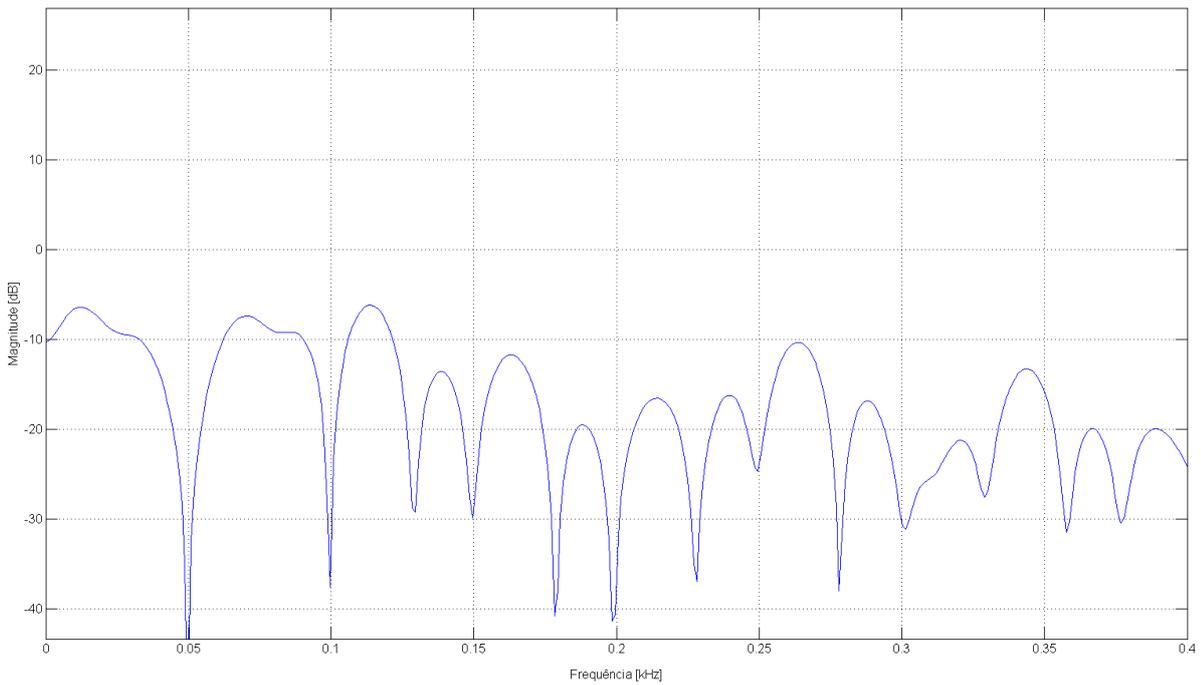


Figura 4.6: Resposta em frequência do filtro *AR* para mancal sem defeito (novo).

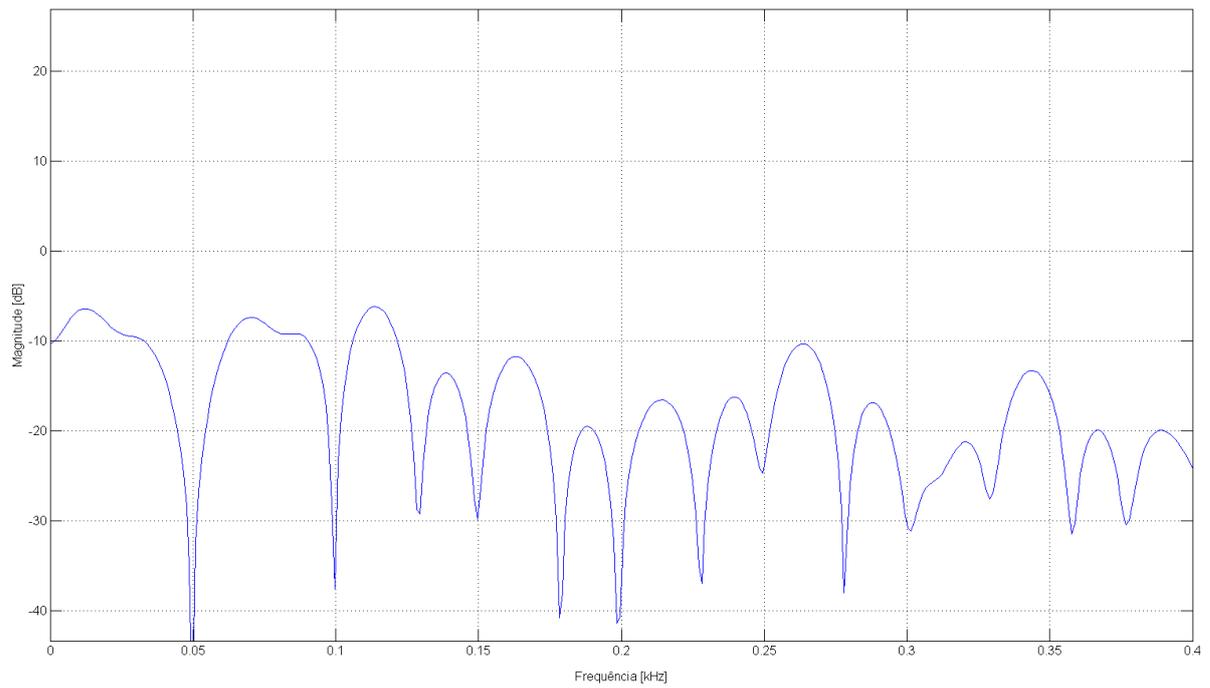


Figura 4.7: Resposta em frequência do filtro AR para mancal com defeito na pista externa.

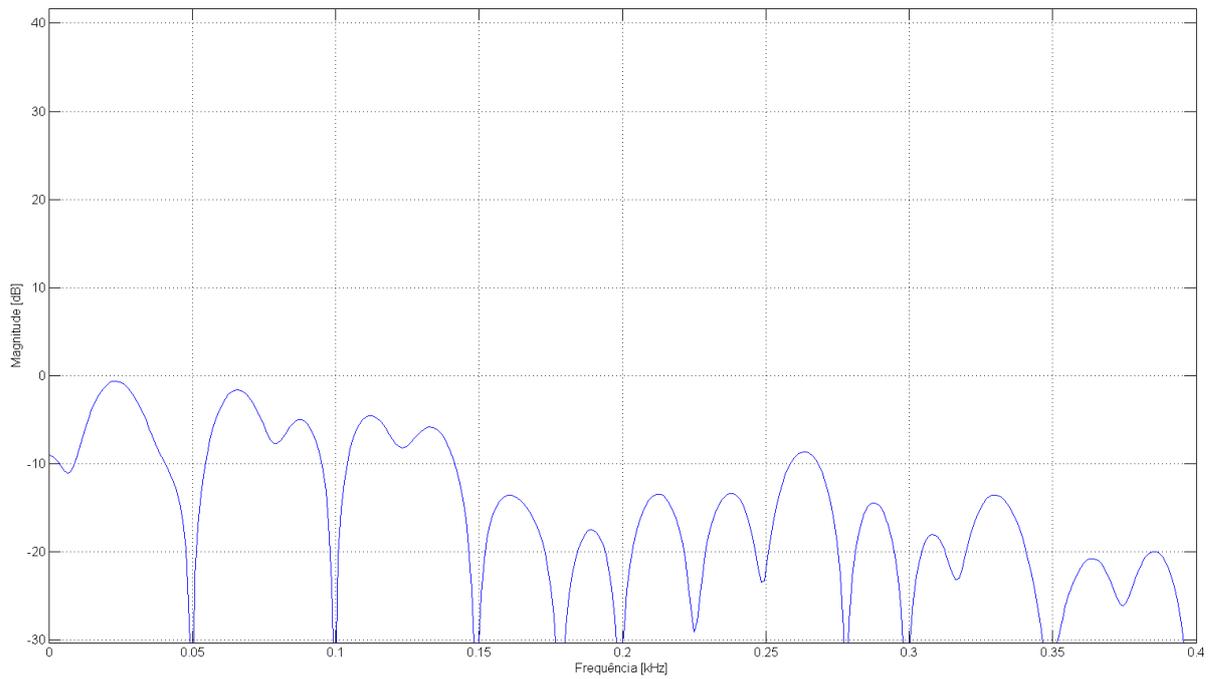


Figura 4.8: Resposta em frequência do filtro AR para mancal com defeito na pista interna.

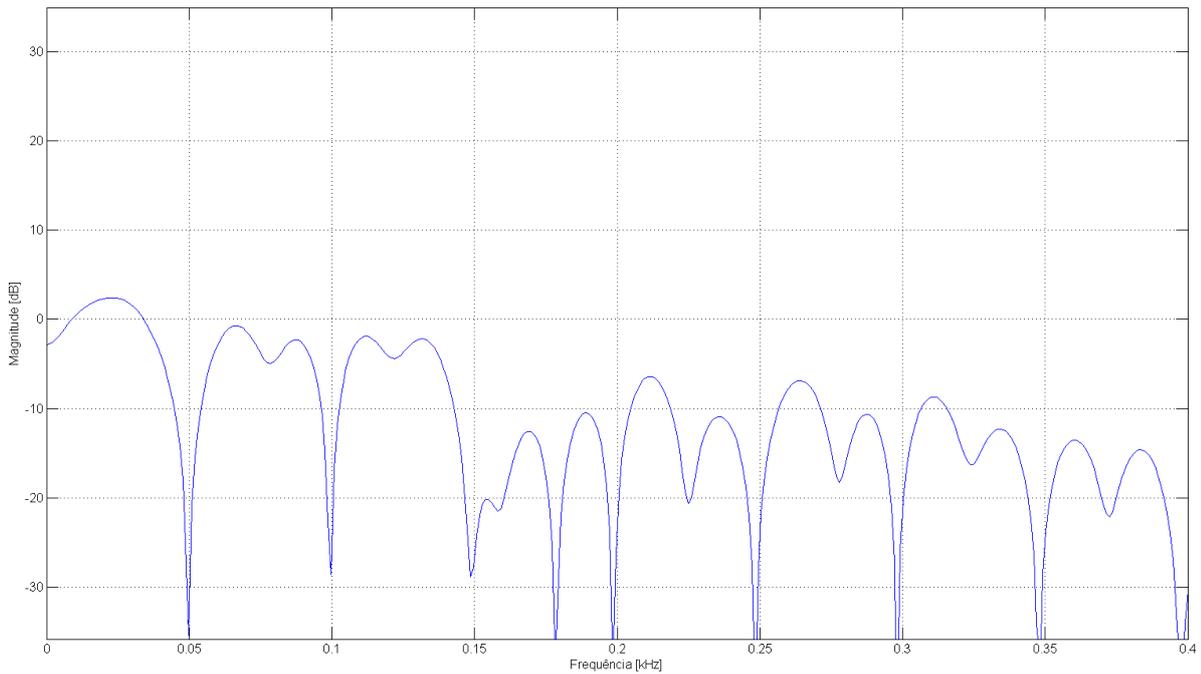


Figura 4.9: Resposta em frequência do filtro *AR* para mancal com defeito na esfera.

A Figura 4.10 traz os sinais no domínio do tempo resultantes da filtragem *AR* e os respectivos valores de curtose. Os espectros em frequência associados aos sinais são mostrados na Figura 4.11.

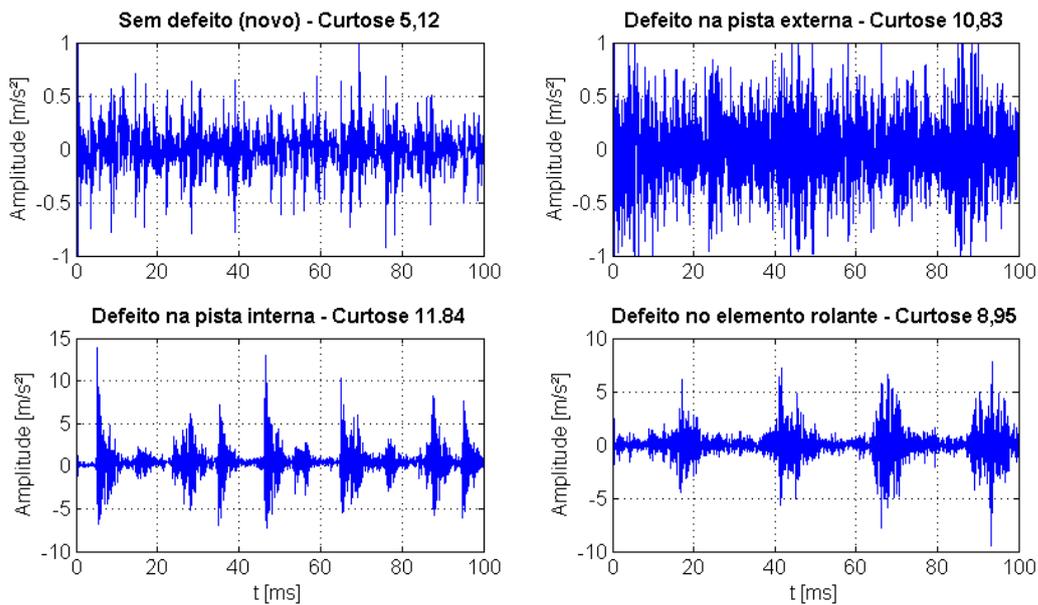


Figura 4.10: Sinais produzidos pelos mancais após filtragem *AR*.

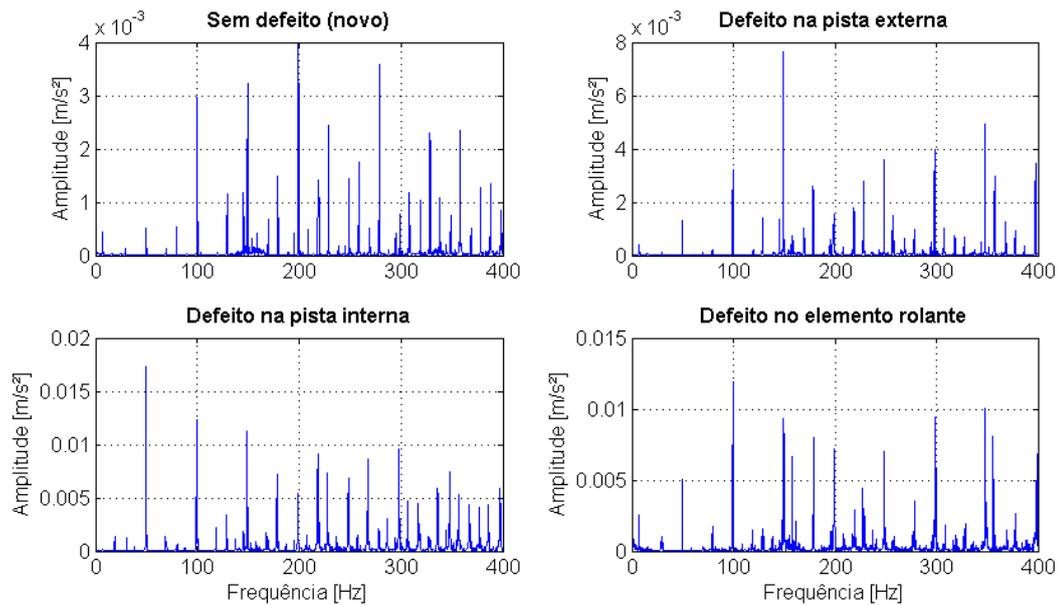


Figura 4.11: Espectros em frequência correspondentes aos sinais após filtragem AR.

A inspeção dos gráficos permite concluir que as respostas dos filtros AR dimensionados para cada uma das condições analisadas se assemelham visualmente à resposta do filtro TSA da Figura 4.3 em termos do conteúdo de frequências, no entanto, as magnitudes são significativamente menores. Houve um pequeno aumento das curtoses dos sinais dos mancais com defeito na pista externa e elemento rolante. A qualidade da remoção das componentes determinísticas foi muito inferior à TSA.

#### 4.1.4 Filtragem SANC

O método seguinte é o do filtro adaptativo SANC, cuja função é recursiva e com um número de pesos a ser determinado e atualizado a cada iteração, o que significa que pode lidar com pequenas variações do sinal ou propriedades do sistema. O processo recursivo é chamado de mínimos médios quadráticos, do inglês *Least Mean Squares (LMS)*, sendo os comandos realizados pelo algoritmo proposto resumidos no Quadro 4.3.

Quadro 4.3: Sequência executada pela rotina SANC.

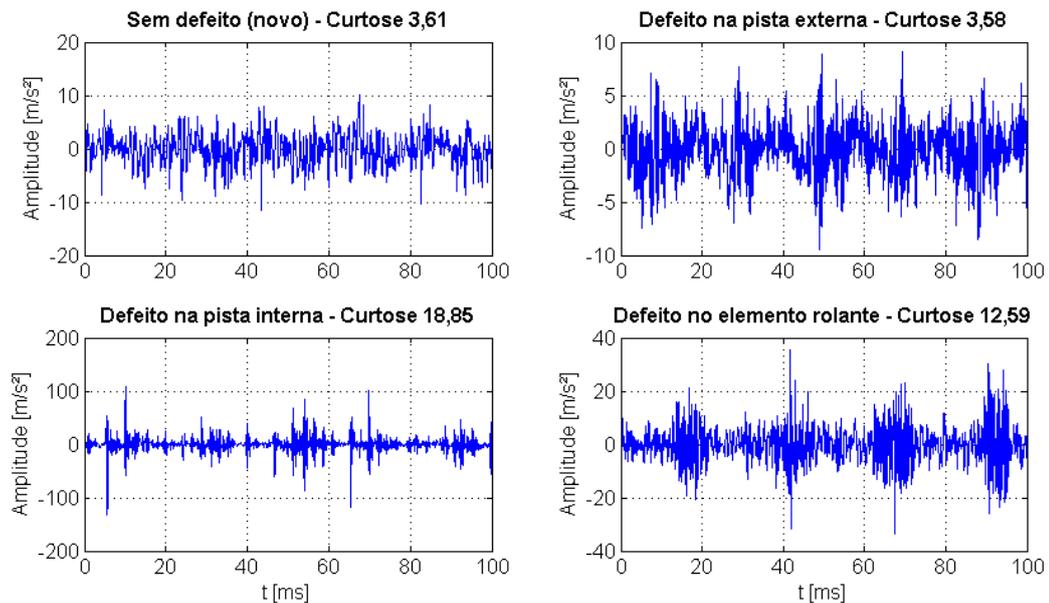
```

function [SANC] = SANC(sinal_coletado, sinal_atrasado);

nfiltro = 100;
for i=1:nfiltro
    vetor_coeficientes = 20*1/exp(i);
end
passo = 0,05;
for i=1:nfiltro
    for j=1:nfiltro
        filtro = dsp.LMSfilter(i, "Normalised LMS");
         $\mu$  = vetor_coeficientes(j);
        [saída,erro] = step(filtro, sinal_atrasado, sinal_coletado), passo,  $\mu$ );
        erro_RMS = RMS(erro);
    end
    [erro_minimo,pos_erro_minimo] = min(erro_RMS);
    comp_filtro = min(erro_minimo);
     $\mu$  = vetor_coeficientes(comp_filtro);
    SANC = dsp.LMSfilter(comp_filtro,"Normalised LMS");

```

As amplitudes dos sinais no domínio do tempo resultantes da filtragem *SANC*, apresentados na Figura 4.12, sofreram pouca redução, diferentemente das técnicas *TSA* e *AR*. Percebe-se, também, que as curtoses dos sinais no domínio do tempo obtidos são inferiores às originais. Tampouco houve atenuação das componentes determinísticas, como visto nos espectros em frequência da Figura 4.13.

Figura 4.12: Sinais produzidos pelos mancais após filtragem *SANC*.

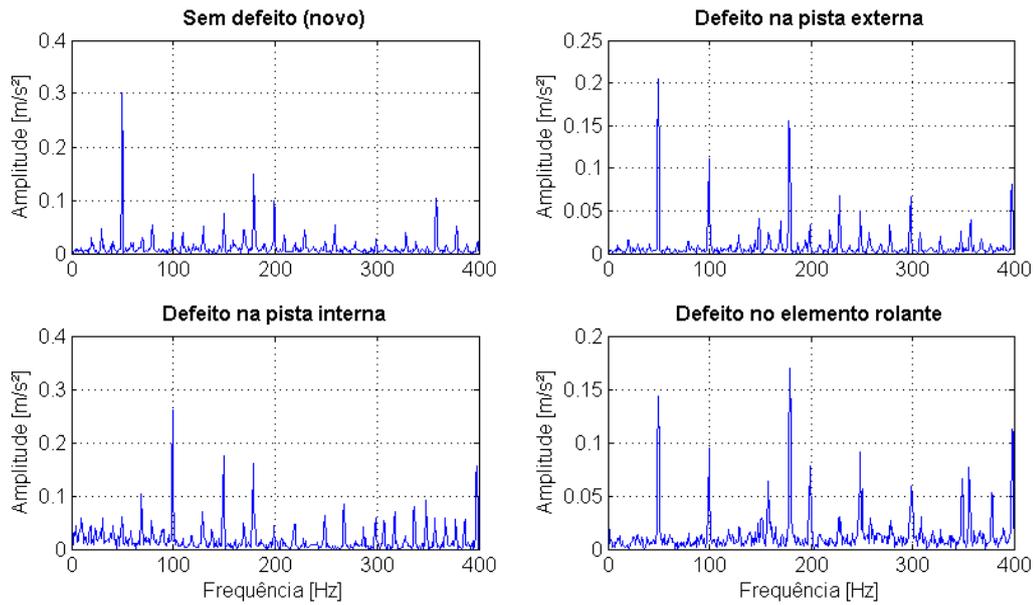


Figura 4.13: Espectros em frequência correspondentes aos sinais após filtragem SANC.

#### 4.1.5 Filtragem DRS

A última técnica de filtragem a ser testada é a de separação discreta-aleatória. Para tanto, Randall e Antoni (2010) demonstram que a equação 2.5, que fornece a função de resposta em frequência do filtro *DRS*, pode ser reorganizada para dar origem à equação 4.1.

$$H(f) = \frac{\rho N / 2 |W(f)|^2}{\rho N / 2 |W(f)|^2 + 1}, \quad (4.1)$$

onde  $\rho$  é a relação ruído-sinal,  $N$  o tamanho da transformada discreta de Fourier e  $W(f)$  a transformada de Fourier da janela utilizada, escalonada para uma amplitude máxima unitária no domínio da frequência.

O procedimento utilizado para a determinação da função de resposta em frequência (*FRF*) do filtro empregando este método é apresentado no Quadro 4.4.

No *MatLab* a função *SNR* calcula a relação ruído-sinal, dada como a razão entre os somatórios quadráticos das magnitudes de um sinal real coletado a uma taxa de amostragem  $f_s$  e um ruído  $y$  de mesmo comprimento, excluindo-se as potências associadas à frequência fundamental,  $f_r$ , e os  $n$ -ésimos harmônicos.

Quadro 4.4: Sequência executada pela rotina DRS.

```
function [DRS] = DRS(sinal_coletado, fr, fs, nharmonicos);

njanela = 2^nextpow2(15*fr);
janela = hann(njanela);
rho = SNR(sinal_coletado,fs,nharmonicos);
Wf = (abs(fft(sinal_coletado.*janela))/(njanela/2)).^2;
DRS = ifft(rho*njanela/2*Wf/(rho*njanela/2*Wf +1));
```

Quando não se conhece o ruído, como neste caso, a função *SNR* o determina através de um periodograma modificado de mesmo comprimento que o sinal coletado.

As respostas em frequência dos filtros calculados através do procedimento exposto são mostradas nas Figuras 4.14, 4.15, 4.16 e 4.17, respectivamente, para os casos de um mancal sem defeito (novo), com defeito na pista externa, com defeito na pista interna e com defeito no elemento rolante.

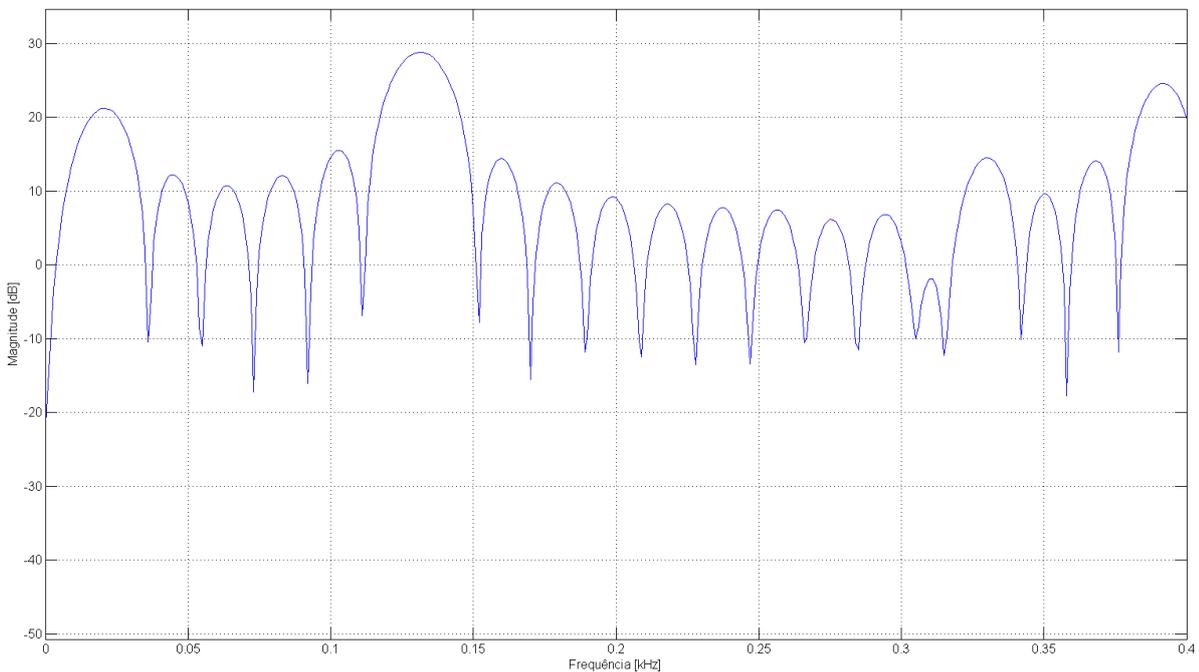


Figura 4.14: Resposta em frequência do filtro *DRS* para mancal sem defeito (novo).

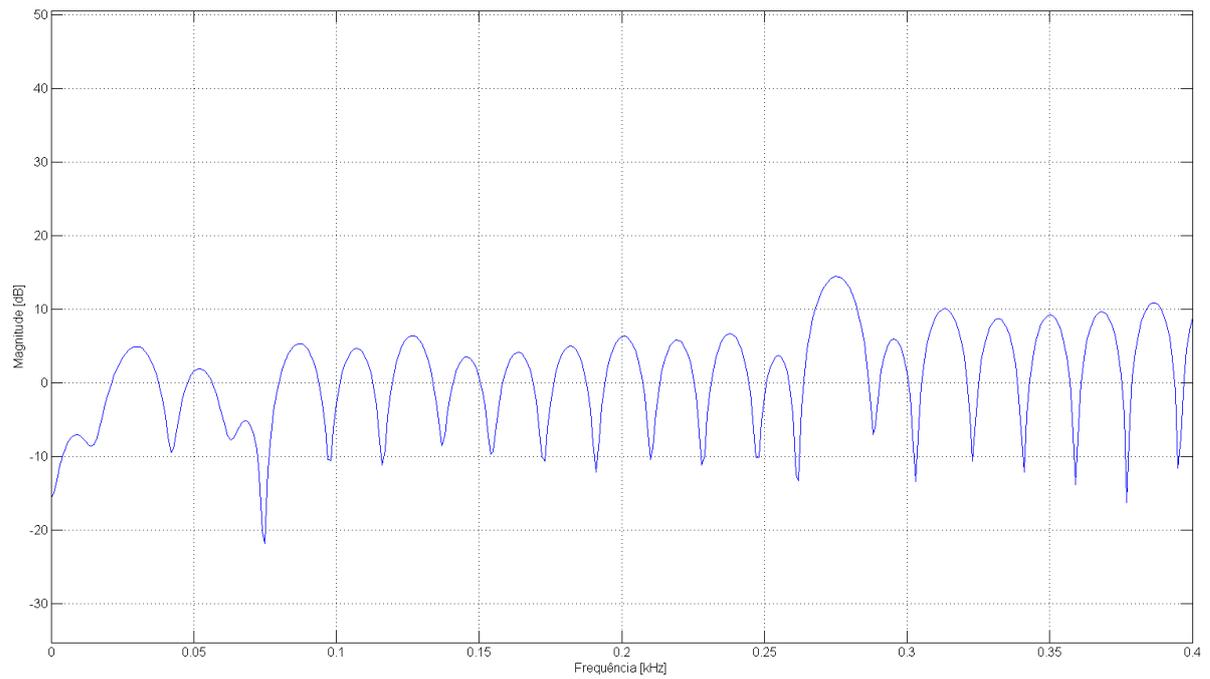


Figura 4.15: Resposta em frequência do filtro *DRS* (mancal com defeito na pista externa).

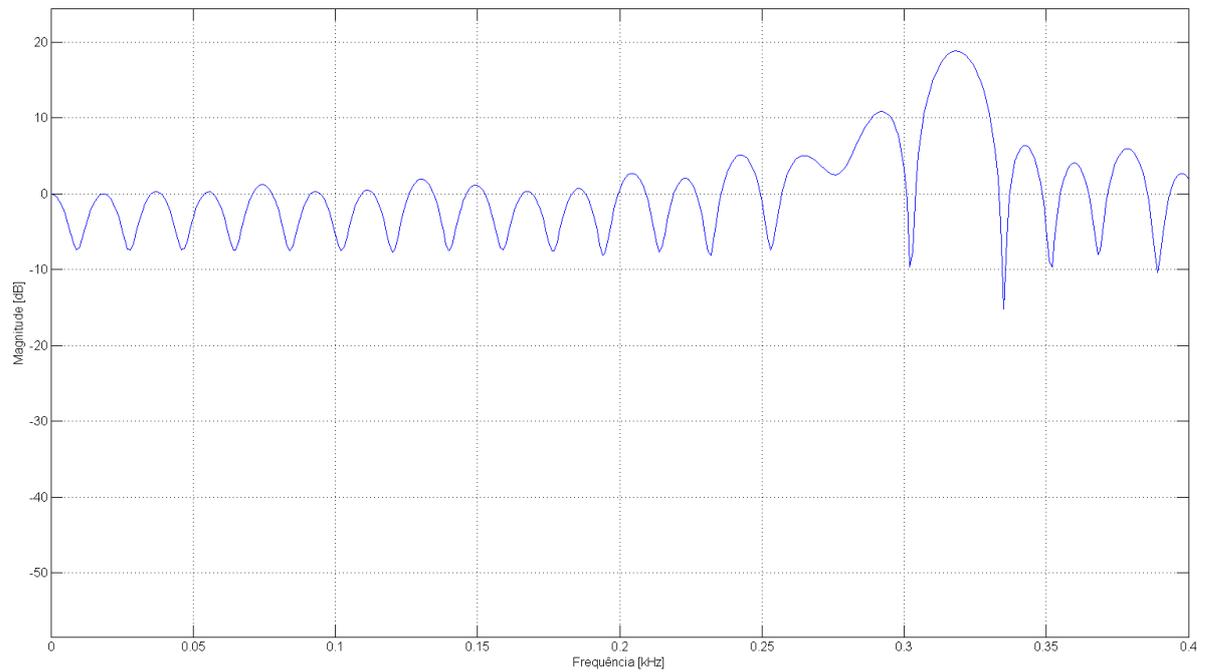


Figura 4.16: Resposta em frequência do filtro *DRS* (mancal com defeito na pista interna).

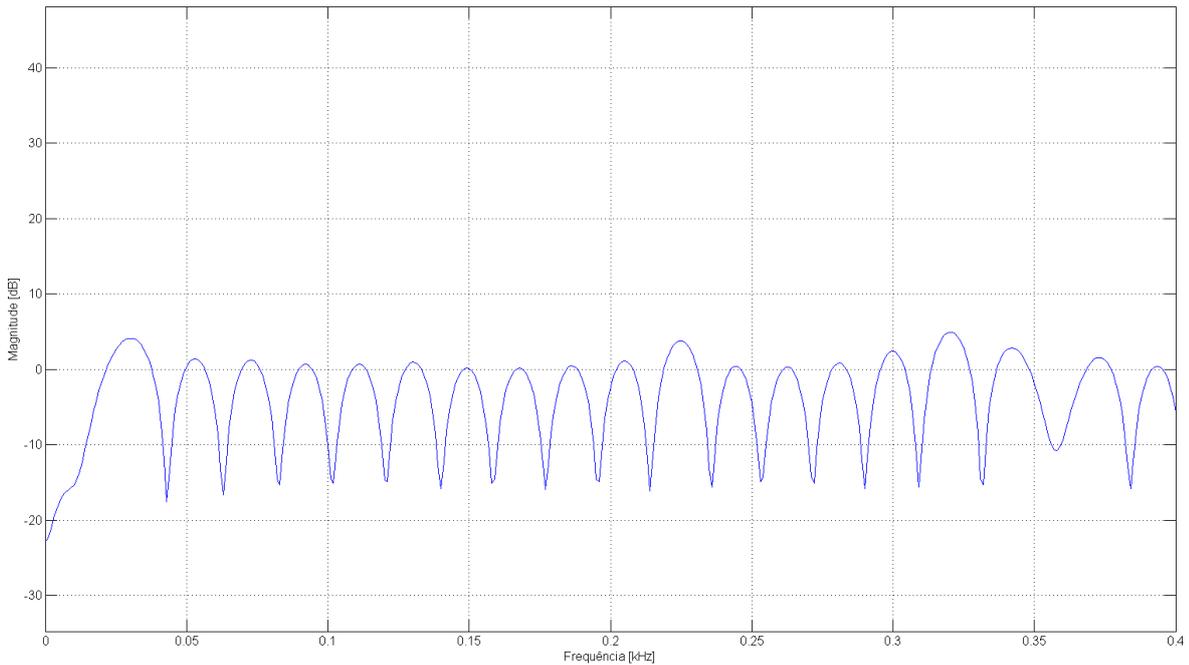


Figura 4.17: Resposta em frequência do filtro *DRS* (mancal com defeito na esfera).

Os sinais no domínio do tempo obtidos por meio da filtragem *DRS* são apresentados na Figura 4.18. Como visto, não houve amplificação da curtose dos mesmos.

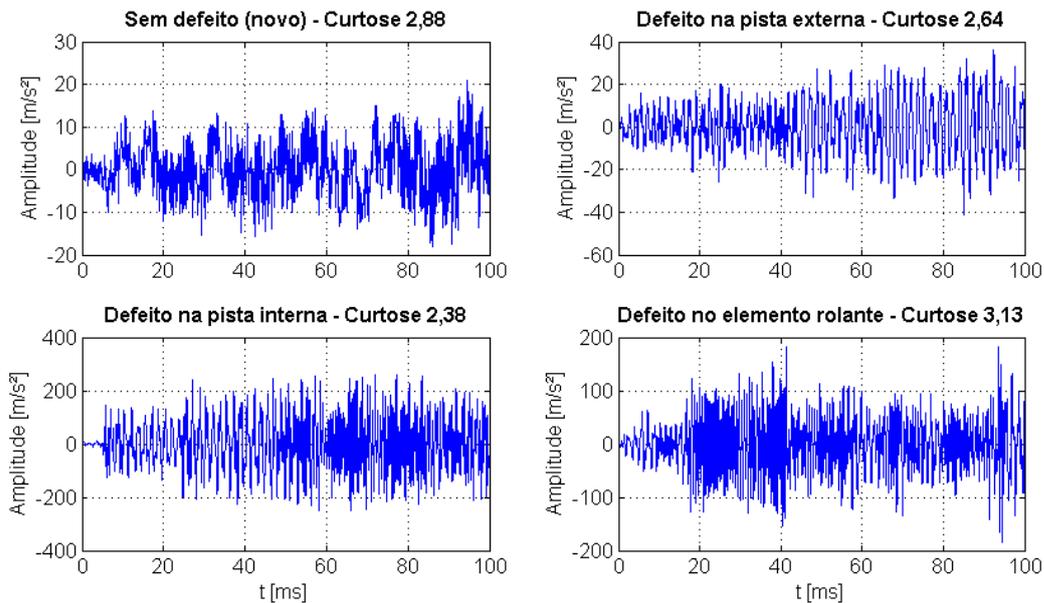


Figura 4.18: Sinais produzidos por meio da filtragem *DRS*.

Apesar das amplitudes ligeiramente superiores, os espectros em frequência obtidos por meio da *DRS*, vistos na Figura 4.19, são semelhantes àqueles obtidos através da técnica *SANC*.

No entanto, deve-se destacar que o tempo necessário ao processamento *SANC* é imensamente maior que o dedicado à *DRS*, tornando esta segunda uma substituta ideal.

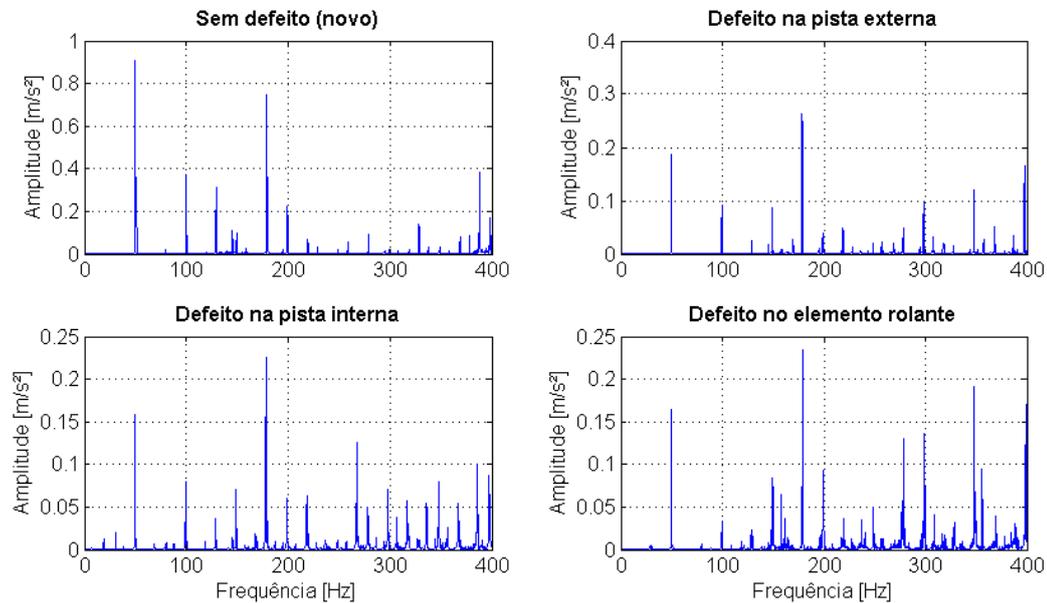


Figura 4.19: Espectros em frequência correspondentes aos sinais após filtragem *DRS*.

#### 4.1.6 Comparação dos resultados das filtrações

Como citado anteriormente, a escolha da técnica de filtragem leva em consideração tanto a capacidade de remoção das componentes determinísticas do sinal quanto a amplificação da curtose. Por este motivo foi elaborada a Tabela 4.1, que contempla os valores de curtose obtidos para cada situação, em amostra única e sem a aplicação do rastreamento de ordens, e uma análise qualitativa da limpeza das componentes determinísticas.

Através da análise da Tabela 4.1 é possível concluir que as técnicas *AR* e *SANC* forneceram as maiores curtoses em apenas uma das quatro condições ensaiadas, cada, além disso, apresentaram fraco desempenho em termos de remoção das componentes determinísticas. A técnica *TSA*, por sua vez, forneceu as maiores curtoses em duas das condições ensaiadas, além disso, ofereceu a melhor limpeza do sinal. O método *DRS* obteve os piores resultados, contrariando as expectativas. Apesar do emprego dos parâmetros citados em Randall e Antoni (2010), acredita-se que a deficiência do método decorre do tamanho arbitrado para a janela.

Tabela 4.1: Comparação entre os parâmetros dos filtros.

Tipo de defeito	Curtose obtida pela filtragem [ - ]				
	Sem filtragem	<i>TSA</i>	<i>AR</i>	<i>SANC</i>	<i>DRS</i>
Sem defeito (novo)	3,43	7,18	5,12	3,61	2,88
Defeito na pista externa	3,96	3,92	10,83	3,58	2,64
Defeito na pista interna	20,46	19,61	11,84	18,85	2,38
Defeito no elemento rolante	10,85	7,44	8,95	12,69	3,13
Remoção determinística	-	Boa	Fraca	Fraca	Fraca
Tempo de processamento	-	Baixo	Elevado	Elevado	Baixo

Como a *TSA* mostrou-se superior aos demais, quando comparadas a qualidade da limpeza, a curtose do sinal obtido e o tempo de processamento, este método será empregado para o tratamento de todos os sinais coletados.

#### 4.1.7 Amplificação dos sinais filtrados

O Capítulo 2 destacou que a perda de energia dos choques originados na fonte pelo efeito dissipativo do caminho de transmissão deve ser compensada por um filtro que, uma vez deconvolucionado do sinal de referência, seja capaz de amplificar a curtose do sinal resultante.

Por este motivo, a rotina adotada no algoritmo proposto utiliza a deconvolução de Wiener juntamente com um filtro passa-banda de resposta ao impulso finita, *FIR* (*Finite Impulse Response*), para a maximização da curtose do sinal. Por convenção, a banda de frequências filtradas encontra-se entre 500 e 2500 Hz, sendo o comprimento do filtro variado linearmente.

Os comandos utilizados são apresentados no Quadro 4.5, sendo a saída da rotina um filtro cujos coeficientes deverão ser deconvolucionados do sinal original para amplificação de sua curtose.

Quadro 4.5: Sequência executada pela rotina MED.

```
function [MED] = MED(sinal_coletado);

nfiltro = 64;
for i=2:nfiltro
    filtro = fir1(i,[500 2500], 'bandpass');
    sinal_referencia = edgetaper(sinal_coletado, filtro);
    sinal_teste = deconvwnr(sinal_referencia, filtro);
    curtose(i) = kurtosis(sinal_teste);
end
[max_curtose, nideal] = max(curtose);
MED = fir1(nideal,[500 2500], 'bandpass');
```

Os sinais amplificados por meio da técnica *MED* são apresentados nas Figuras 4.20 a 4.23.

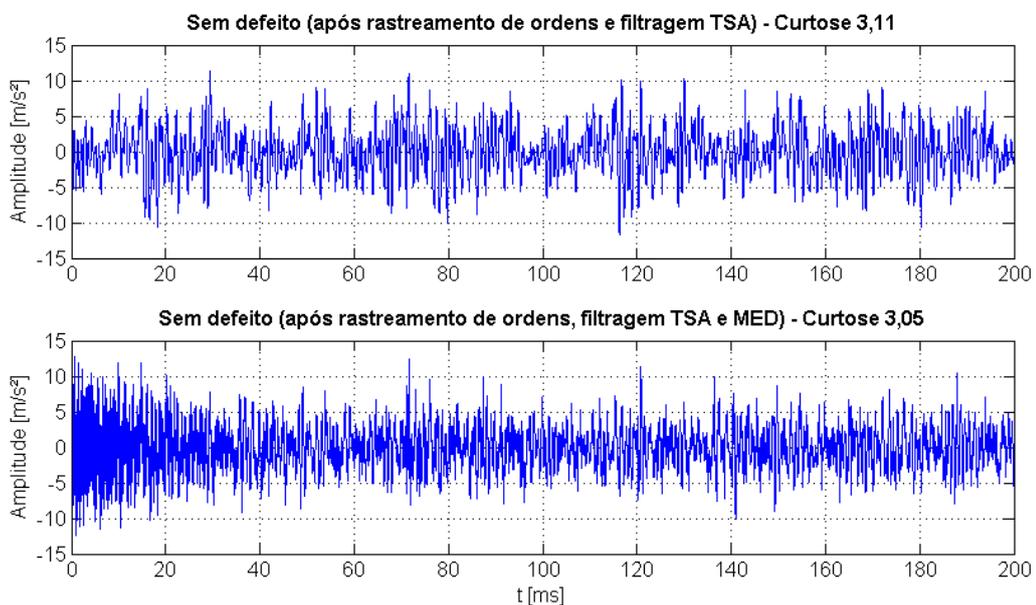


Figura 4.20: Sinais antes e após *MED* (mancal sem defeito).

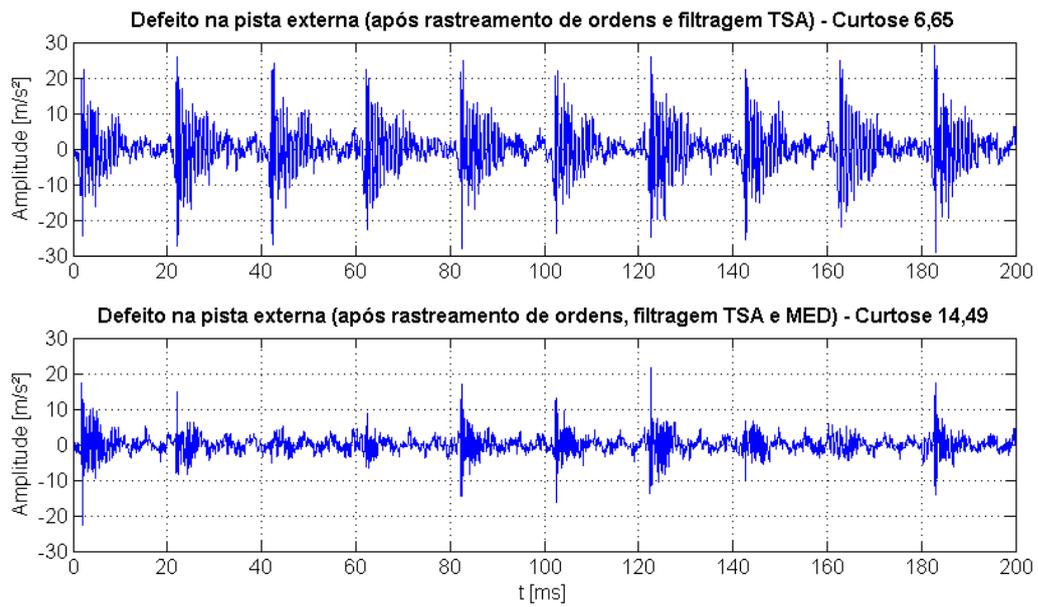


Figura 4.21: Sinais antes e após *MED* (mancal com defeito na pista externa).

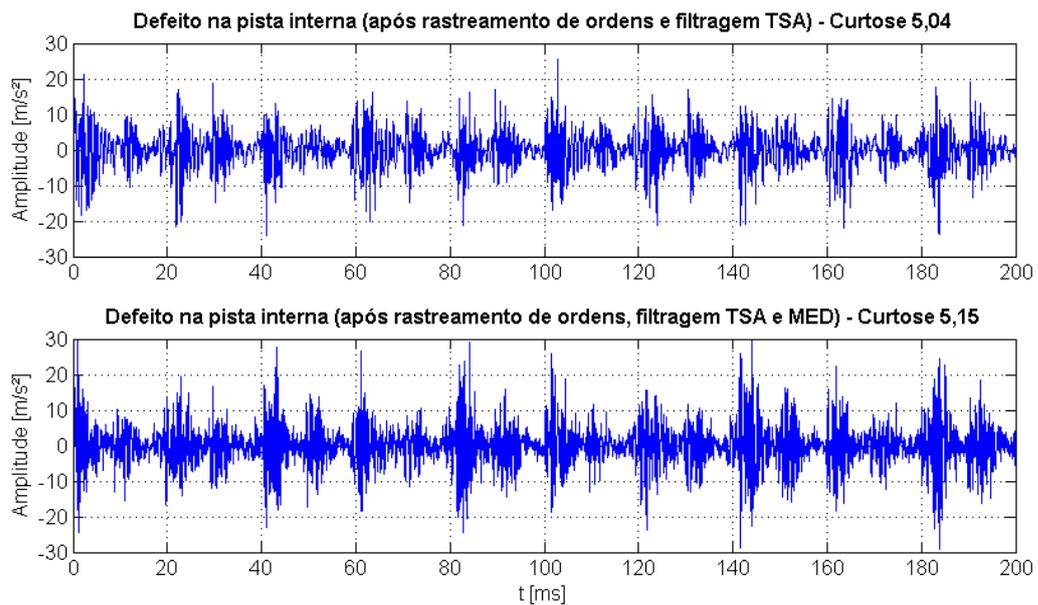


Figura 4.22: Sinais antes e após *MED* (mancal com defeito na pista interna).

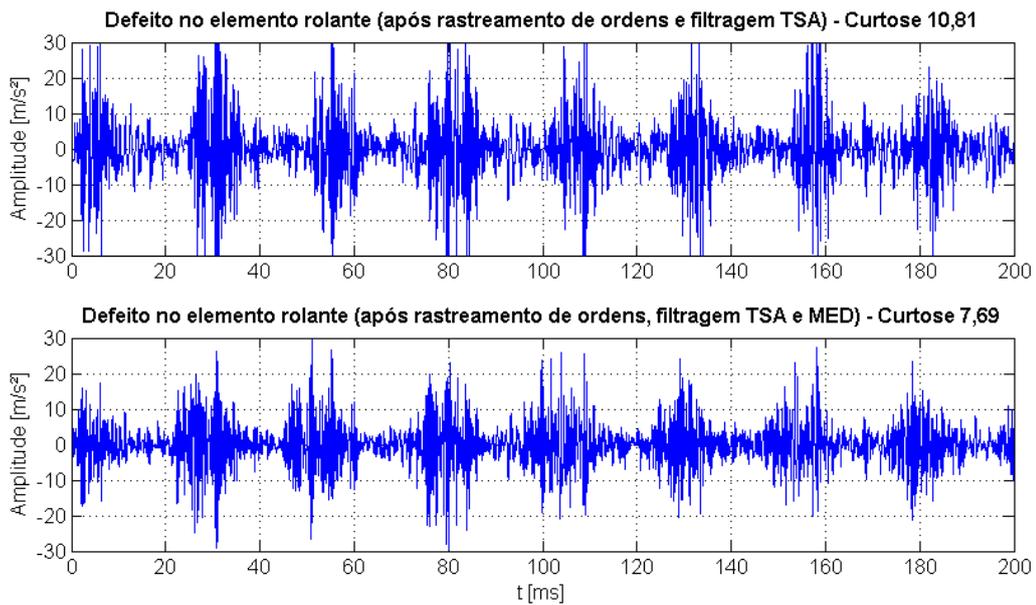


Figura 4.23: Sinais antes e após *MED* (mancal com defeito na esfera).

A análise dos gráficos evidencia a amplificação dos picos, destacando-os dos pontos adjacentes, contudo, a curtose dos sinais somente foi elevada nos casos dos mancais com defeitos nas pistas interna e externa. Segundo Randall e Antoni (2010), a técnica de entropia mínima de deconvolução somente deve ser utilizada em casos de rolamentos de alta velocidade, onde as respostas ao impulso da banda filtrada possuem comprimentos comparáveis aos espaçamentos existentes entre os pulsos causados pelos defeitos. No caso em questão, o incremento na curtose foi mais sutil justamente pela baixa velocidade de rotação do eixo do equipamento. Por este motivo não será empregada nas análises deste trabalho.

#### 4.1.8 Seleção da banda de demodulação

Uma vez findada a etapa de condicionamento do sinal, é necessário selecionar a banda de frequências de maior impulsividade a ser demodulada. A determinação das faixas de passagem e rejeição do filtro, assim como sua ordem, é feita com o auxílio do curtograma, cujas operações necessárias à criação são mostradas no Quadro 4.6.

Quadro 4.6: Sequência executada pela rotina SK.

```

function [SK] = SK(sinal_coletado);

njanela = 8;
vetor_janelas = [2:1:njanela];
vetor_janelas = 2.^vetor_janelas;
for i=1:njanela
    linhas = ceil(length(sinal_coletado)/vetor_janelas(i));
    for j=1:linhas
        matriz_sinal(j,:) = sinal_TSA((j-1)*vetor_janelas(i):j*vetor_janelas(i));
    end
    janela = hann(vetor_janelas(i));
    for k=1:linhas
        matriz_sinal(k,:) = matriz_sinal(k,:).*janela';
        matriz_fft(k,:) = (abs(fft(matriz_sinal(k,:))))/vetor_janelas(i);
    end
    SK(i,:) = mean(matriz_fft(i,:)).^4/(mean(matriz_fft(i,:)).^2)^2 - 2;
end

```

A saída da função *SK* é um curtograma, representado por uma matriz de curtoses do sinal em função da frequência e do tamanho da janela utilizada,  $N$ , como os vistos nas Figuras 4.24, 4.25, 4.26 e 4.27 para os sinais coletados em um mancal sem defeito (novo), com defeito na pista externa, com defeito na pista interna e no elemento rolante, respectivamente. Não foi empregada, para tanto, a amplificação dos sinais por meio da técnica *MED*.

A fim de evitar os erros de *aliasing*, os curtogramas foram limitados à frequência máxima de 9600 Hz, equivalentes à metade da taxa de amostragem adotada.

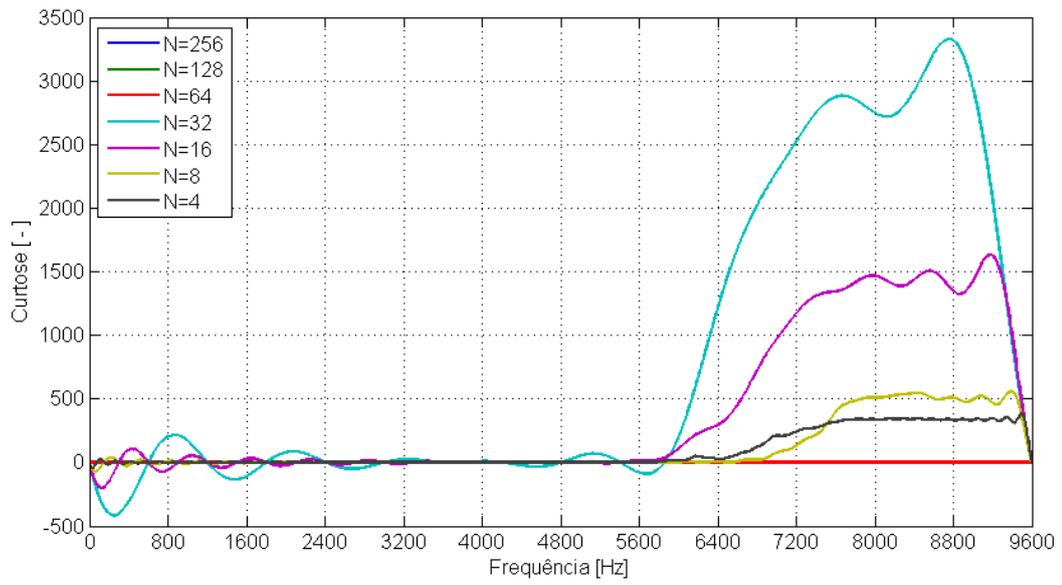


Figura 4.24: Curtograma do sinal de um mancal sem defeito (novo).

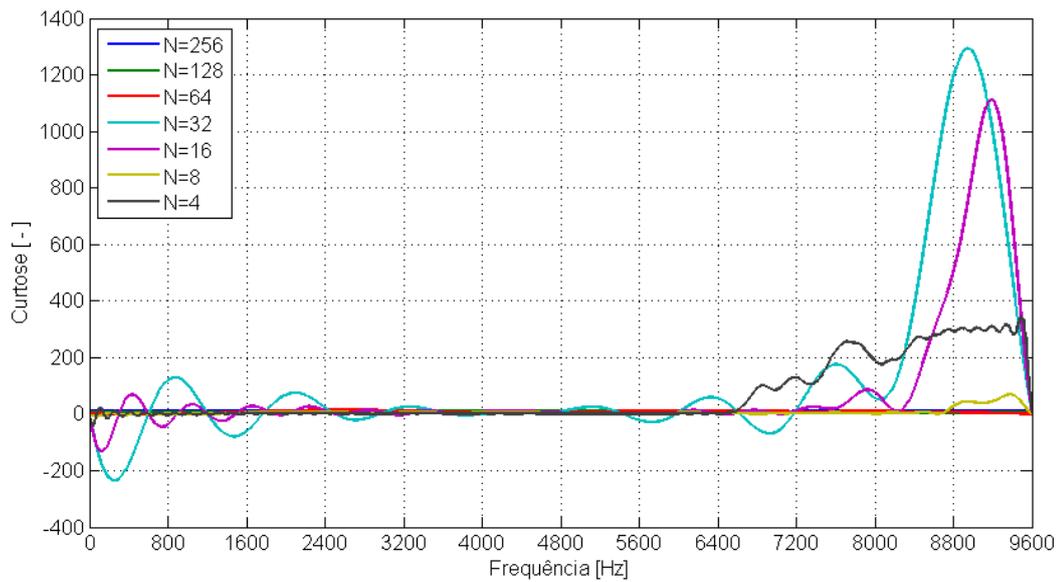


Figura 4.25: Curtograma de um mancal com defeito na pista externa.

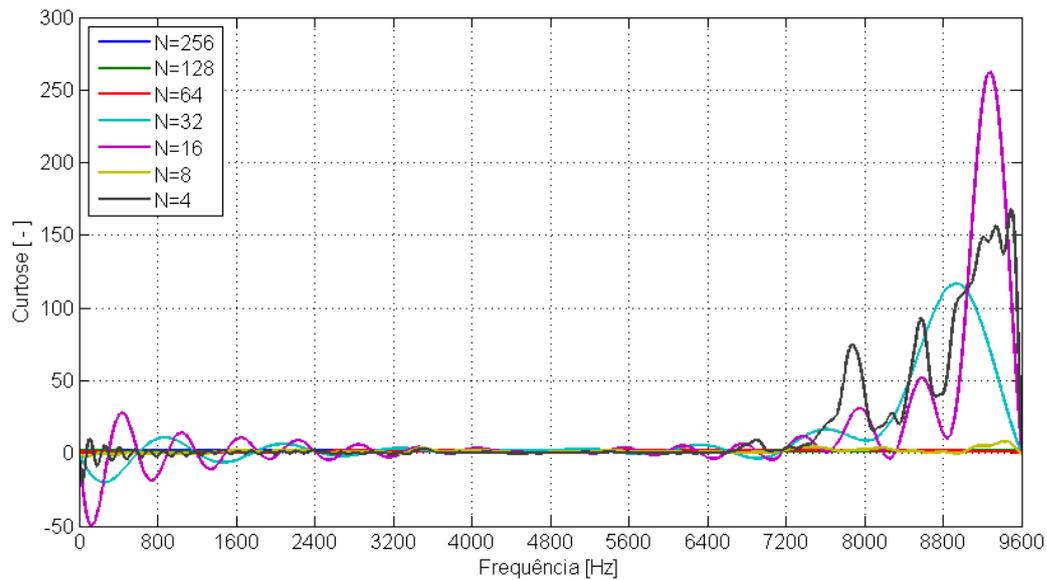


Figura 4.26: Curtograma de um mancal com defeito na pista interna.

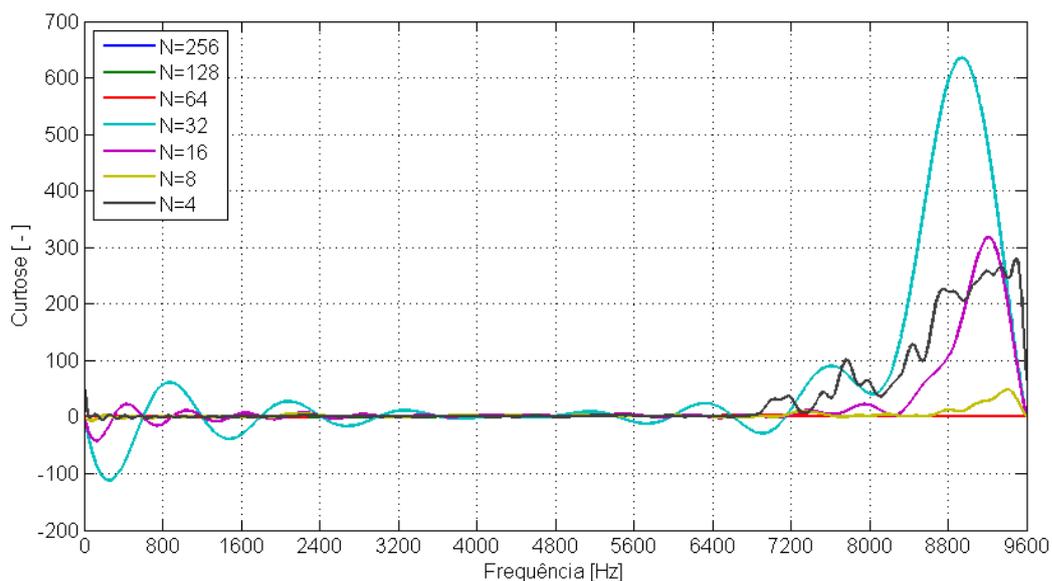


Figura 4.27: Curtograma de um mancal com defeito no elemento rolante.

Os gráficos ilustram como a escolha do tamanho da janela influencia os resultados da curtose espectral. Para os casos analisados, as janelas com tamanhos de 16 e 32 amostras produziram respostas mais aceitáveis. Aquelas com comprimentos de 4 e 8 amostras causaram suavização excessiva das curvas, enquanto as superiores a 64 amostras reduziram consideravelmente o valor da curtose espectral, muito provavelmente pelo fato do comprimento da janela ser superior ao comprimento dos picos.

Em grande parte das situações o maior pico de curtose espectral ocorre próximo à frequência de 8900 Hz para uma janela de 32 amostras. Desta forma, projeta-se o filtro passa-

banda cujas características são listadas na Tabela 4.2. A resposta em frequência do mesmo é mostrada na Figura 4.28 e os sinais no domínio do tempo resultantes nas Figuras 4.29, 4.30, 4.31 e 4.32.

Tabela 4.2: Características do filtro projetado através dos curtogramas.

Ordem	32
Primeira banda de rejeição	8300 Hz
Primeira banda de passagem	8450 Hz
Segunda banda de passagem	9150 Hz
Segunda banda de rejeição	9300 Hz
Frequência de amostragem	19200 Hz
Tipo	<i>FIR LMS</i> todo polo
Peso da primeira banda de rejeição	1
Peso da banda de passagem	4
Peso da segunda banda de rejeição	1

Deve-se ressaltar que os sinais apresentados, obtidos após a eliminação de suas componentes determinísticas e da determinação da banda de frequências de maior impulsividade, guardam poucas semelhanças com os originais. Como correspondem apenas às fontes de maior potencial energético do sinal, assim demonstrado pelos curtogramas, é possível atribuí-los aos defeitos existentes nos mancais de rolamento.

Estando concluídas as etapas de rastreamento de ordens, de separação das componentes determinísticas e de seleção da banda de maior impulsividade, faz-se a construção do sinal analítico por meio da transformada de Hilbert. Dela obtém-se um sinal complexo cuja parte real corresponde ao próprio sinal, enquanto a parte imaginária corresponde à transformada propriamente dita.

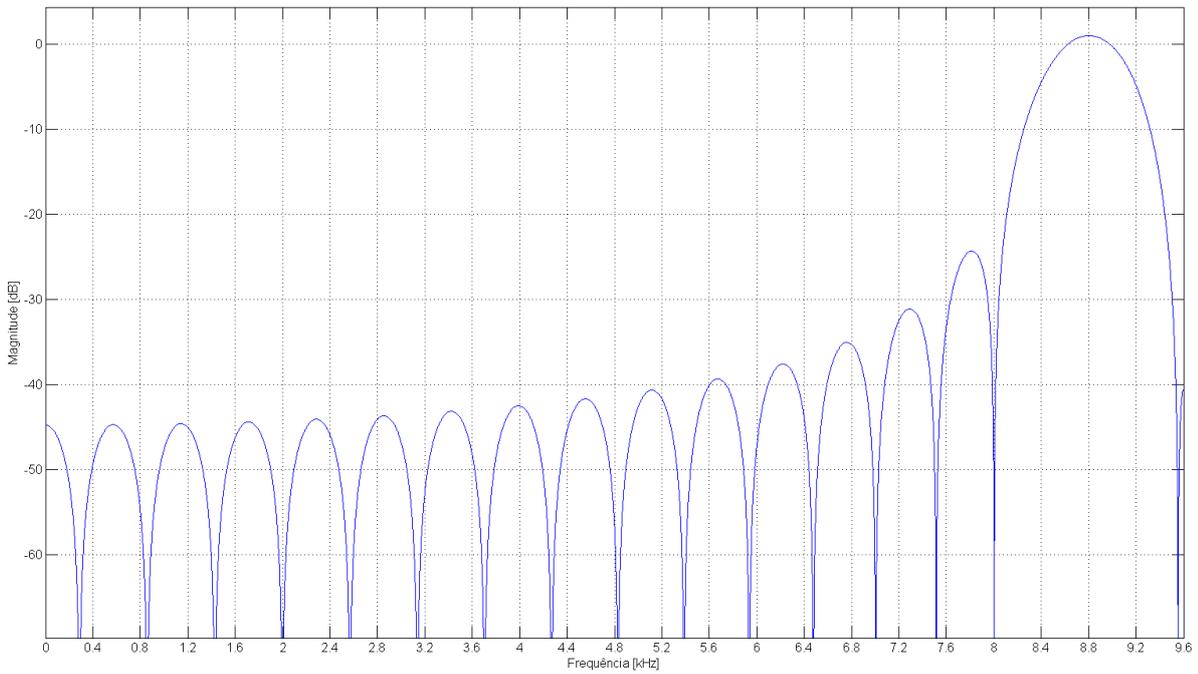


Figura 4.28: Resposta em frequência do filtro dimensionado a partir dos curtogramas.

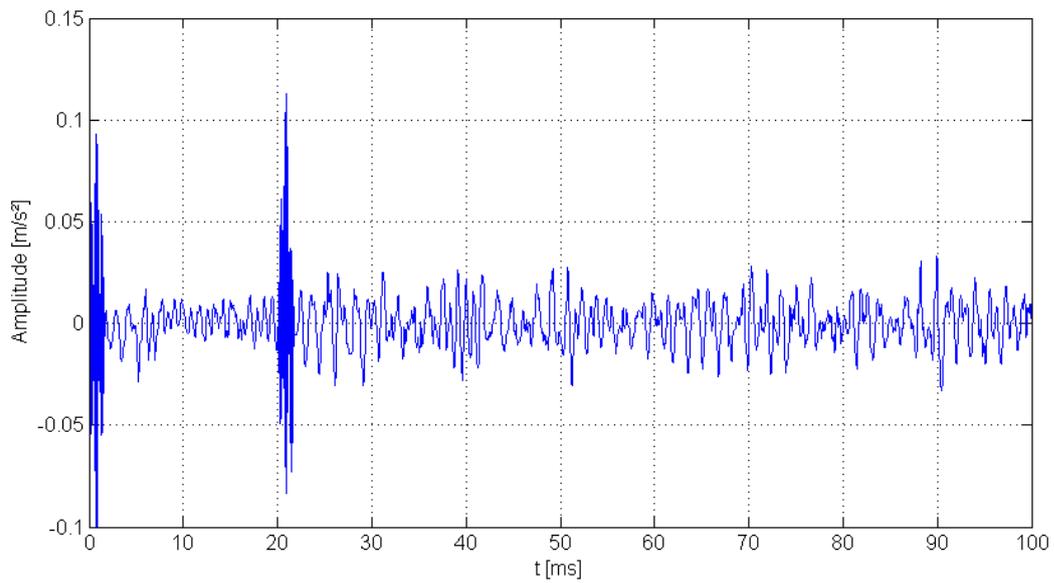


Figura 4.29: Sinal de um mancal sem defeito (novo) após separação da banda impulsiva.

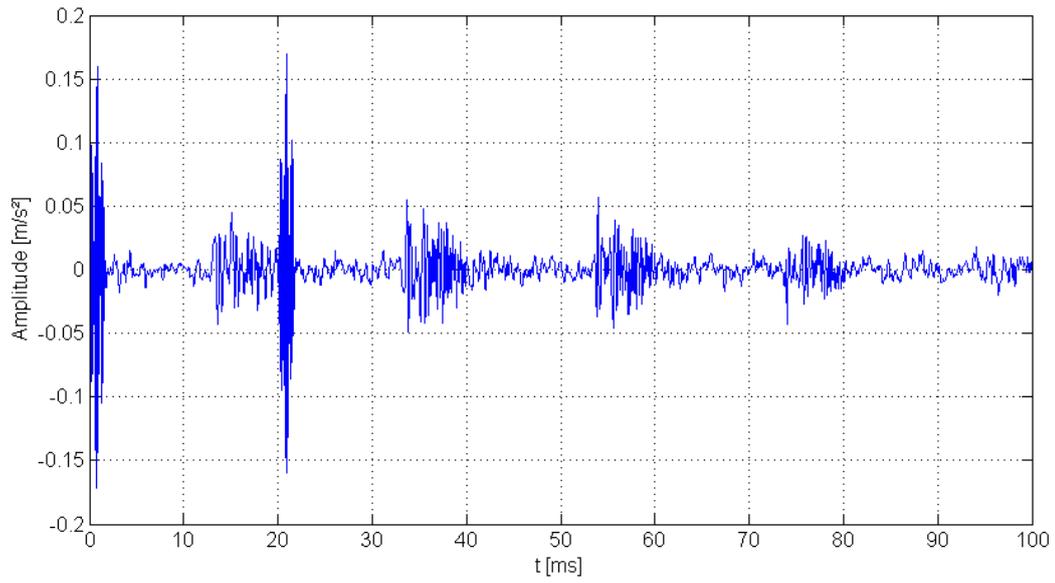


Figura 4.30: Sinal de um mancal com defeito na pista externa após separação.

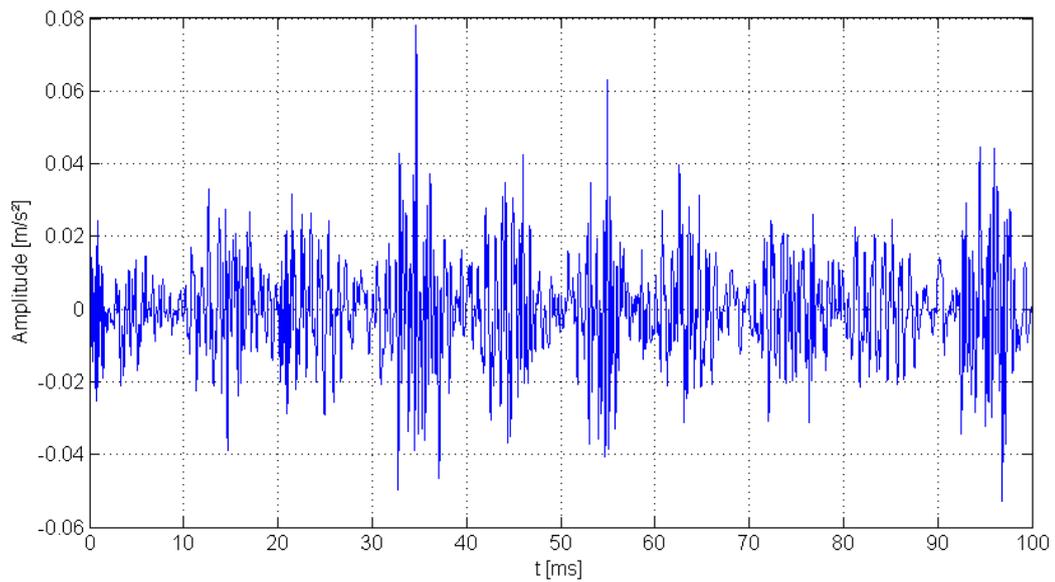


Figura 4.31: Sinal de um mancal com defeito na pista interna após separação.

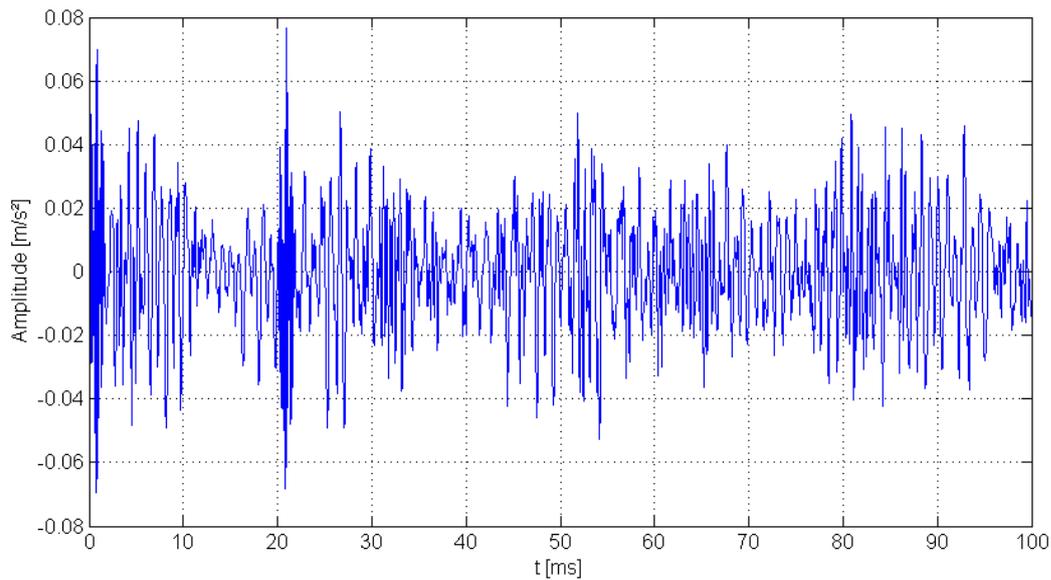


Figura 4.32: Sinal de um mancal com defeito no elemento rolante após separação.

#### 4.1.9 Determinação do espectro quadrático de envelope

O espectro quadrático de envelope, por sua vez, é obtido pela convolução entre as transformadas discretas do sinal analítico e seu complexo conjugado. O Quadro 4.7 apresenta o conjunto de operações realizadas no algoritmo para a obtenção dos espectros de envelope dos sinais.

Quadro 4.7: Sequência executada pela rotina envelope.

```
function [ENVELOPE] = ENVELOPE(sinal_SK);

sinalanalitico = hilbert(sinal_SK, length(sinal_SK)*2);
complexanalitico = conj(sinalanalitico);
ENVELOPE = conv(fft(sinalanalitico), fft(complexanalitico));
```

Os espectros quadráticos de envelope construídos através do algoritmo proposto por Randall e Antoni (2010) são apresentados nas Figuras 4.33, 4.34, 4.35 e 4.36, novamente para os casos dos mancais sem defeito, com defeito na pista externa, com defeito na pista interna e com defeito no elemento rolante, respectivamente. As amplitudes às frequências características de defeito na pista externa,  $A_{FBPO}$ , e na pista interna,  $A_{FBPI}$ , são apresentadas na Tabela 4.3 para cada uma das condições ensaiadas. As amplitudes dos primeiros harmônicos,  $A_{2FBPO}$  e  $A_{2FBPI}$  também são mostradas, dada sua importância para o sistema especialista.

Tabela 4.3: Amplitudes às frequências características de defeito (envelope tradicional).

Tipo de defeito	Potência (amplitude de envelope quadrático) [ - ]			
	$A_{FBPO}$ 178,0 Hz	$A_{FBPI}$ 269,7 Hz	$A_{2x_{FBPO}}$ 356,0 Hz	$A_{2x_{FBPI}}$ 539,4 Hz
Sem defeito (novo)	0,0000016	0,0000130	0,0000120	0,0000150
Defeito na pista externa	0,0000031	0,0000089	0,0000016	0,0000089
Defeito na pista interna	0,0000130	0,0000230	0,0000110	0,0000540
Defeito no elemento rolante	0,0000015	0,0000046	0,0000160	0,0000240

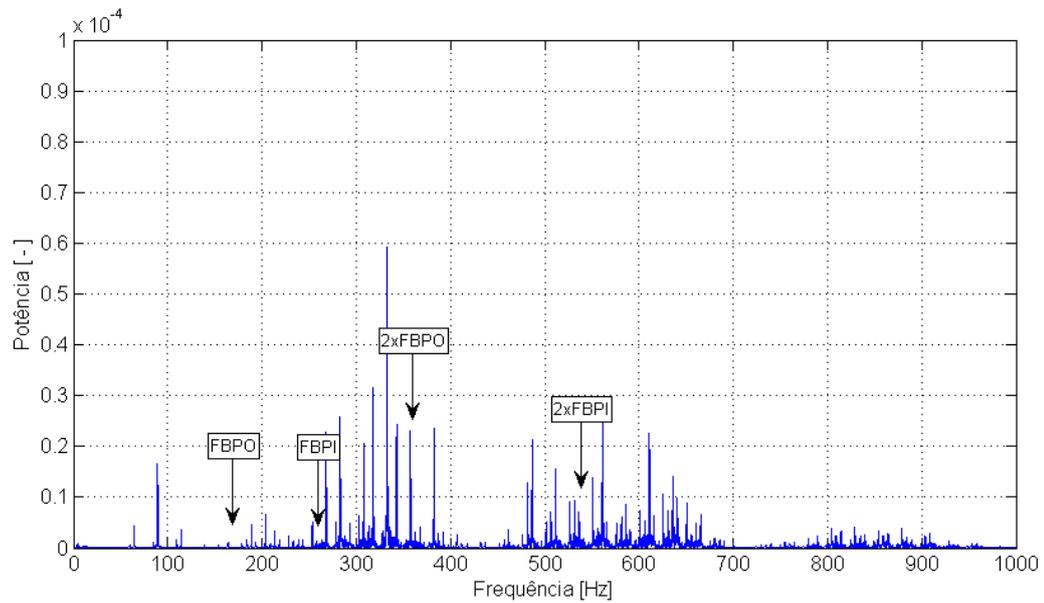


Figura 4.33: Espectro de envelope de um sinal de um mancal novo.

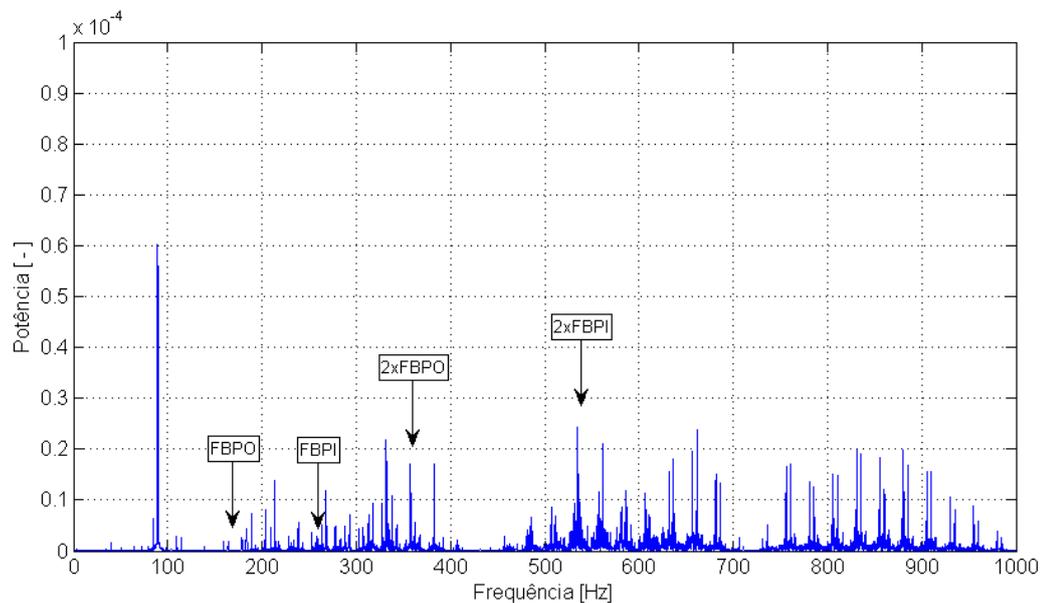


Figura 4.34: Espectro de envelope de um sinal de um mancal com defeito na pista externa.

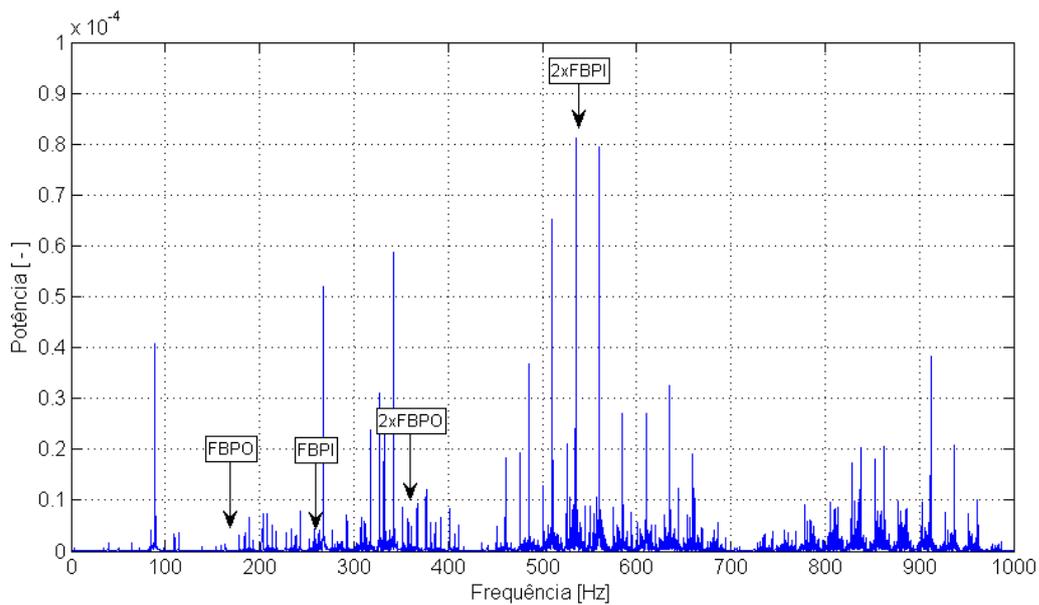


Figura 4.35: Espectro de envelope de um sinal de um mancal com defeito na pista interna.

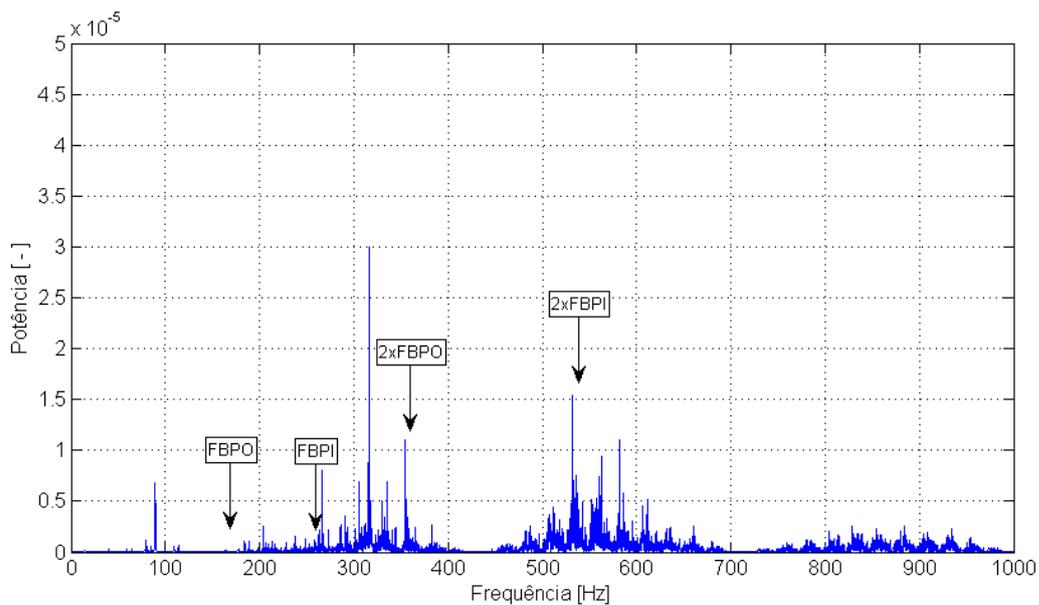


Figura 4.36: Espectro de envelope de um sinal de um mancal com defeito na esfera.

Deve-se salientar que o processamento requerido à obtenção destas propriedades é deveras complicado e altamente dependente da escolha de parâmetros. Por outro lado, a Decomposição Média Local, *LMD*, que será descrita a seguir, é autônoma e pouco influenciada pelo operador. Os resultados obtidos por meio deste procedimento serão posteriormente comparados aos obtidos pelo envelopamento tradicional.

## 4.2 Decomposição média local

Como versado, o algoritmo da decomposição média local converte um sinal qualquer em um conjunto finito de funções produto, cada qual formada a partir de um envelope modulado em amplitude e um sinal modulado em frequência.

As etapas necessárias à obtenção do conjunto de funções produto são conforme os algoritmos da *OELMD* apresentado no trabalho de Zhang, C. *et al.* (2017) como uma otimização ao original proposto por Smith (2005). Sendo assim, será descrito inicialmente o procedimento primitivo de decomposição preconizado pela *LMD*, o qual será complementado pelos valores de amplitudes e larguras de banda de frequências dos ruídos, e pelo número de médias otimizado pelo primeiro para a redução dos efeitos da mixagem de modos inerente ao segundo.

### 4.2.1 Decomposição por LMD

De acordo com o fluxograma da *LMD*, visto na Figura 2.22, o estágio exordial do algoritmo é o de determinação dos extremos locais do sinal. Na rotina concebida para esta tarefa, cujo código em *MatLab* é visto no Quadro 4.8, isto é feito através da função *findpeaks*, que avalia se uma amostra  $x(n)$  de um determinado sinal é maior que as amostras adjacentes  $x(n-1)$  e  $x(n+1)$ , sendo os produtos finais vetores contendo os valores das amplitudes dos extremos encontrados no sinal analisado e as posições ocupadas pelos mesmos. A determinação dos vales presentes no sinal é realizada de maneira análoga, tendo como entrada, no entanto, uma versão invertida do sinal.

Quadro 4.8: Sequência executada pela rotina extremos.

```
function [picos, locpicos, vales, locvales] = extremos(sinal_coletado);

[picos, locpicos] = findpeaks(sinal_coletado);
[vales, locvales] = findpeaks(-sinal_coletado);
vales = -vales;
```

O resultado de um sinal hipotético tratado através da rotina proposta é apresentado na Figura 4.37, onde é possível visualizar o sinal e os valores dos picos e vales.

Em seguida, ainda de acordo com a Figura 2.22, o algoritmo deve calcular as amplitudes médias locais,  $m_i$ , e envelopes médios locais,  $a_i$ . Contudo, antes disso é necessário organizar os picos e vales consecutivos em apenas um vetor de extremos. Para este fim é empregada a função *reshape* do *MatLab*, a qual toma os valores linha a linha de uma matriz,

em uma coluna por vez, e os transpõem para um vetor cujo comprimento final corresponde a soma dos comprimentos dos vetores de picos e vales. O Quadro 4.9 apresenta a sequência executada.

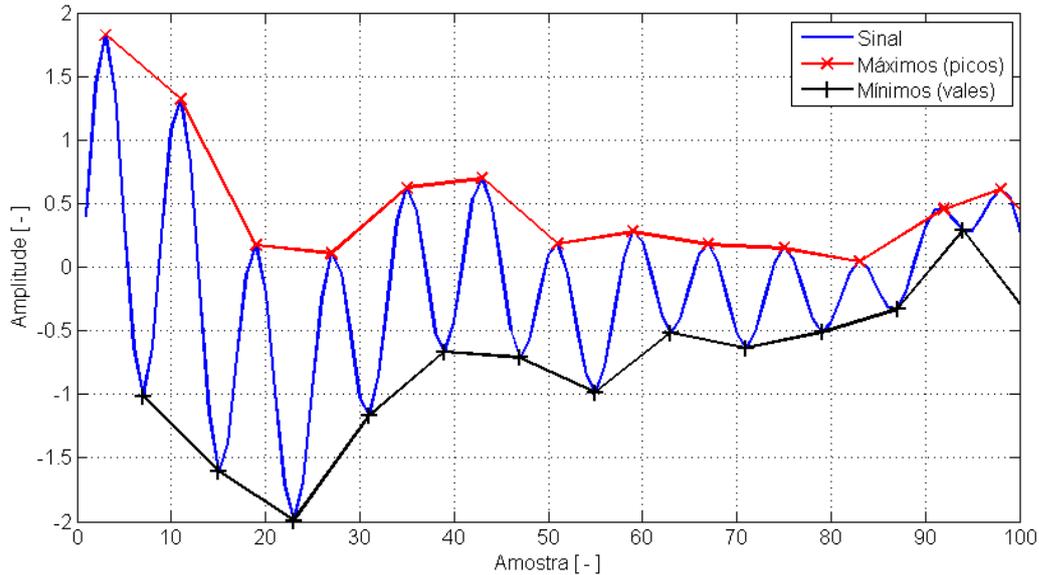


Figura 4.37: Resultado de um sinal hipotético tratado pela rotina *extremos*.

Quadro 4.9: Sequência executada pela rotina *organiza*.

```
function [extremos, locextremos] = organiza(picots, locpicots, vales, locvales);

extremos = reshape([picots; vales], 1, length(picots)+length(vales);
locextremos = reshape([locpicots; locvales], 1, length(locpicots)+length(locvales);
```

Uma vez concluída, a rotina retorna dois vetores, um para os extremos, composto de picos e vales intercalados, e outro para as posições assumidas por estes. Quando apresentados em conjunto com o sinal tratado, dão origem ao gráfico da Figura 4.38.

Tendo determinado os vetores de amplitudes de extremos e de suas respectivas posições no sinal, é possível calcular os valores das amplitudes médias locais, através das equações 2.8, 2.21 e 2.22, e dos envelopes médios locais, por meio das equações 2.9, 2.23 e 2.24.

No algoritmo desenvolvido, a determinação destes valores, vistos na Figura 4.39, é realizada através da sequência de comandos apresentada no Quadro 4.10.

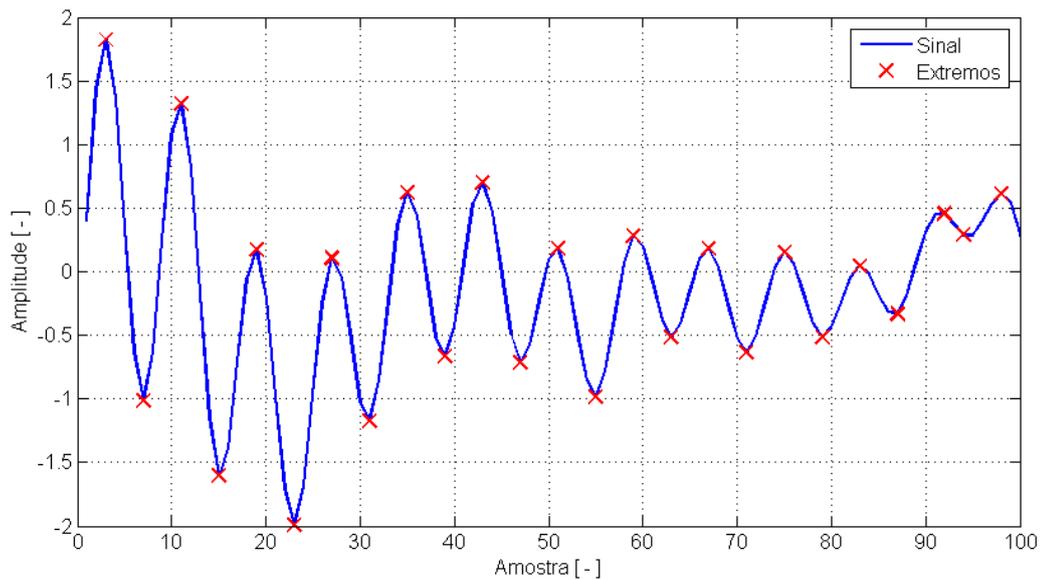


Figura 4.38: Extremos de um sinal hipotético.

Quadro 4.10: Rotina para determinação das amplitudes e envelopes locais.

```
function [m, a, locm] = locais(extremos, locextremos, sinal_coletado);

for i=1:length(locextremos)
    if i == 1
        m(i) = (extremos(i+1)+2*extremos(i+2)+extremos(i+3))/4;
        a(i) = (abs(extremos(i+1)-extremos(i+2))+abs(extremos(i+2)-extremos(i+3)))/4;
        locm(i) = round((locextremos(i))/2);
    else
        m(i) = (extremos(i-1)+extremos(i))/2;
        a(i) = abs((extremos(i-1)-extremos(i))/2);
        locm(i) = round((locextremos(i-1)+locextremos(i))/2);
    end
    if i == length(locextremos)
        m(i+1) = (pkvale(i-2)+2*pkvale(i-1)+pkvale(i))/4;
        a(i+1) = (abs(pkvale(i)-pkvale(i-1))+abs(pkvale(i-1)-pkvale(i-2)))/4;
        locm(i+1) = round((locextremos(i)+length(sinal_coletado))/2);
    end
end
end
```

Logo após, estes valores locais devem ser suavizados através de médias móveis, cujo período, ou época, é determinado pela equação 2.25. Ao término do processo são obtidas duas curvas suavizadas, uma para as amplitudes médias e outra para os envelopes médios. No entanto, seus comprimentos são menores que o sinal em processamento e, por este motivo,

devem ser alongados por artifício de interpolação cúbica para que possam ser subtraídos do sinal coletado. No algoritmo elaborado, os procedimentos de suavização e alongamento são executados conforme a sequência estabelecida no Quadro 4.11.

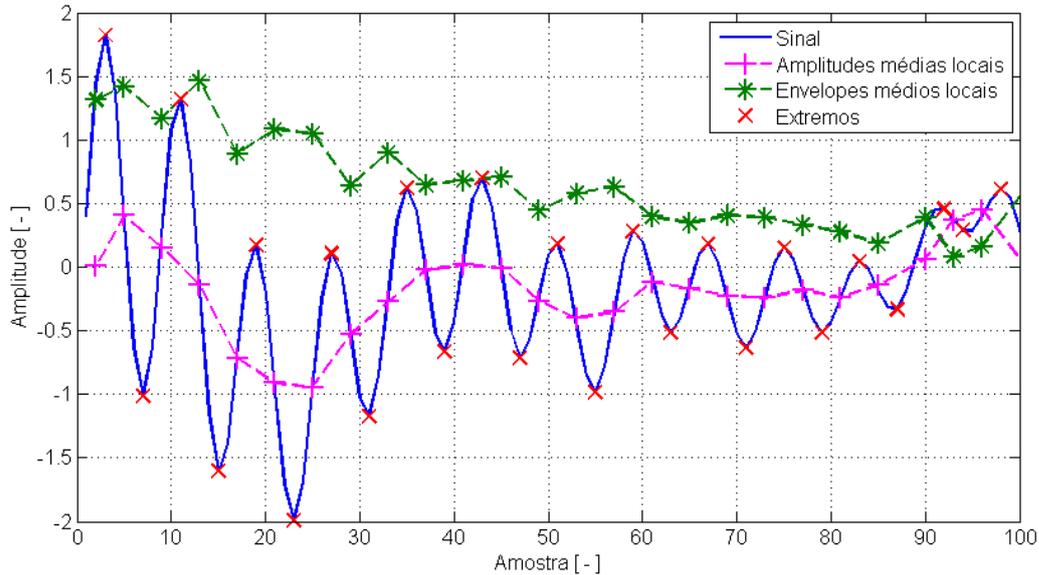


Figura 4.39: Valores de amplitudes e envelopes médios locais.

Quadro 4.11: Sequência executada pela rotina de suavização e alongamento dos vetores.

```
function [imsmooth, iasmooth] = suaviza(extremos, locm, sinal_coletado);

R = 5;
for i=1:length(extremos)-1
    maxl(i) = extremos(i+1)-extremos(i);
end
epochs = ceil(abs((max(maxl)/R)));
msmooth = smooth(m,epochs,'moving');
imsmooth = interp1(locm,msmooth,[1:length(sinal_coletado)],'pchip');
asmooth = smooth(a,epochs,'moving');
iasmooth = interp1(locm,asmooth,[1:length(sinal_coletado)],'pchip');
```

A função *smooth* suaviza o vetor de valores médios locais através da aplicação de um filtro de médias móveis, tendo como argumento o número de períodos desejado. Já a função *interp1* realiza uma interpolação cúbica ponderada, em *MatLab* denominada *pchip*, para adicionar pontos entre dois valores consecutivos em quantidade proporcional à distância existente entre os mesmos. Com isso, são obtidas duas curvas suavizadas de amplitudes e

envelopes médios locais, cujos comprimentos, doravante, são idênticos aos do sinal em processamento. Este resultado pode ser visto na Figura 4.40.

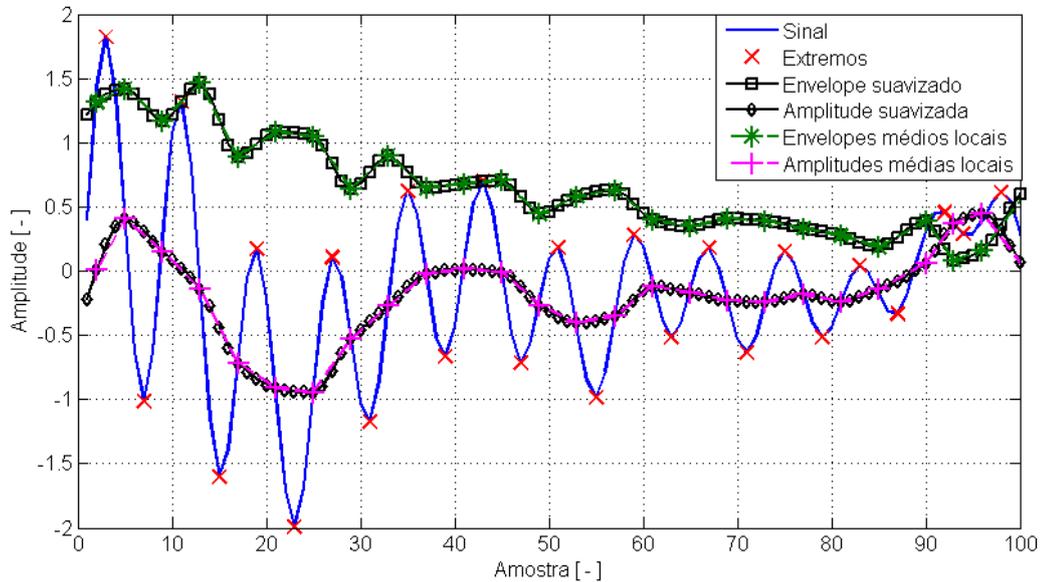


Figura 4.40: Valores de amplitudes e envelopes suavizados.

Finalizadas as etapas de determinação e suavização das curvas de valores médios locais, o algoritmo está habilitado à execução do primeiro laço do fluxograma da *LMD* mostrado na Figura 2.22, que corresponde à gradativa decomposição do sinal em processamento até a obtenção de um vetor de envelopes suavizados constante. Esta iteração é realizada no algoritmo proposto através das operações descritas no Quadro 4.12.

A função *iteracao1* subtrai o vetor de amplitudes suavizadas médias locais, *imsmooth*, do sinal em processamento, denominado *sinal\_coletado*, dando origem ao vetor *h*. A cada iteração, o sinal original é substituído pelo vetor *s*, dado pelo quociente da divisão dos vetores resultante, *h*, e de envelopes suavizados médios locais, *iasmooth*. Estes valores, por sua vez, são armazenados em uma matriz de envelopes, *Ma*, em todas as iterações. O vetor *at*, por sua vez, corresponde aos envelopes suavizados médios locais da iteração *n*, inicialmente descrito como um vetor de zeros. A rotina se encerra quando o produto interno do vetor *at* é igual a 1 (um), indicando que o envelope suavizado médio local é constante. A saída da função é a matriz de envelopes suavizados, *Ma*, composta de *n* linhas.

Quadro 4.12: Operações realizadas para solução do primeiro laço da LMD.

```

function [Ma, s] = iteracao1(sinal_coletado);

at = zeros(1,length(sinal_coletado));
n = 1;
while single(prod(at)) ~= 1
    [picos, lopicos, vales, locvales] = extremos(sinal_coletado);
    [extremos, locextremos] = organiza(picos, lopicos, vales, locvales);
    [m, a, locm] = locais(extremos, locextremos, sinal_coletado);
    [imsmooth, iasmooth] = suaviza(extremos, locm, sinal_coletado);
    h = sinal_coletado - imsmooth;
    s = h./iasmooth;
    Ma(n,:) = iasmooth;
    at = iasmooth;
    sinal_coletado = s;
    n = n + 1;
end

```

Acabada esta verificação, o algoritmo inicia o segundo laço do fluxograma da *LMD*, que corresponde à obtenção das funções produto, frequências e fases instantâneas, envelopes das funções produto e o sinal suavizado pós-decomposição,  $u$ . A sequência iterativa pode ser visualizada no Quadro 4.13.

A cada iteração a rotina atualiza o sinal em decomposição, substituindo-o por sua versão suavizada, obtida da diferença do sinal decomposto e sua respectiva função produto. O critério de parada é o desvio padrão deste sinal resultante. Caso o valor escolhido para este parâmetro seja muito baixo, o algoritmo irá produzir inúmeras funções produto redundantes, aumentando o consumo computacional, enquanto um valor elevado pode não promover a decomposição completa do sinal. Para evitar o congelamento da rotina é estipulado um número máximo de funções produto igual a 10 (dez).

Com a solução do segundo laço é encerrada a decomposição *LMD* segundo Smith (2005), tendo como resultados uma matriz de funções produto,  $PF$ , contendo um número  $k$  de funções, os envelopes instantâneos associados às funções produto, *envelope*, as frequências, *instfreq*, e fases, *instfase*, instantâneas, e o restante do sinal decomposto em cada iteração,  $u$ .

Quadro 4.13: Operações realizadas para solução do segundo laço da LMD.

```

function [instfase, instfreq, envelope, PF, u] = iteracao2(sinal_coletado, fs, desvpad);

k = 1;
flag = 1;
while flag > 0
    [Ma, s] = iteracao1(sinal_coletado);
    instfase(k,:) = acos(s);
    for w=1:length(s)
        if w < length(s)
            instfreq(k,w) = fs/(2*pi())*(instfase(w+1)-instfase(w));
        else
            instfreq(k,w) = 0;
        end
    end
    envelope(k,:) = prod(Ma);
    PF(k,:) = envelope(k,:).*s;
    u = sinal_coletado - PF(k,:);
    k = k + 1;
    if std(u(k,:)) < desvpad
        flag = 0;
    end
    if k == 10
        flag = 0;
    end
    sinal_coletado = u(k,:);
    k = k + 1;
end

```

Os espectros quadráticos das funções produto,  $PF$ , apresentadas nas Figuras 4.41, 4.42, 4.43 e 4.44, são calculados através da equação 2.28 para as condições de mancal sem defeito, com defeito na pista externa, com defeito na pista interna e com defeito no elemento rolante, e mostrados nas Figuras 4.45, 4.46, 4.47 e 4.48, respectivamente. A partir dos mesmos são determinadas as amplitudes mostradas na Tabela 4.4, correspondentes às frequências características de defeito para cada uma das situações estudadas.

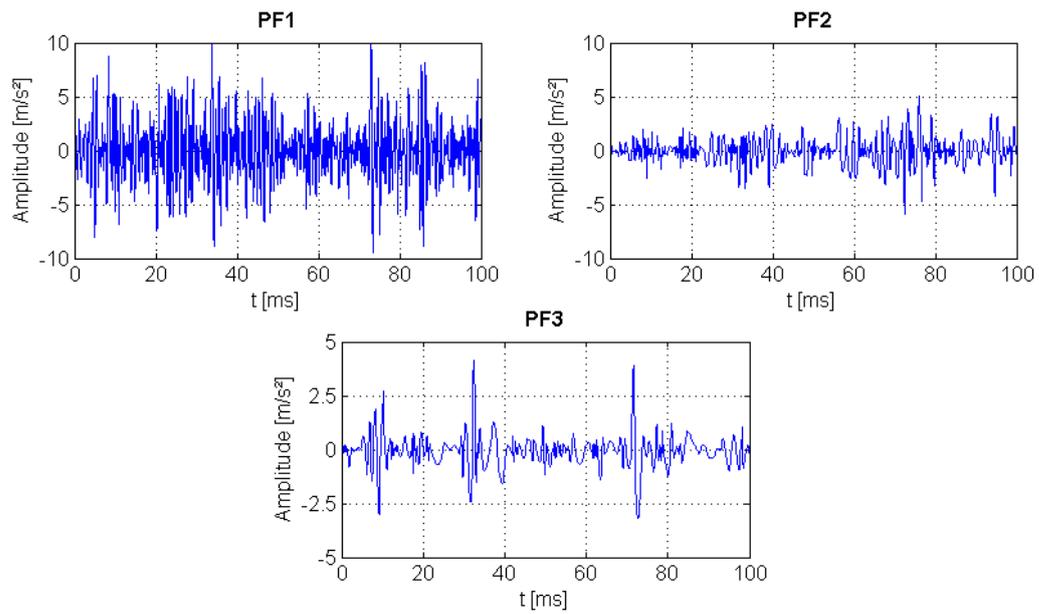


Figura 4.41: Funções produto fornecidas pela *LMD* (mancal sem defeito).

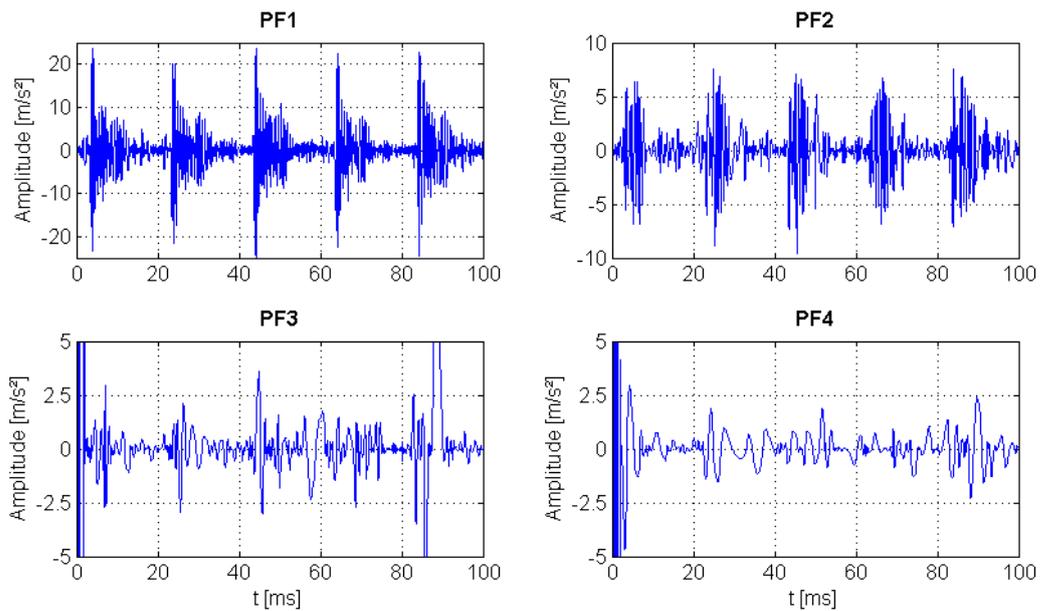


Figura 4.42: Funções produto fornecidas pela *LMD* (mancal com defeito na pista externa).

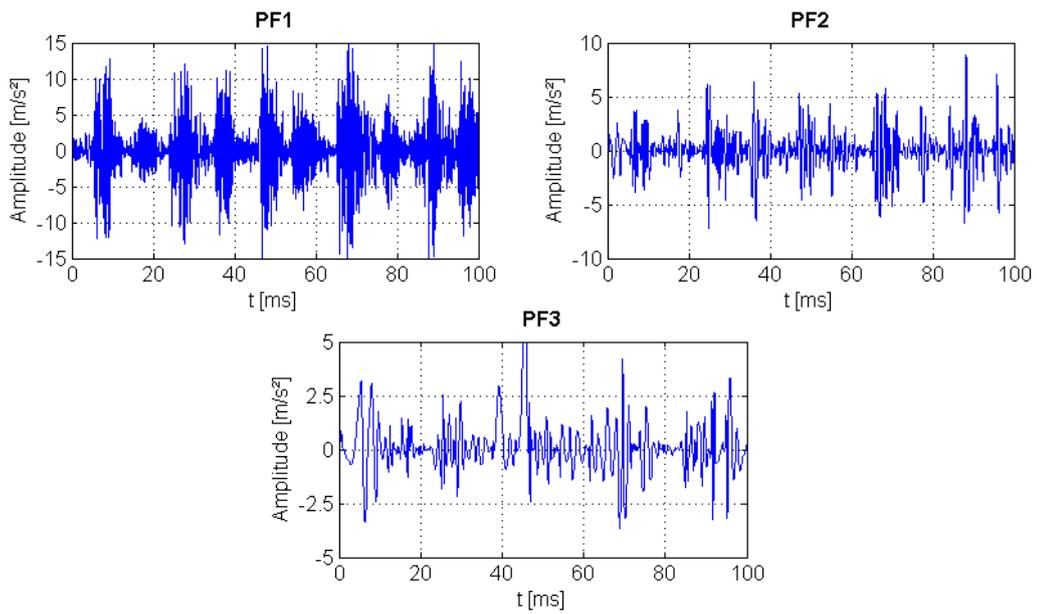


Figura 4.43: Funções produto fornecidas pela *LMD* (mancal com defeito na pista interna).

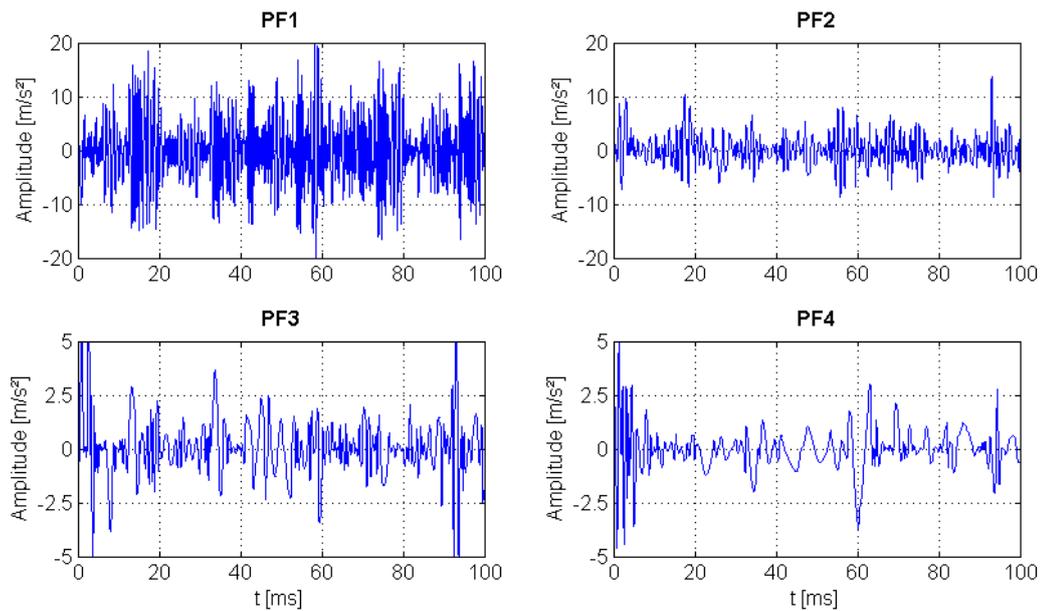


Figura 4.44: Funções produto fornecidas pela *LMD* (mancal com defeito na esfera).

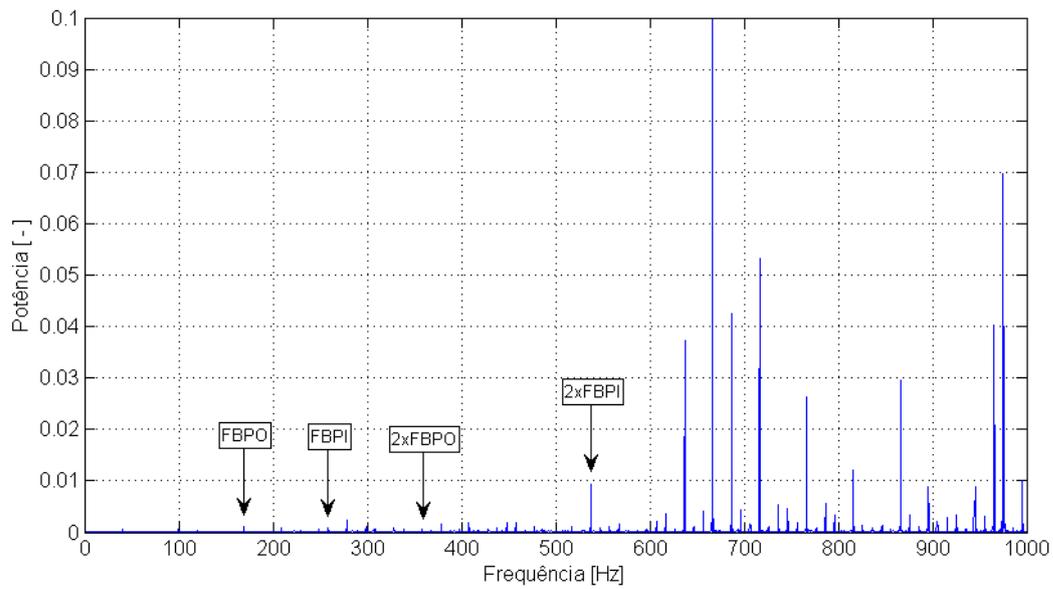


Figura 4.45: Espectro quadrático obtido pela *LMD* (mancal sem defeito).

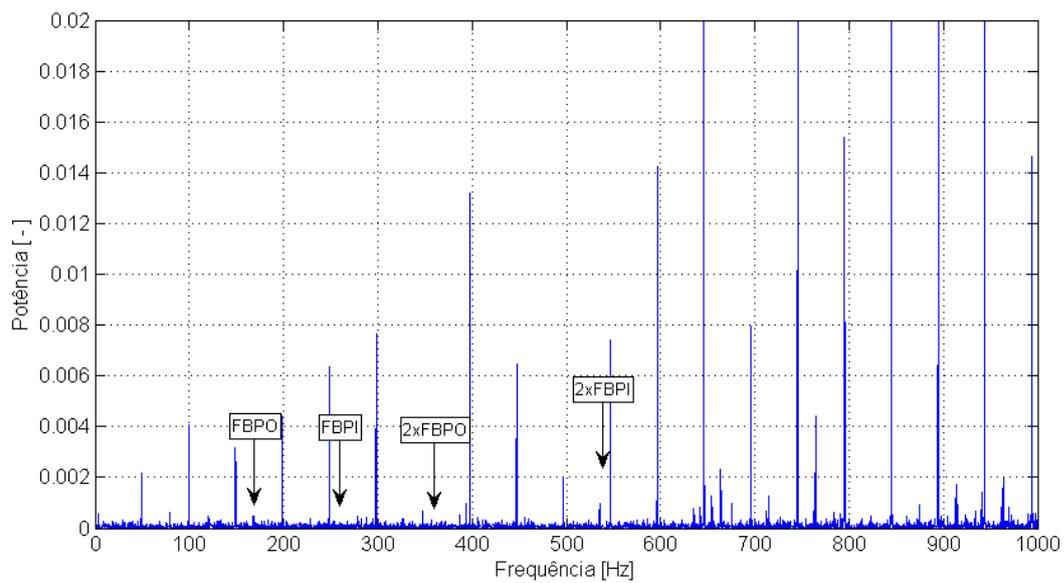


Figura 4.46: Espectro quadrático obtido pela *LMD* (mancal com defeito na pista externa).

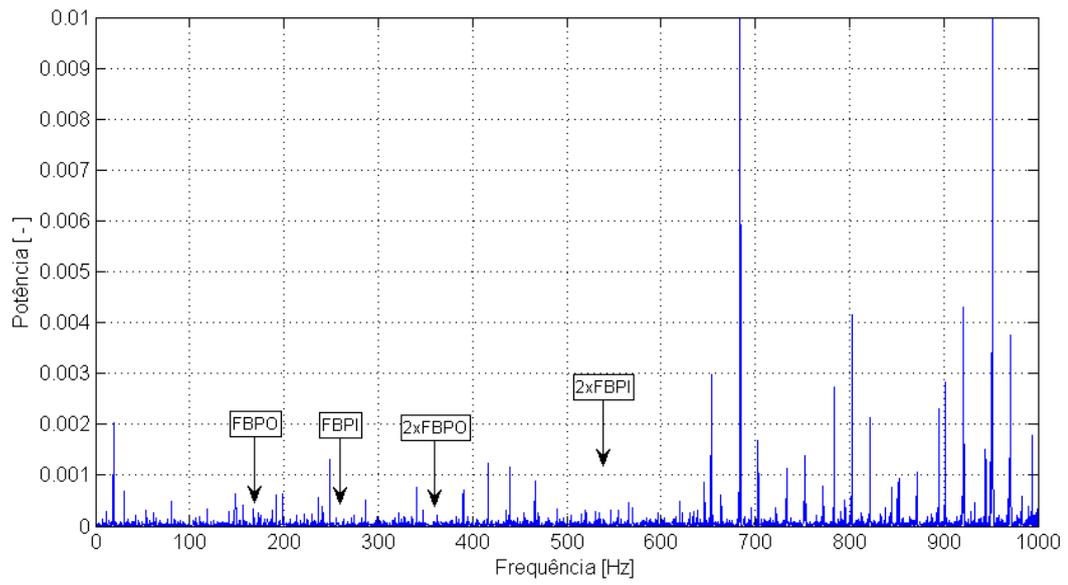


Figura 4.47: Espectro quadrático obtido pela *LMD* (mancal com defeito na pista interna).

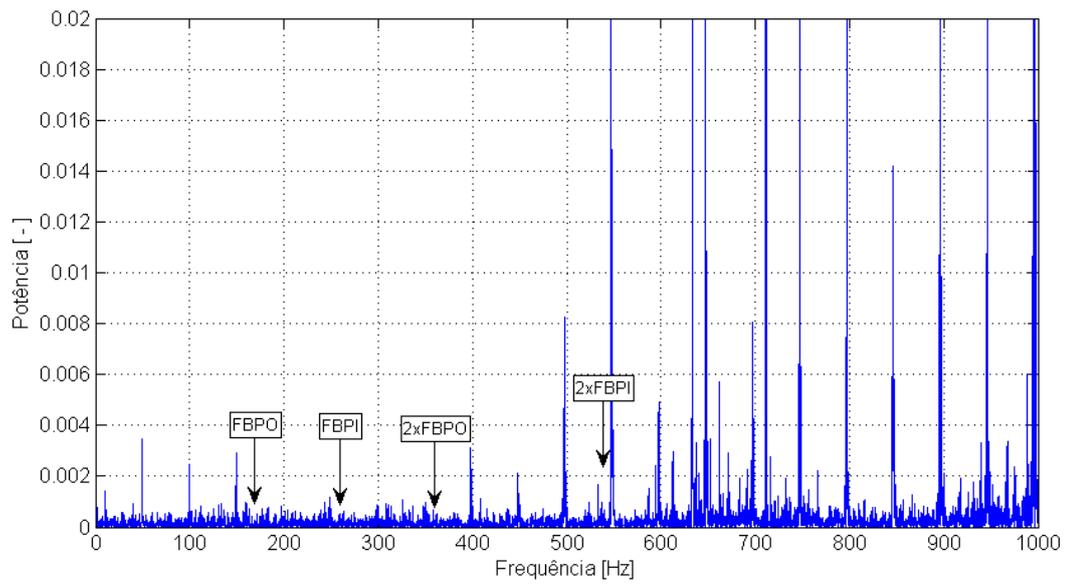


Figura 4.48: Espectro quadrático obtido pela *LMD* (mancal com defeito na esfera).

Tabela 4.4: Amplitudes às frequências características de defeito (LMD).

Tipo de defeito	Potência (amplitude de envelope quadrático) [ - ]			
	$A_{FBPO}$ 178,0 Hz	$A_{FBPI}$ 269,7 Hz	$A_{2 \times FBPO}$ 356,0 Hz	$A_{2 \times FBPI}$ 539,4 Hz
Sem defeito (novo)	0,00160	0,01300	0,00170	0,00190
Defeito na pista externa	0,00120	0,00087	0,00190	0,00190
Defeito na pista interna	0,00029	0,00067	0,00067	0,00110
Defeito no elemento rolante	0,00270	0,00540	0,04300	0,03400

Como esperado, houve mistura de modos em todas as decomposições, evidenciada pela elevada semelhança visual entre a primeira,  $PF_1$ , e segunda funções produto,  $PF_2$ .

## 4.2.2 Decomposição por OELMD

Estando concluída a discretização do algoritmo primitivo da *LMD*, dá-se início à implementação de sua versão otimizada, proposta por Zhang, C. *et al.* (2017) e denominada *OELMD*. Como sabido, esta técnica modela as funções produto como uma média daquelas obtidas a partir do sinal original somado a uma série de ruídos brancos cujas amplitudes e larguras de banda de frequências devem ser previamente melhoradas a fim de mitigar a mistura de modos própria da *LMD*.

O fluxograma da *OELMD*, exibido na Figura 4.49, utiliza, além do desenvolvimento realizado para a *LMD*, três etapas complementares para a determinação da amplitude,  $L_N$ , da largura da banda de frequências,  $fb$ , e do número de médias,  $N_E$ , ideais.

No ciclo inicial, representado pela prumada à esquerda do fluxograma, o algoritmo da *OELMD* realiza a busca do valor ideal de  $L_N$  em um vetor finito de opções, espaçadas por intervalo constante de amplitudes, sendo escolhida aquela que produz um erro relativo médio quadrático, *RRMSE*, máximo. Na linguagem utilizada a solução deste laço é obtida através da função apresentada no Quadro 4.14.

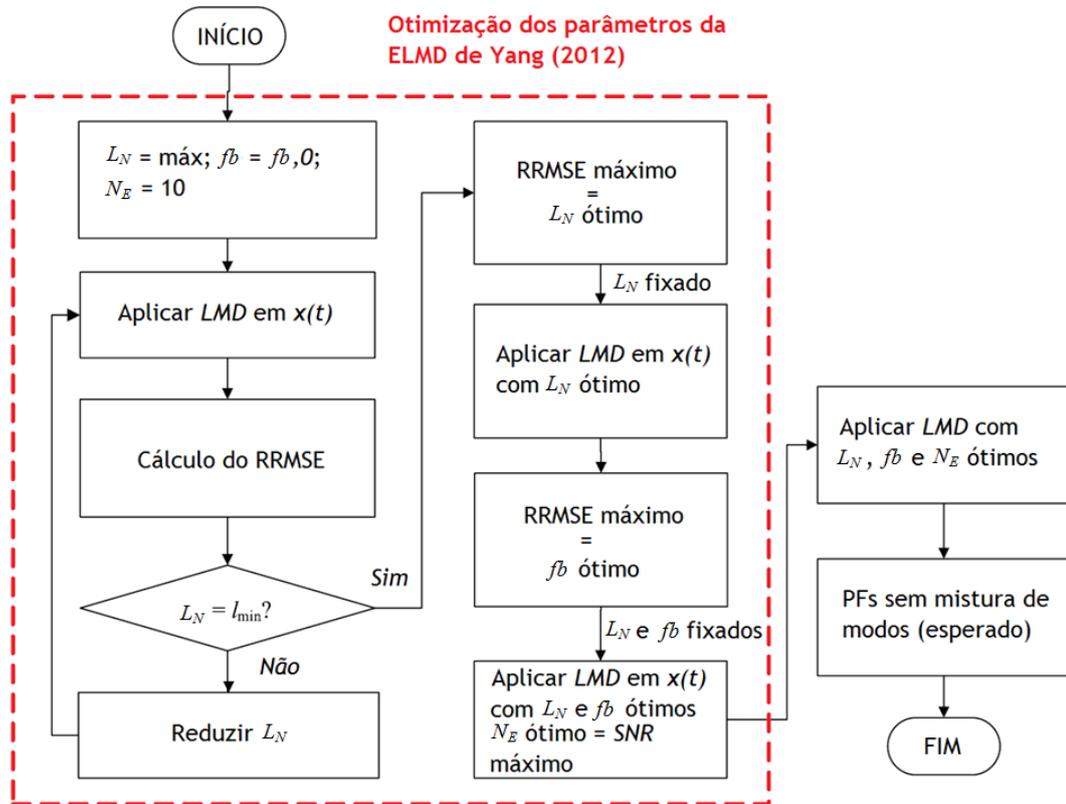


Figura 4.49: Fluxograma da OELMD.

Fonte: Adaptada de Zhang, C. *et al.* (2017).

Quadro 4.14: Operações realizadas para solução do primeiro laço da OELMD.

```

function [ln] = lideal(sinal_coletado, fs, desvpad);

vetamp = linspace(0.05,2,40);
for pos_vetamp = 1:length(vetamp)
    PFt = zeros(10,length(sinal_coletado));
    mPF = zeros(10,length(sinal_coletado));
    for ne = 1:10
        PF = zeros(10,length(sinal_coletado));
        ruido = vetamp(pos_vetamp)*wgn(length(sinal_coletado),1,0)';
        [bfiltro,afiltro] = butter(4, 0.5, 'high');
        ruidofiltrado = filter(bfiltro, afiltro, ruido);
        sinal_aux = sinal_coletado + ruidofiltrado;
        [instfase, instfreq, envelope, PF, u] = iteracao2(sinal_aux, fs, desvpad);
        PFt = PFt+PF;
    end
    mPF = PFt/ne;
    RMSE(:,pos_vetamp) = RRMSE(sinal_coletado, mPF);
end
plot(vetamp,RMSE)
[maxRMSE, posRMSE] = max(RMSE);
ln = vetamp(:, posRMSE);
  
```

Esta função alimenta o algoritmo original da *LMD*, visto anteriormente, com o sinal somado a um ruído branco gaussiano, gerado no *MatLab* por meio do comando *wgn*, tratado por um filtro passa alta de *butterworth* de quarta ordem e largura de banda equivalente à metade da frequência de amostragem, *fs*.

As funções produto resultantes deste processamento para uma determinada amplitude de ruído, selecionada a partir do vetor finito de amplitudes, *vetamp*, são somadas e armazenadas em um único vetor denominado *PFt*. Após a execução do algoritmo um número *ne* de vezes, é calculada a função produto final média, *mPF*.

A *PF* final e o sinal coletado originalmente são, então, inseridos na função *RRMSE*, apresentada no Quadro 4.15, que calcula, através da equação 2.26, o erro relativo médio quadrático associado à amplitude testada.

É necessário ressaltar que o denominador da equação da *RRMSE* é o desvio padrão de segunda ordem do sinal em decomposição.

Quadro 4.15: Operações realizadas para o cálculo do erro relativo médio quadrático.

```
function [RMSE] = RRMSE(sinal_coletado, mPF);  
  
RMSE = (rms(sinal_coletado - rms(mPF(1,:)))/std(sinal_coletado, 1);
```

As curvas de valores de *RRMSE* em função da amplitude do ruído adicionado são apresentadas na Figura 4.50. Como resultado se obtém as amplitudes ideais para o ruído de 2,41; 9,49; 7,91 e 6,34 m/s<sup>2</sup>, determinadas a partir dos valores máximos dos erros relativos para as condições de mancal sem defeito, com defeito na pista externa, com defeito na pista interna e com defeito no elemento rolante, respectivamente.

Uma vez fixada a amplitude ideal para o ruído é iniciado o ciclo de otimização da largura da banda de frequências, mostrado no ramo central da Figura 4.49. O procedimento executado para tanto, apresentado no Quadro 4.16, é similar ao anterior, e consiste na maximização do erro relativo médio por meio da variação da largura da banda de frequências do ruído branco adicionado, *fb*. Os parâmetros de entrada do algoritmo são a amplitude ideal,  $L_N$ , o desvio padrão desejado em cada sinal suavizado, *desvpad*, o sinal coletado originalmente e a taxa de amostragem, *fs*.

Os valores assumidos por *fb* são tomados a partir de um conjunto finito de opções, e, para que haja compatibilidade com a frequência de amostragem, o sinal em processamento é reamostrado a cada iteração. A saída da rotina é a largura ideal para a banda de frequências do ruído, cujos valores associados ao *RRMSE* são apresentados na Figura 4.51 para cada uma das condições testadas.

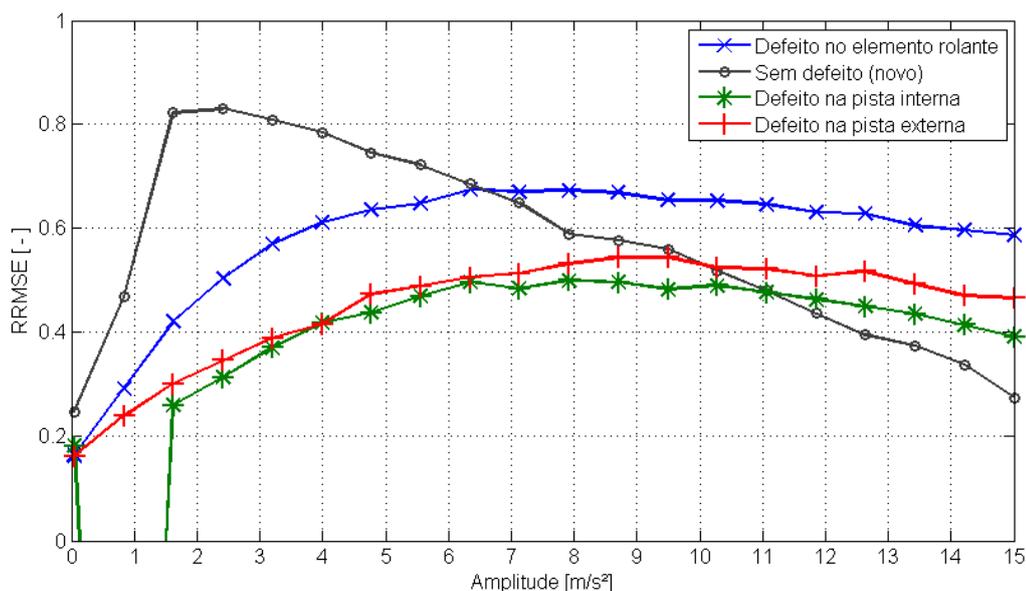


Figura 4.50: Valores de  $RRMSE$  associados às amplitudes do ruído adicionado.

Quadro 4.16: Operações realizadas para solução do segundo laço da OELMD.

```
function [fb] = fbideal(sinal_coletado, ln, fs, desvpad);

vetfb = linspace(1, 20, 20);
for pos_vetfb = 1:length(vetfb)
    sinal_reamostrado = resample(sinal_coletado, pos_vetfb*length(sinal_coletado), ...
    ... length(sinal_coletado));
    PFt = zeros(10,length(sinal_reamostrado));
    mPF = zeros(10,length(sinal_reamostrado));
    for ne = 1:10
        PF = zeros(10,length(sinal_reamostrado));
        ruido = ln*wgn(length(sinal_reamostrado),1,0)';
        [bfiltro,afiltro] = butter(4, 0.5, 'high');
        ruidofiltrado = filter(bfiltro, afiltro, ruido);
        sinal_aux = sinal_reamostrado + ruidofiltrado;
        [instfase, instfreq, envelope, PF, u] = iteracao2(sinal_aux, fs, desvpad);
        PFt = PFt+PF;
    end
    mPF = PFt/ne;
    RMSE(:, pos_vetfb) = RRMSE(sinal_coletado, mPF);
end
[maxRMSE, posRMSE] = max(RMSE);
fb = vetfb(:, posRMSE);
```

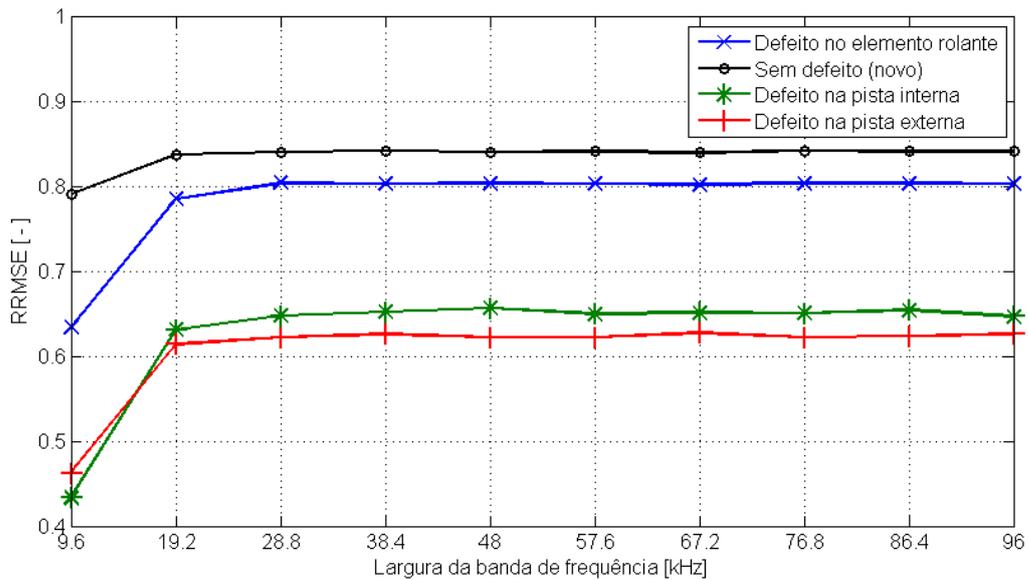


Figura 4.51: Valores de  $RRMSE$  associados às larguras da banda de frequência do ruído.

As larguras das bandas de frequência dos ruídos adicionados são aquelas com maior  $RRMSE$  associado. Para as condições de mancal sem defeito, com defeito na pista externa, com defeito na pista interna e com defeito no elemento rolante estes valores são, respectivamente, 19,2; 38,4; 48 e 28,8 kHz.

Para finalizar, é executada a rotina de aperfeiçoamento do número de médias a partir dos valores ótimos da amplitude do ruído adicionado,  $L_N$ , e da largura de banda de frequências,  $fb$ .

No algoritmo proposto tal procedimento é executado através da sequência de comandos apresentada no Quadro 4.17, a qual utiliza o conceito de maximização da relação ruído-sinal,  $SNR$ , calculada através de uma versão modificada da equação 2.28, para a determinação do número de médias ideal,  $ne_{ideal}$ .

Na Figura 4.52 são apresentadas as  $SNR$  obtidas em função do número de médias empregado na decomposição dos sinais analisados, sendo os valores ideais de médias 180, 200, 200 e 190, respectivamente para as condições sem defeito, com defeito na pista externa, com defeito na pista interna e com defeito no elemento rolante.

Quadro 4.17: Operações realizadas para solução do terceiro laço da OELMD.

```

function [ne_ideal] = neideal(sinal_coletado, ln, fb, fs, desvpad);

vetne = linspace(10, 200, 10);
sinal_reamostrado = resample(sinal_coletado, fb/fs*length(sinal_coletado), ...
    ... length(sinal_coletado));
for pos_vetne = 1:length(vetne)
    PFt = zeros(10,length(sinal_reamostrado));
    mPF = zeros(10,length(sinal_reamostrado));
    for ne = 1:vetne(pos_vetne)
        PF = zeros(10,length(sinal_reamostrado));
        ruido = ln*wgn(length(sinal_reamostrado),1,0)';
        [bfiltro,afiltro] = butter(4, 0.5, 'high');
        ruidofiltrado = filter(bfiltro, afiltro, ruido);
        sinal_aux = sinal_reamostrado + ruidofiltrado;
        [instfase, instfreq, envelope, PF, u] = iteracao2(sinal_aux, fs, desvpad);
        PFt = PFt+PF;
    end
    mPF = PFt/ne;
    SNR(:, pos_vetne) = snr(sinal_reamostrado, sinal_reamostrado-mPF(1,:));
end
plot(vetne, SNR)
[maxSNR, posSNR] = max(SNR);
ne_ideal = vetne(:, posSNR);

```

Com os valores ótimos de  $L_N$ ,  $fb$  e  $N_E$  estabelecidos, o algoritmo da *OELMD* propriamente dito é utilizado para calcular as funções produto, vistas nas Figuras 4.53, 4.54, 4.55 e 4.56, das quais são extraídos os espectros quadráticos, mostrados nas Figuras 4.57, 4.58, 4.59 e 4.60, e amplitudes às frequências características de defeito para cada uma das condições ensaiadas, resumidas na Tabela 4.5.

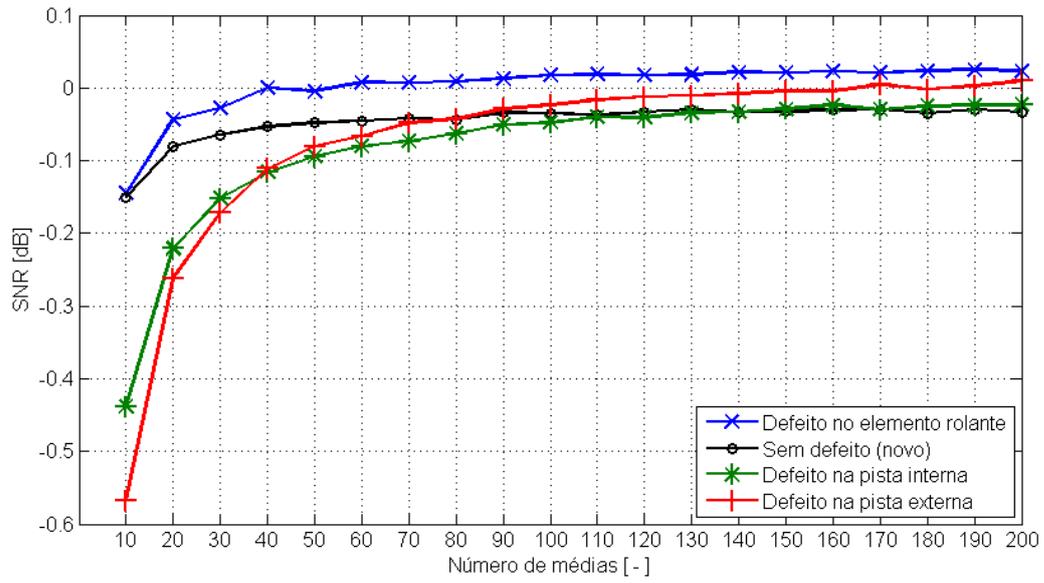


Figura 4.52: Valores de *SNR* associados ao número de médias utilizado pela *OELMD*.

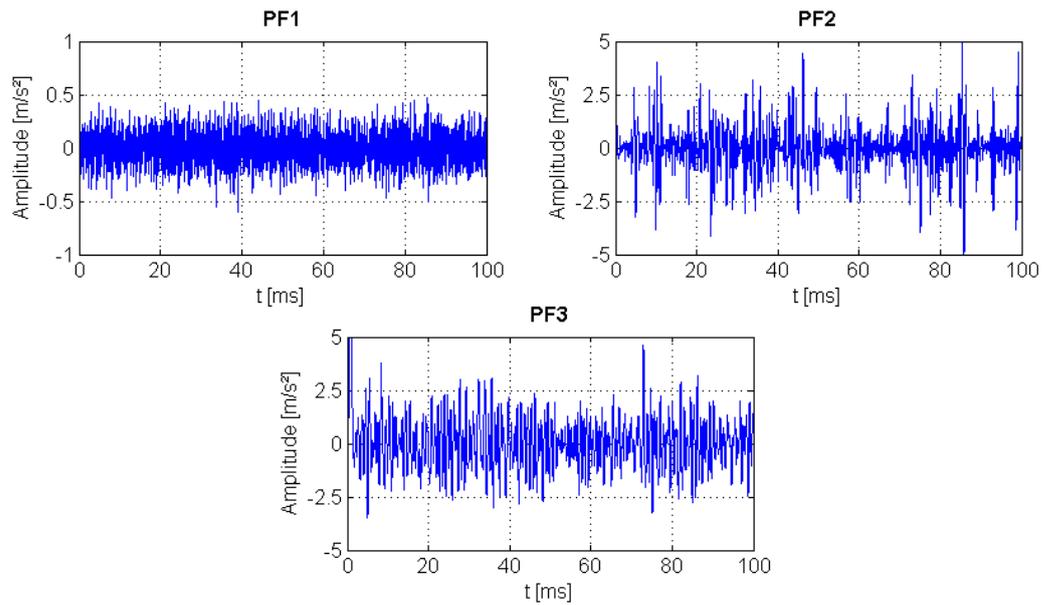


Figura 4.53: Funções produto fornecidas pela *OELMD* (mancal sem defeito).

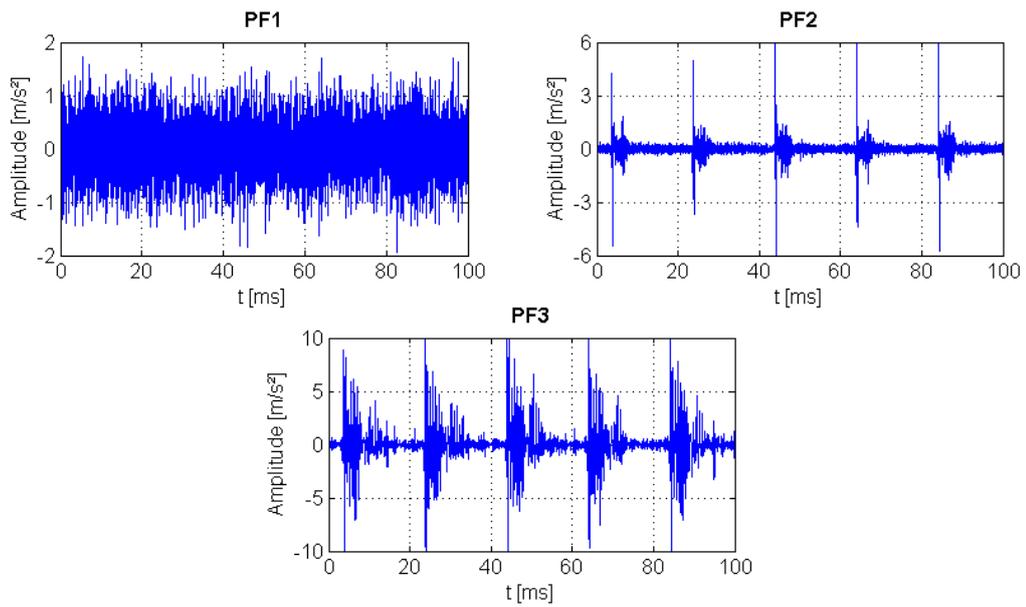


Figura 4.54: Funções produto fornecidas pela *OELMD* (defeito na pista externa).

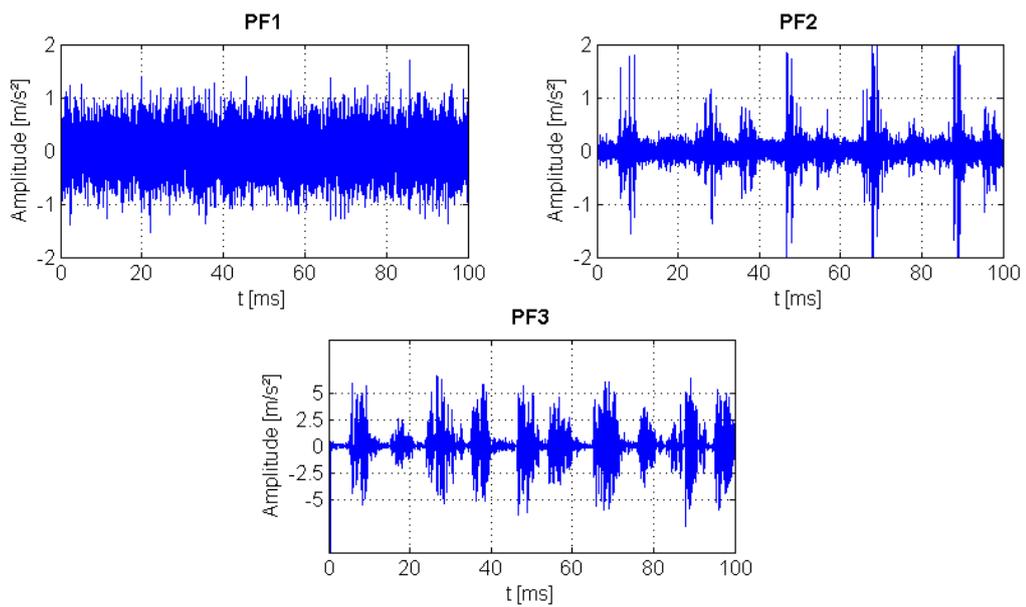


Figura 4.55: Funções produto fornecidas pela *OELMD* (defeito na pista interna).

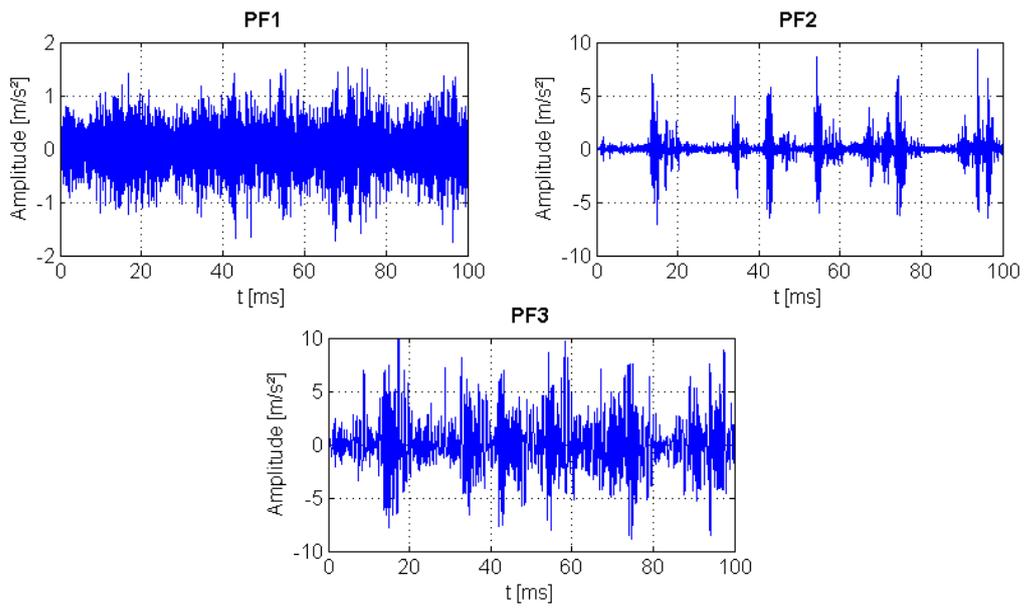


Figura 4.56: *PF* fornecidas pela *OELMD* (mancal com defeito na esfera).

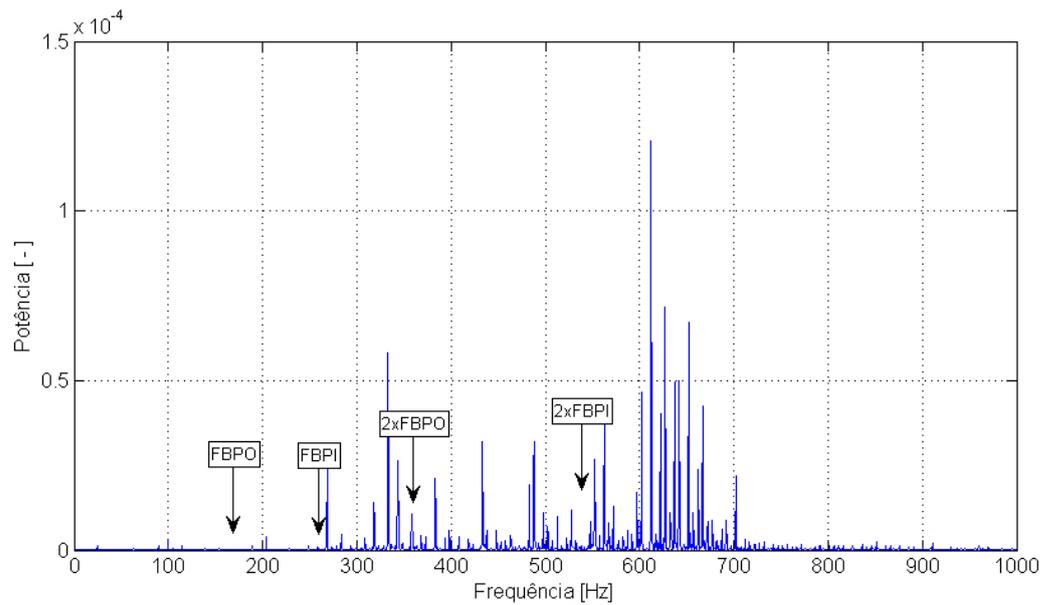


Figura 4.57: Espectro quadrático obtido pela *OELMD* (mancal sem defeito).

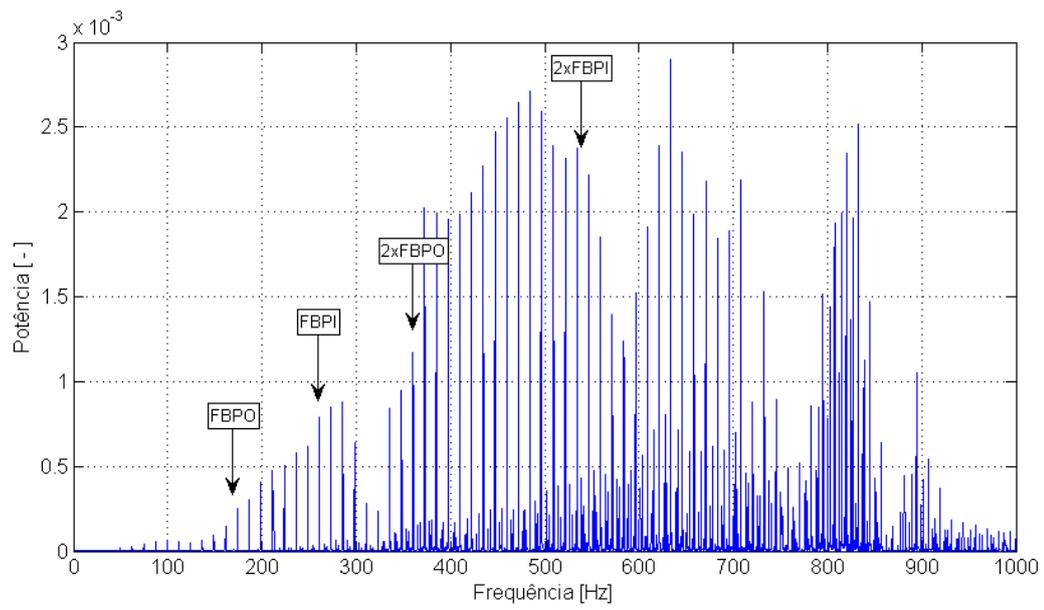


Figura 4.58: Espectro quadrático obtido pela *OELMD* (defeito na pista externa).

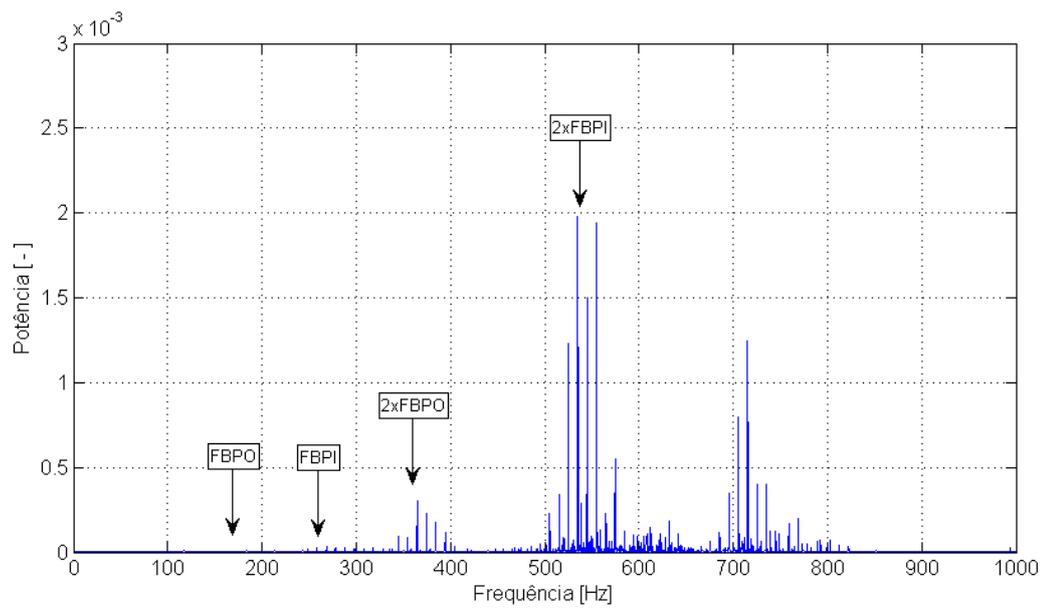


Figura 4.59: Espectro quadrático obtido pela *OELMD* (defeito na pista interna).

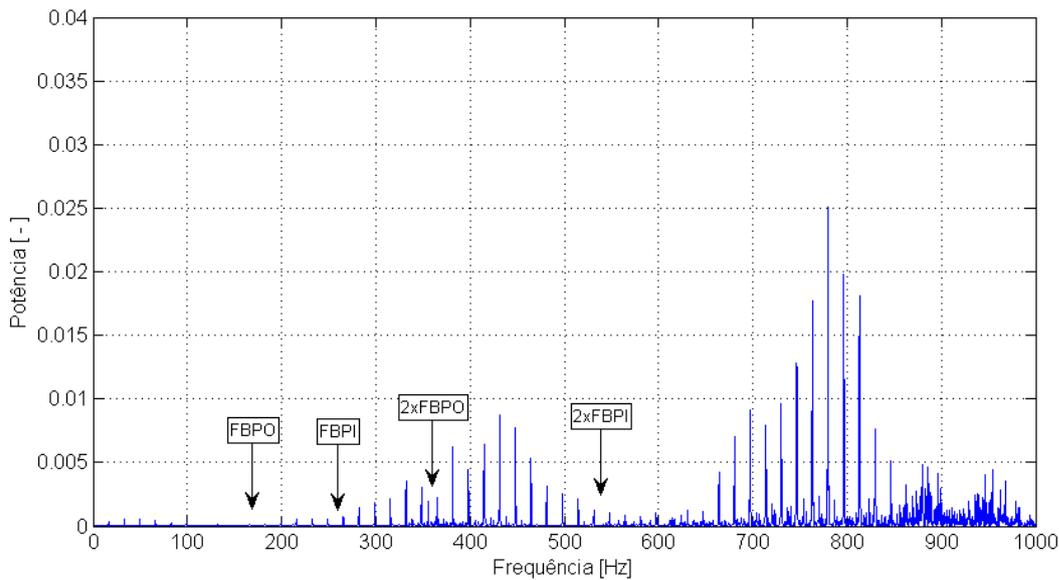


Figura 4.60: Espectro quadrático obtido pela *OELMD* (mancal com defeito na esfera).

Tabela 4.5: Amplitudes às frequências características de defeito (*OELMD*).

Tipo de defeito	Potência (amplitude de envelope quadrático) [ - ]			
	$A_{FBPO}$ 178,0 Hz	$A_{FBPI}$ 269,7 Hz	$A_{2x FBPO}$ 356,0 Hz	$A_{2x FBPI}$ 539,4 Hz
Sem defeito (novo)	0,000028	0,0000076	0,00001	0,0000036
Defeito na pista externa	0,000260	0,0009500	0,00061	0,0001300
Defeito na pista interna	0,000160	0,0006400	0,00031	0,0000290
Defeito no elemento rolante	0,004300	0,0012000	0,02930	0,0046000

Após a completa caracterização dos métodos de tratamento, é estabelecido na seção seguinte o sistema especialista que servirá de meio padronizado para comparação dos diagnósticos gerados pelos mesmos.

### 4.3 Sistema especialista

O sistema especialista desenvolvido para este trabalho utilizará testes lógicos similares àqueles postulados por Boumahdi *et al.* (2010), admitindo a incorporação dos atributos discutidos no Capítulo 2 para torna-lo capaz de diferenciar os defeitos existentes nos elementos rolantes.

Adrede a sua descrição, são apresentados na Tabela 4.6 os valores médios dos indicadores estatísticos previamente estabelecidos, os quais foram calculados para cada uma

das condições analisadas através das equações 2.33, 2.34 e 2.35, considerando um erro padrão para uma distribuição de *Student* bicaudal com nível de confiança de 99,9% e população de 10 amostras.

Tabela 4.6: Indicadores estatísticos dos sinais.

Condição do mancal	Indicadores estatísticos		
	Valor eficaz [ $m/s^2$ RMS]	Curtose [-]	Fator de crista [-]
Sem defeito (novo)	2,71±0,04	3,33±0,09	4,13±0,44
Defeito na pista externa	2,26±0,07	5,06±0,15	3,84±0,23
Defeito na pista interna	2,47±0,05	4,34±0,08	4,54±0,27
Defeito no elemento rolante	4,87±0,25	3,99±0,48	5,33±0,51

Com base nos corolários estabelecidos no Capítulo 2 e valores acima, projetou-se a árvore de decisão mostrada na Figura 4.61, a qual servirá de alicerce para o sistema especialista desenvolvido neste trabalho.

O valor do atributo do primeiro teste foi determinado a partir do limite inferior do fator de crista obtido para um mancal com defeito no elemento rolante. Já os valores dos atributos dos segundo e quarto testes foram determinados com base nos limites superior e inferior das curtoses calculadas para um mancal sem defeito e com defeito na pista externa, respectivamente.

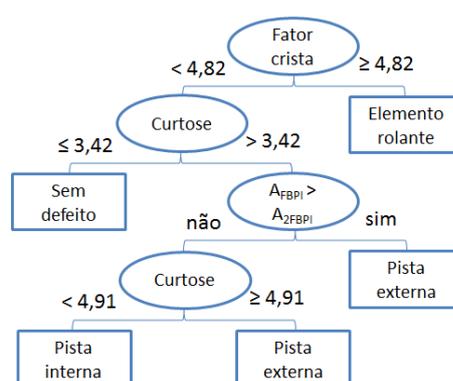


Figura 4.61: Árvore de decisão proposta.

Analogamente ao trabalho de Boumahdi *et al.* (2010), as saídas do algoritmo serão armazenadas em uma matriz de confusão, como a ilustrada no Quadro 4.18, que irá contabilizar, a partir das classes de entradas conhecidas,  $i$ , o número de amostras defeituosas dentro de um conjunto de respostas possíveis. No entanto, diferentemente dos autores, não será considerada a possibilidade de defeitos múltiplos.

Quadro 4.18: Matriz de confusão utilizada para a quantificação de diagnósticos.

Classes de entrada (i)	Respostas possíveis (colunas)			
	1	2	3	4
1-Sem defeito				
2-Defeito na pista externa				
3-Defeito na pista interna				
4-Defeito no elemento rolante				

Uma vez estabelecida a árvore de decisão, os valores padrões para os atributos de teste e o método de armazenamento das respostas, é possível operacionalizar o sistema especialista sob a forma do algoritmo apresentado no Quadro 4.19.

Quadro 4.19: Algoritmo do sistema especialista.

```
function [mat] = especialista(curtose, fatorcrista, afbpi, a2fbpi, fs, i);

mat = zeros(4,4);
if fatorcrista >= 4.82
    mat(i,4) = 1;
end
if cf < 4.77
    if curtose <= 3.42
        mat(i,1) = 1;
    end
    if curtose > 3.42
        if afbpi >= a2fbpi
            mat(i,3) = 1;
        end
        if afbpi < a2fbpi
            if curtose < 4.91
                mat(i,3) = 1;
            end
            if curtose >= 4.91
                mat(i,2) = 1;
            end
        end
    end
end
end
end
```

Este sistema especialista foi submetido a um teste de exaustão em um algoritmo genético com população de um milhão de indivíduos para a verificação de sua completude, tendo alcançado respostas válidas para todas as combinações possíveis de entrada. O mesmo teste assegurou, ainda, a consistência do sistema especialista pelo fato de produzir respostas únicas independentemente das combinações de entrada. A população de teste também não contempla a existência de indivíduos com múltiplos defeitos, do mesmo modo que o algoritmo testado.

Após a completa caracterização dos métodos de diagnóstico e a validação do sistema especialista, serão apresentados, no capítulo seguinte, os resultados alcançados através da metodologia proposta.



# Capítulo 5

## Resultados e Discussões

Como enunciado no Capítulo 1, os métodos de tratamento escolhidos para este comparativo serão avaliados quanto à capacidade de diagnosticar assertivamente mancais de rolamento expostos a diferentes tipos de dano. Contudo, tal apreciação somente é possível após a discussão da qualidade dos dados produzidos experimentalmente, cujos indicadores estatísticos são apresentados na Figura 5.1.

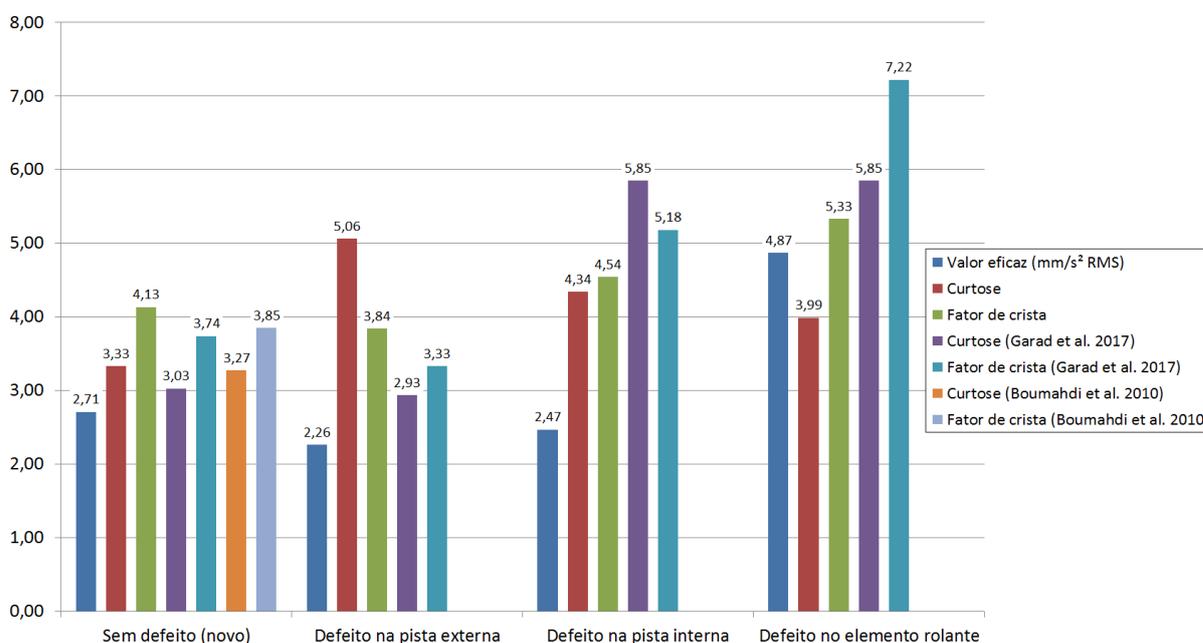


Figura 5.1: Comparação entre os indicadores estatísticos dos sinais.

Do gráfico apresentado depreendem-se quatro importantes resultados: o primeiro, que o fator de crista calculado na direção radial para a condição de mancal com dano no elemento rolante, de 5,33, supera os valores obtidos para os demais defeitos, confirmando as observações de Garad *et al.* (2017).

O segundo, que os valores médios de curtose e fator de crista calculados a partir dos dados coletados na direção radial para um mancal sem defeito, de 3,33 e 4,13,

respectivamente, estão em perfeita concordância com aqueles obtidos por Garad *et al.* (2017), de 3,03 e 3,74, respectivamente, e Boumahdi *et al.* (2010), de 3,27 e 3,85, respectivamente.

O terceiro, que houve um aumento de aproximadamente 52% no valor da curtose para o rolamento com dano na pista externa em relação àquele sem defeito, contrariando a característica de insensibilidade atribuída a este parâmetro por Garad *et al.* (2017).

O quarto, e último, que o fator de crista obtido experimentalmente, de 3,84, é, de fato, insensível aos defeitos na pista externa, como estabelecido por Garad *et al.* (2017).

Não foi possível comparar os resultados obtidos nos mancais danificados com aqueles de Boumahdi *et al.* (2010), pois os valores de curtose e fator de crista apresentados pelos autores referem-se apenas à condição de mancal sem defeito (novo).

Em virtude da elevada aderência dos valores obtidos quando comparados aos encontrados na literatura, fruto do rigor empregado na coleta dos dados, é possível atestar a consistência das informações. Sendo assim, estender-se-á a análise aos sinais no domínio do tempo e espectros produzidos pelos métodos comparados.

Como sabido, segundo o teorema de Wold todo sinal de um processo estocástico pode ser separado em duas parcelas: uma determinística, e sem interesse para fins de diagnóstico, e outra aleatória, cujo conteúdo, previamente sobrepujado pela porção de maior intensidade, pode revelar informações contundentes. No método de envelopamento tradicional este fragmento de maior importância é obtido por meio de filtragens sequenciais. Por outro lado, nos métodos da *LMD* e *OELMD* este mesmo fragmento é exposto através da decomposição contínua dos sinais em funções produto, as quais, basicamente, representam os modos vibracionais que os compõem. Notoriamente, ao menos um modo de vibrar representará a parcela determinística do sinal decomposto. Logo, os demais ora representarão um ruído puro, e sem fins práticos, ora o conteúdo de maior relevância propriamente dito.

### **5.1.1 Análise dos sinais no domínio do tempo**

Isto posto, a análise dos sinais produzidos pelos métodos sobreditos permitirá classificá-los quanto à seletividade. No caso dos sinais processados a partir de um mancal sem defeito, cujas amostras são vistas na Figura 5.2 justapostas ao sinal original, não foram recuperadas informações relevantes. Tal constatação, todavia, não causa estranheza, pois, em se tratando de componente novo não é esperado o aparecimento de processos impulsivos. Ademais, verifica-se no sinal resultante do envelopamento tradicional a existência de amplitudes muito inferiores às do sinal original, as quais podem ser atribuídas ao filtro *TSA* empregado em seu processamento.

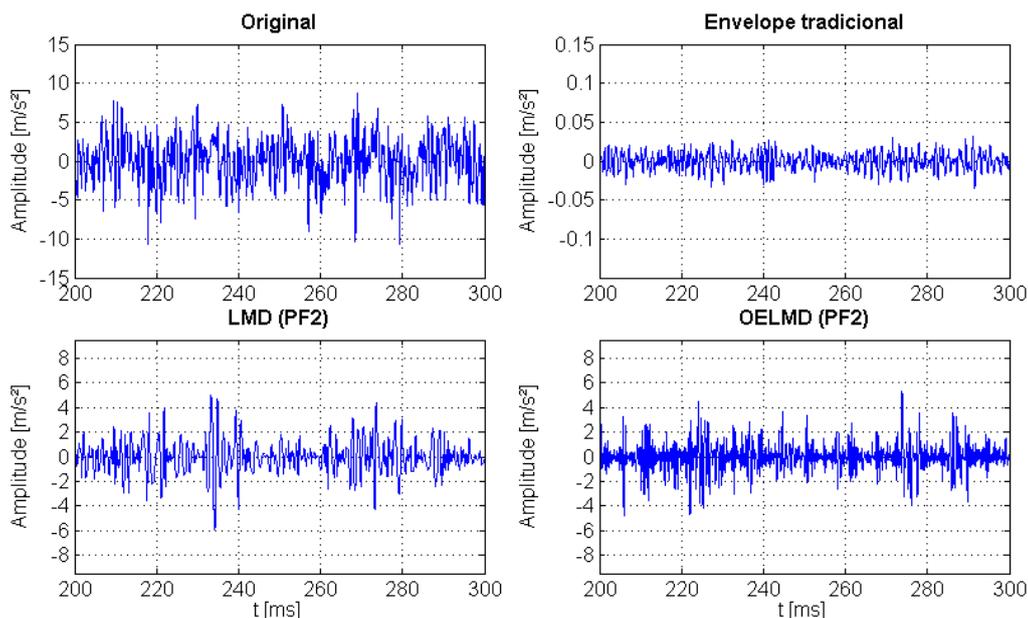


Figura 5.2: Sinais produzidos pelos diferentes métodos (mancal sem defeito).

Diferentemente da situação anterior, os sinais processados para a condição de mancal com dano na pista externa, ilustrados em amostras únicas na Figura 5.3, expuseram informações de maior relevância. Após o tratamento, todos os métodos foram capazes de revelar a frequência de repetição dos pulsos de choque, de período aproximado de 20 ms. Por motivo análogo ao caso do mancal sem defeito, novamente houve uma grande redução das amplitudes do sinal produzido pelo método de envelopamento tradicional. Ademais, é possível identificar uma elevada semelhança visual entre os sinais original e aquele produzido pelo método *LMD*, causada pela mistura de modos inerente a este processo. Esta condição, sem embargo, não é observada no sinal decorrente da *OELMD*, que, por sua vez, promoveu a melhor separação do sinal.

Dos sinais produzidos a partir de um mancal com dano na pista interna, vistos na Figura 5.4, apenas aquele proveniente do método *OELMD* foi capaz de apontar claramente a frequência de repetição. Observa-se, também, uma grande redução de amplitudes em todos os métodos.

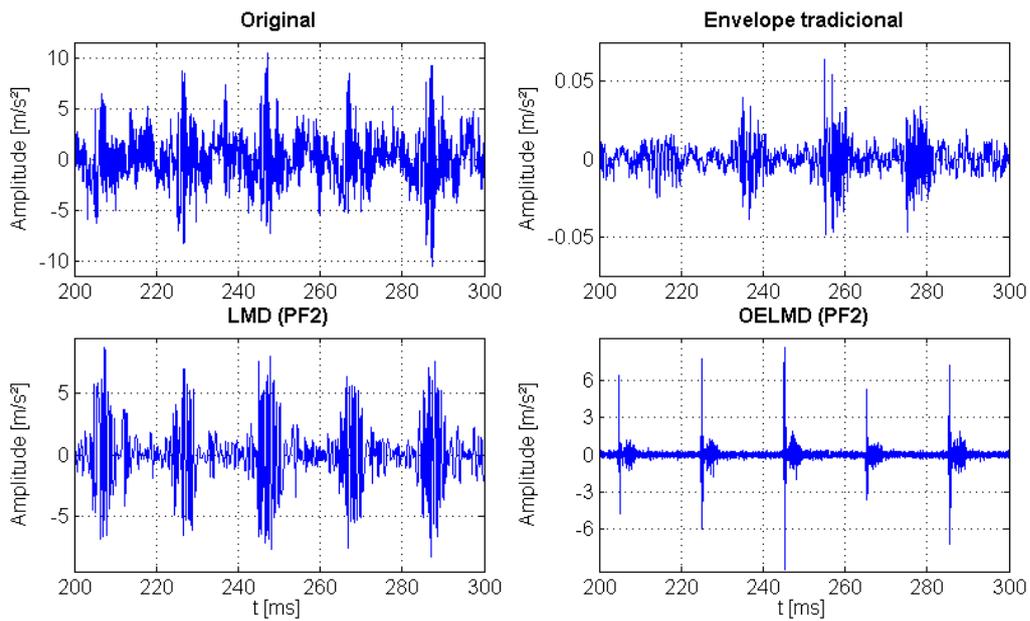


Figura 5.3: Sinais produzidos pelos diferentes métodos (defeito na pista externa).

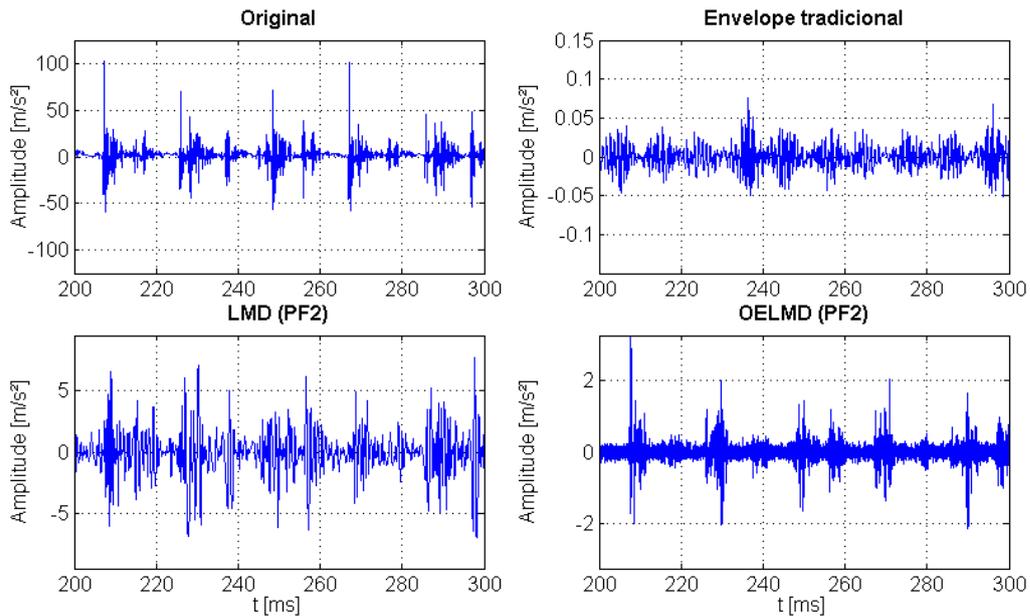


Figura 5.4: Sinais produzidos pelos diferentes métodos (defeito na pista interna).

Não obstante, nenhum dos métodos foi capaz de revelar claramente a modulação à frequência da gaiola prevista por Randall e Antoni (2010) para o caso do mancal com dano no elemento rolante, como visto na Figura 5.5. Uma vez mais o método *OELMD* superou os demais quanto à capacidade de separação do sinal.

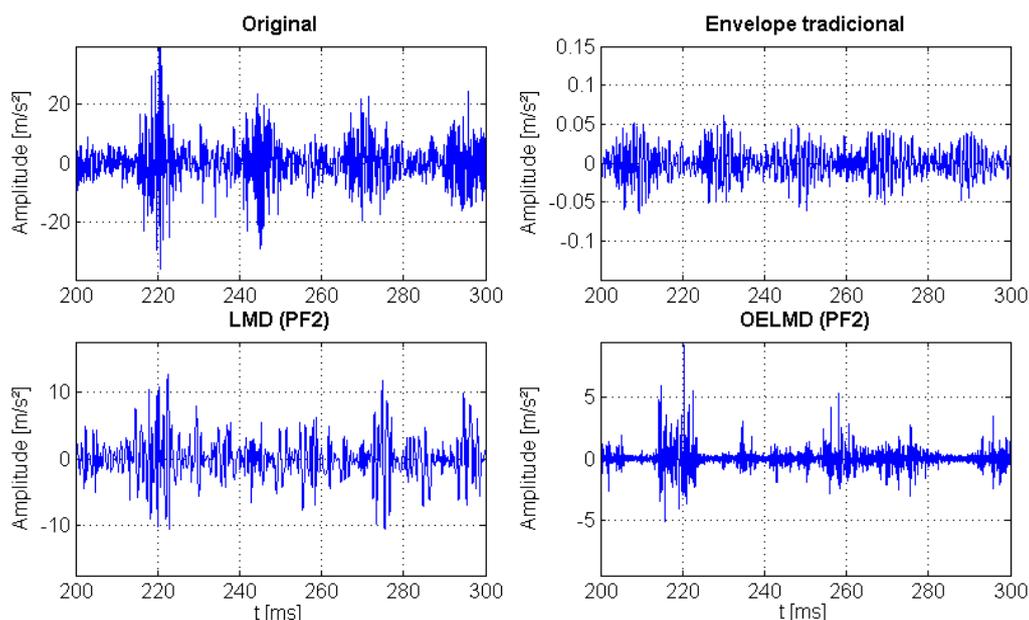


Figura 5.5: Sinais produzidos pelos diferentes métodos (elemento rolante).

### 5.1.2 Análise dos sinais no domínio da frequência

De acordo com Scheffer e Girdhar (2004), mancais de rolamento classificados no terceiro estágio de degradação, como os observados neste trabalho, possuem espectros com elevadas amplitudes às frequências características de defeito, as quais podem ou não serem ladeadas por bandas moduladoras. Sendo assim, a análise das respostas em frequência dos sinais produzidos pelos métodos permitirá elencar aqueles com maior potencial de diagnóstico.

Com este intuito, são apresentados na Figura 5.6 os espectros quadráticos calculados a partir dos sinais de um mancal com defeito na pista externa processados pelos métodos comparados, dos quais se verificam os seguintes resultados:

- A frequência característica de dano na pista externa, de 178,0 Hz, é visível no espectro calculado com base no sinal sem processamento. Não há modulação;
- O espectro calculado a partir do sinal processado pela *LMD* assemelha-se, em conteúdo, àquele obtido do sinal sem processamento, confirmando novamente a mistura de modos. A frequência característica de defeito não é visível;
- Presença da frequência fundamental de defeito e harmônicos no espectro fornecido pelo envelope tradicional, sem bandas laterais. Verifica-se, também, a existência de uma grande amplitude à frequência de 89,41 Hz, equivalente à metade da frequência característica de defeito;
- Diversos picos em frequências múltiplas de 13 Hz no espectro da *OELMD*, sem correlação aparente com o defeito analisado.

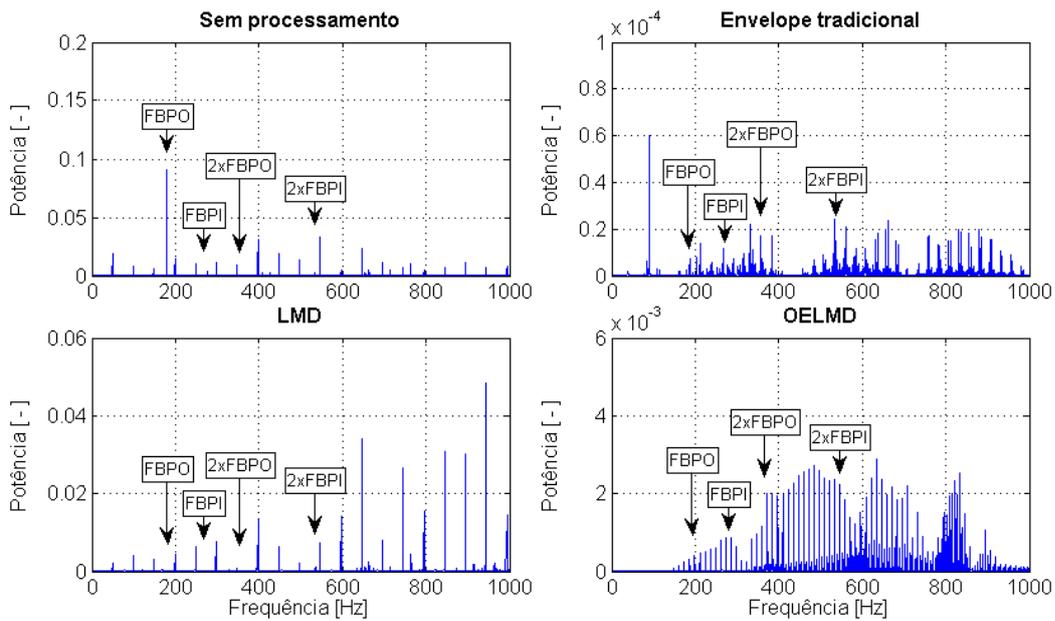


Figura 5.6: Comparação dos espectros produzidos para defeito na pista externa.

A mesma discussão é feita para os espectros gerados pelos sinais coletados no mancal com a pista interna danificada, vistos na Figura 5.7, culminando com os resultados abaixo listados:

- O primeiro harmônico da frequência característica de defeito e as bandas laterais são visíveis no espectro calculado diretamente do sinal não processado;
- O mesmo ocorre para o espectro produzido pelo envelope tradicional, que ainda revelou a frequência característica de defeito;
- A *LMD* novamente forneceu um espectro visualmente similar àquele do sinal sem processamento. Ademais, não permitiu associar os picos encontrados ao defeito analisado;
- A *OELMD* foi muito eficaz na identificação do defeito, pois, além de revelar claramente o pico harmônico da frequência característica, eliminou todos aqueles não correlacionados ao dano. A modulação esperada não é visível.

Por fim, analisar-se-ão, sob o mesmo ponto de vista, os espectros mostrados na Figura 5.8, os quais foram produzidos pelos diferentes métodos a partir dos sinais coletados para o mancal com dano no elemento rolante.

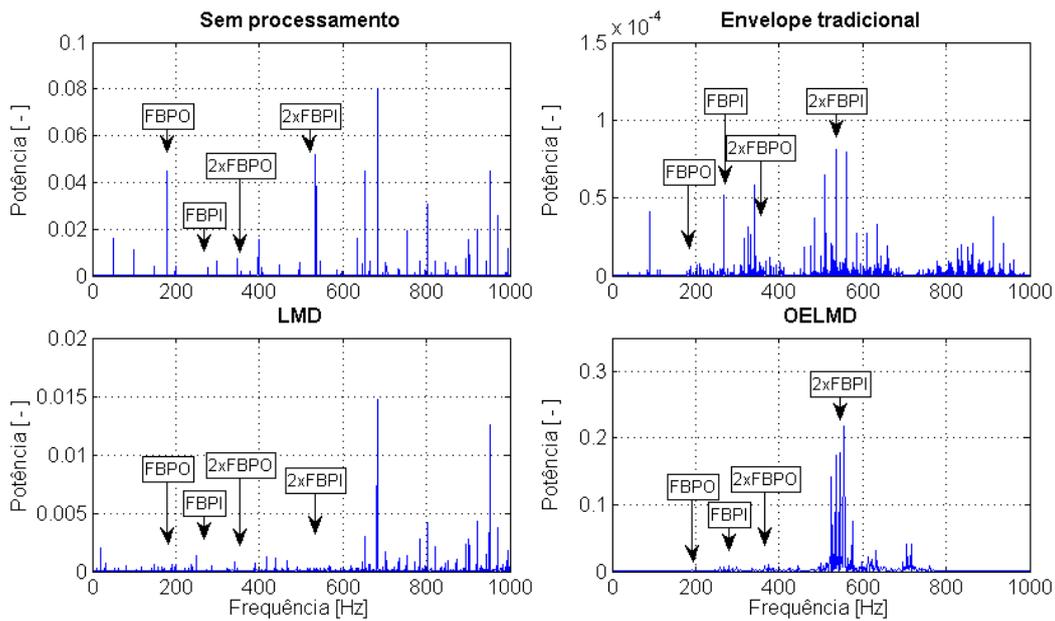


Figura 5.7: Comparação dos espectros produzidos para defeito na pista interna.

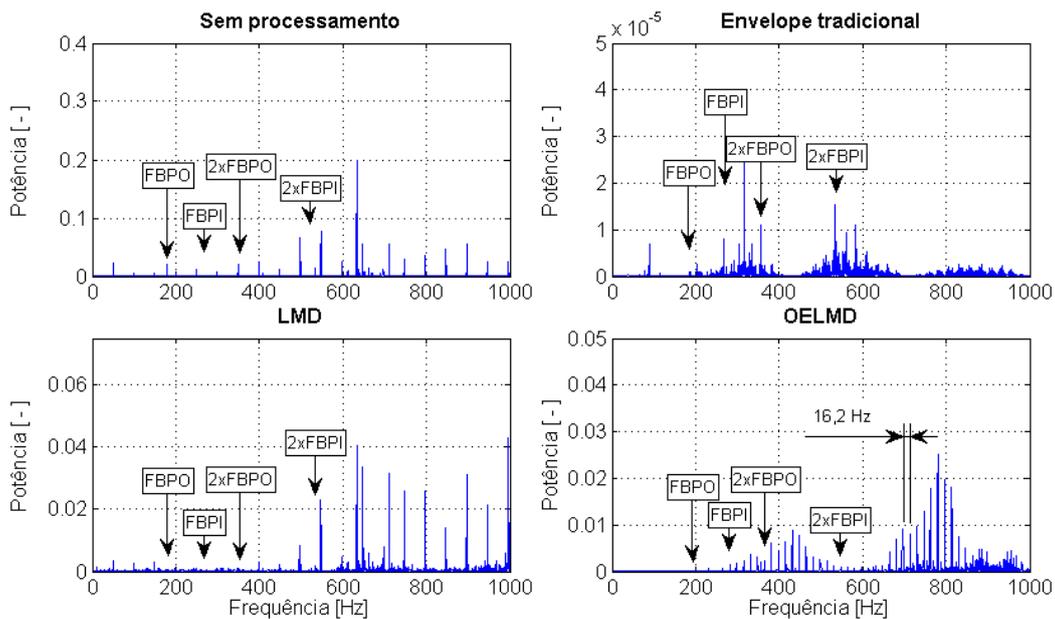


Figura 5.8: Comparação dos espectros produzidos para defeito no elemento rolante.

Como visto, o método da *LMD* não foi capaz de detectar amplitudes à frequência característica de defeito e harmônicas, assim como no caso do espectro obtido a partir do sinal não processado. Em contrapartida, o método do envelope tradicional mostrou pequenas amplitudes nestas frequências, contudo, a modulação prevista não foi detectada.

A *OELMD*, por sua vez, além de mostrar a primeira e segunda harmônicas da frequência característica de defeito, trouxe à tona a frequência de modulação de 16,2 Hz.

### 5.1.3 Avaliação da capacidade de diagnóstico

A última, e principal característica que será avaliada, é a capacidade de diagnóstico de defeitos dos métodos apresentados quando submetidos ao sistema especialista proposto. Por conseguinte, todos os sinais coletados foram oferecidos a esta análise, sendo os resultados obtidos pelos métodos do envelopamento tradicional, decomposições *LMD* e *OELMD* apresentados nas matrizes de confusão dos Quadros 5.1, 5.2 e 5.3, respectivamente. Para fins de comparação são apresentados no Quadro 5.4 os resultados obtidos diretamente dos sinais não processados, cujas amplitudes de vibração às frequências características de defeito foram extraídas do espectro quadrático de acordo com a equação 2.29.

Quadro 5.1: Número de amostras diagnosticadas pelo método de envelopamento.

Classes de entrada	Respostas possíveis (colunas)			
	1	2	3	4
<i>1-Sem defeito</i>	10	0	0	0
<i>2-Defeito na pista externa</i>	0	10	0	0
<i>3-Defeito na pista interna</i>	0	0	10	0
<i>4-Defeito no elemento rolante</i>	0	0	0	10

Quadro 5.2: Número de amostras diagnosticadas pelo método de decomposição LMD.

Classes de entrada	Respostas possíveis (colunas)			
	1	2	3	4
<i>1-Sem defeito</i>	10	0	0	0
<i>2-Defeito na pista externa</i>	0	10	0	0
<i>3-Defeito na pista interna</i>	0	0	10	0
<i>4-Defeito no elemento rolante</i>	0	0	0	10

Quadro 5.3: Número de amostras diagnosticadas pelo método de decomposição OELMD.

Classes de entrada	Respostas possíveis (colunas)			
	1	2	3	4
<i>1-Sem defeito</i>	10	0	0	0
<i>2-Defeito na pista externa</i>	0	10	0	0
<i>3-Defeito na pista interna</i>	0	0	10	0
<i>4-Defeito no elemento rolante</i>	0	0	0	10

Quadro 5.4: Número de amostras diagnosticas a partir dos sinais sem processamento.

Classes de entrada	Respostas possíveis (colunas)			
	1	2	3	4
1-Sem defeito	0	0	10	0
2-Defeito na pista externa	0	5	5	0
3-Defeito na pista interna	0	1	9	0
4-Defeito no elemento rolante	0	3	7	0

Para facilitar a visualização dos resultados, as informações constantes nos Quadros 5.1 a 5.4 foram agrupadas em um único gráfico, mostrado a seguir na Figura 5.9.

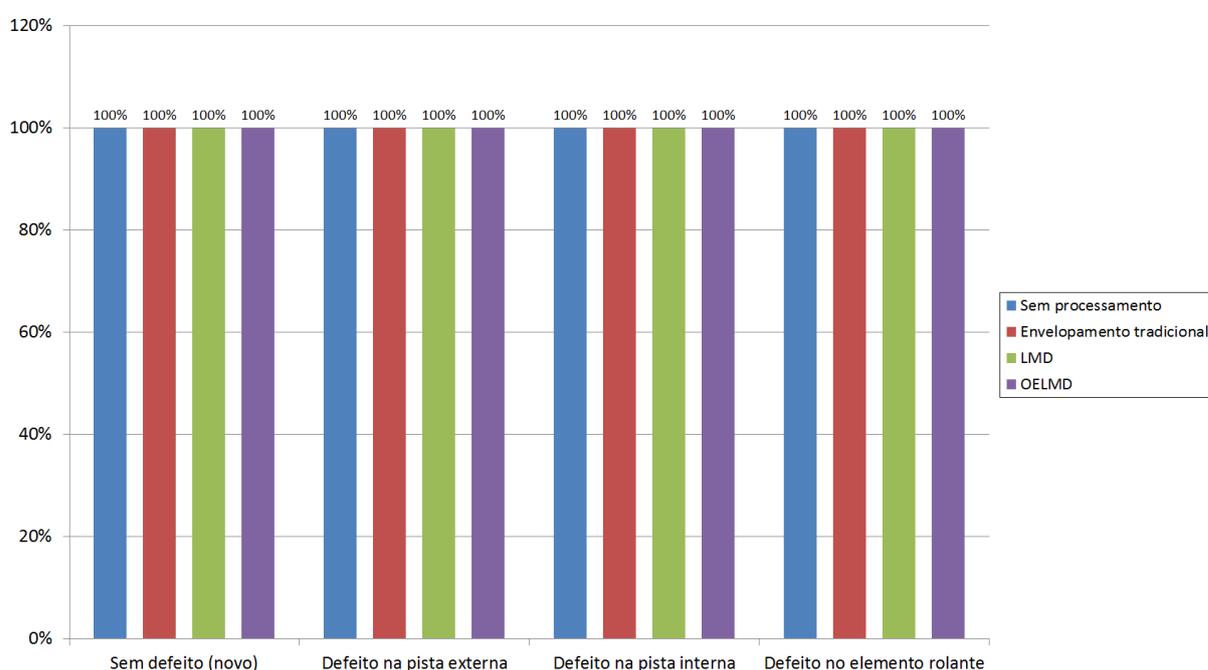


Figura 5.9: Índice de acertos dos métodos submetidos ao sistema especialista proposto.

Devido à elevada severidade dos danos aplicados, evidenciada pelos valores assumidos pelos indicadores estatísticos, o sistema especialista proposto foi capaz de diagnosticar prontamente os mancais isentos de defeito e aqueles com dano no elemento rolante. Por este motivo, coube aos métodos comparados unicamente a diferenciação dos defeitos existentes nas pistas interna e externa. Não obstante, igual índice de acertos foi apontado para estas outras duas condições em todos os métodos testados, confirmando a capacidade de diagnóstico dos mesmos. Conquanto, cabe ressaltar a excepcional diferença de consumo computacional requerido, visto que a decomposição *OELMD* exigiu um tempo médio de 2 horas e 42 minutos, aproximadamente 320 vezes superior à decomposição *LMD*, que, por sua vez, necessitou de apenas 30,33 s em média. O envolvimento tradicional apresentou um tempo médio de processamento ligeiramente menor que o referido, de 24,54 s, desprezando-se, obviamente, o requisito da fase de parametrização. O sistema especialista,

por outro lado, utilizou em média 24 ms de processamento, independentemente do método previamente empregado.

Finda a apresentação dos resultados alcançados por meio da metodologia proposta, serão proferidas na sequência as respectivas conclusões acerca do tema.

# Capítulo 6

## Conclusão

Este trabalho procurou comparar as respostas fornecidas por duas abordagens distintas de tratamento de sinais quando empregadas para fins de diagnóstico de defeitos em mancais de rolamento, sendo uma baseada no método de envelopamento tradicional e outra na decomposição média local, *LMD*. A primeira, profundamente discutida por diversos autores e de reconhecida eficácia, data da década de 1970, enquanto a segunda, cujas aplicações práticas são averiguadas até o presente momento, foi divulgada apenas em 2005. Devido à relevância e destaque nas recentes publicações, a versão otimizada da decomposição média local, denominada *OELMD*, também foi posta à prova. Visando conferir maior credibilidade ao estudo realizado, foram utilizados sinais reais de vibração coletados em uma bancada de teste composta por um motor elétrico de indução, eixo, mancais de rolamento radiais de esfera modelo 6004 e demais instrumentos de controle e aquisição.

A extensa revisão da literatura permitiu tanto o delineamento do estado da arte dentre a ampla gama de opções, bem como proporcionou a transcrição dos algoritmos originais dos métodos comparados para a linguagem de programação escolhida. Outrossim, todos os parâmetros evocados pelos mesmos foram apresentados e selecionados mediante o emprego de critérios ali fundamentados.

Em se tratando do método de envelopamento tradicional, a separação da porção determinística do sinal, correspondente ao próprio movimento de rotação do eixo, foi feita através da técnica *TSA* por efeito de um filtro pente de resposta ao impulso infinita. A banda de demodulação foi escolhida com base no curtograma gerado para uma janela com comprimento de 32 amostras e utilizada para a geração do espectro de potência por meio da transformada de Hilbert, cujas amplitudes às frequências características de defeito foram posteriormente apreciadas pelo sistema especialista. Foi dispensada a amplificação do sinal pela *MED* devido à redução imposta pela mesma aos valores de curtose. No caso dos métodos de decomposição *LMD* e *OELMD* a separação da parcela determinística do sinal não foi necessária, uma vez que o espectro desejado foi calculado com base apenas na função produto de maior impulsividade.

No que diz respeito à capacidade de diagnóstico, pode-se afirmar que todos os métodos comparados obtiveram êxito na caracterização de defeitos enquanto associados ao sistema especialista proposto, contudo, o elevado consumo computacional exigido pela decomposição

*OELMD* a torna inviável para aplicações em tempo real. Os métodos de envelopamento tradicional e da decomposição *LMD* tiveram igual assertividade em condições análogas, contudo, a dependência de um especialista para a seleção dos parâmetros ideais à primeira restringe sua utilização em ambientes com carência de profissionais experientes.

Com relação à qualidade dos sinais tratados, conclui-se que a decomposição *OELMD* superou às demais em função do elevado nível de limpeza e menor redução de amplitudes oferecida, sendo a única a revelar claramente a frequência de repetição dos picos de choque em todas as situações. O envelopamento tradicional também forneceu resultados satisfatórios, no entanto, a atenuação do sinal provocada pela sequência de filtragens exigida pelo método pode conduzir a interpretações errôneas dos resultados. É necessário frisar que as funções produto fornecidas pela *OELMD* são morfologicamente semelhantes aos sinais oriundos do envelopamento tradicional.

Do ponto de vista dos espectros gerados pelos métodos, é factível inferir a superioridade do envelopamento tradicional em detrimento à *OELMD* em função do conteúdo de frequências e modulação reveladas. A demasiada seletividade desta última ocultou parte das frequências de interesse, as quais, no entanto, poderiam ser trazidas à tona através da avaliação dos espectros produzidos pelas demais funções produto mediante, obviamente, o aumento do tempo de processamento. Além disso, a resposta produzida para o caso do mancal com defeito na pista externa não permitiu estabelecer uma correlação clara entre as frequências de 13 Hz, e harmônicas, e o dano avaliado. A mistura de modos causada pela decomposição *LMD*, confirmada pela evidente semelhança visual entre seus espectros e aqueles advindos diretamente do sinal não processado, inviabiliza sua utilização para o tratamento de sinais altamente modulados e complexos.

Como conclusão admite-se a inexistência de um método ideal dentre os explorados, uma vez que ora dependem de exaustiva parametrização, como no caso do envelopamento tradicional, ora demandam um proibitivo consumo computacional, no caso da *OELMD*. Por outro lado, pelos motivos expostos fica confirmada a incapacidade da *LMD* em lidar com sinais como aqueles observados em mancais de rolamento danificados.

Por fim, é afastada a hipótese da completa dispensa da figura do analista enquanto perdurar o equilíbrio entre o tempo disponível ao processamento e o pleno êxito nos diagnósticos.

Sugerem-se os seguintes tópicos como opções para trabalhos futuros:

- a) Emprego de uma ferramenta de eletro-erosão capaz de implantar danos com dimensões controladas e gradativas. Desta forma, poder-se-á avaliar o potencial dos métodos quando aplicados a sinais de mancais com níveis distintos de degradação;
- b) Montagem de um freio dinamométrico, ou outro dispositivo equivalente, para a aplicação de carga sobre os mancais;
- c) Empregar métodos de processamento paralelo para ampliar os estudos acerca da *OELMD*;

- d) Investigação da faixa de frequências entre 1 e 4 kHz com relação à detecção e ao diagnóstico de defeitos;
- e) Discussão dos efeitos da transmissibilidade das caixas de montagem dos mancais.



# Referências Bibliográficas

- Abbasion, S., Rafsanjania, A., Farshidianfarb, A. & Iranic, N. (2007). Rolling element bearings multi-fault classification based on the wavelet denoising and support vector machine, *Mechanical Systems and Signal Processing* 21(3): 2933–2945.
- Antoni, J. & Randall, R. B. (2004). Unsupervised noise cancellation for vibration signals: part I – evaluation of adaptive algorithms, *Mechanical Systems and Signal Processing* 18(2004): 89–101.
- Antoni, J. & Randall, R. B. (2005). On the use of the cyclic power spectrum in rolling element bearings diagnostics, *Journal of Sound and Vibration* 281(2005): 463–468.
- Antoni, J. (2007). Cyclic spectral analysis of rolling-element bearing signals: Facts and fictions, *Journal of Sound and Vibration* 304(29): 497–529.
- Antoni, J., Daniere, J. & Guillet, F. (2002). Effective vibration analysis of ic engines using cyclostationarity. part i - a methodology for condition monitoring, *Journal of Sound and Vibration* 257(5): 815–837.
- Antoniadis, I. & Glossiotis, G. (2001). Cyclostationary analysis of rolling-element bearing vibration signals, *Journal of Sound and Vibration* 248(5): 829–845.
- Bai, M., Huang, J., Hong, M. & Su, F. (2005). Fault diagnosis of rotating machinery using an intelligent order tracking system, *Journal of Sound and Vibration* 280(36): 699–718.
- Barszcz, T. (2009). Decomposition of vibration signals into deterministic and nondeterministic components and its capabilities of fault detection and identification, *International Journal of Applied Mathematics and Computer Science* 19(2): 327–335.
- Boumahdi, M., Dron, J., Rechak, S. & Cousinard, O. (2010). On the extraction of rules in the identification of bearing defects in rotating machinery using decision tree, *Expert Systems With Applications* 37(1): 5887–5894.
- Braun, S. (2011). The synchronous (timedomain) average revisited, *Mechanical Systems and Signal Processing* 25(07): 1087–1102.
- Cempel, C. (1980). Diagnostically oriented measures of vibroacoustical processes, *Journal of Sound and Vibration* 73(4): 547–561.
- Cempel, C. (1988). Vibroacoustical diagnostics of machinery: An outline, *Journal of Sound and Vibration* 2(2): 135–151.
- Chaturvedi, G. K. & Thomas, D. W. (1981). Adaptive noise cancelling and condition

- monitoring, *Journal of Sound and Vibration* 76(3): 391–405.
- Chen, G., Liu, F. & Huang, W. (2017). Sparse discriminant manifold projections for bearing fault diagnosis, *Journal of Sound and Vibration* 399(2): 330–344.
- Cui, L., Gong, X., Zhang, J. & Wang, H. (2016). Double-dictionary matching pursuit for fault extent evaluation of rolling bearing based on the lempel-ziv complexity, *Journal of Sound and Vibration* 385(2): 372–388.
- Cui, L., Wang, J. & Lee, S. (2014). Matching pursuit of an adaptive impulse dictionary for bearing fault diagnosis, *Journal of Sound and Vibration* 333(2): 2840–2862.
- Ding, X., He, Q. & Luo, N. (2015). A fusion feature and its improvement based on locality preserving projections for rolling element bearing fault classification, *Journal of Sound and Vibration* 335(2): 367–383.
- Diniz, P.; da Silva, E.; Netto, S. L. (2014). *Processamento Digital de Sinais: Projeto e Análise de Sistemas*: Bookman Editora.
- Dong, G., Chen, J. & Zhao, F. (2015). A frequency-shifted bispectrum for rolling element bearing diagnosis, *Journal of Sound and Vibration* 339(2): 396–418.
- Dowson, D. & Hamrock, B. J. (1981). *History of ball bearings*, Nasa Technical Memorandum 81689.
- Ebersbach, S. & Peng, Z. (2008). Expert system development for vibration analysis in machine condition monitoring, *Expert Systems With Applications* 34(1): 291–299.
- Elbhah, K. & Sinha, J. K. (2013). Vibration-based condition monitoring of rotating machines using a machine composite spectrum, *Journal of Sound and Vibration* 332(2): 2831–2845.
- Garad, A., Sutar, K. B., Shinde, V. J. & Pawar, A. C. (2017). Analysis of vibration signals of rolling element bearing with localized defects, *International Journal of Current Engineering and Technology* 7(1): 37-42.
- Guo, W. & Tse, P. W. (2013). A novel signal compression method based on optimal ensemble empirical mode decomposition for bearing vibration signals, *Journal of Sound and Vibration* 332(2): 423–441.
- Guo, Y., Liu, T. W., Na, J. & Fung, R. F. (2012). Envelope order tracking for fault detection in rolling element bearings, *Journal of Sound and Vibration* 331(2): 5644–5654.
- Harris, T. A. (2001). *Rolling bearing analysis*. John Wiley and sons.
- Hao, R. & Chu, F. (2009). Morphological undecimated wavelet decomposition for fault diagnostics of rolling element bearings, *Journal of Sound and Vibration* 320(14): 1164–1177.
- Ho, D. & Randall, R. B. (1997). Effects of time delay, order of fir filter and convergence factor on self-adaptive noise cancellation, *Fifth International Congress on Sound and*

Vibration, Adelaide, Austrália.

- Hong, H. & Liang, M. (2009). Fault severity assessment for rolling element bearings using the Lempel-ziv complexity and continuous wavelet transform, *Journal of Sound and Vibration* 320(14): 452–468.
- Janjarasjitt, S., Ocak, H. & Loparo, K. (2008). Bearing condition diagnosis and prognosis using applied nonlinear dynamical analysis of machine vibration signal, *Journal of Sound and Vibration* 317(2): 112–126.
- Jiang, F., Zhu, Z., Li, W., Zhou, G. & GuoanChen (2014). Fault identification of rotor-bearing system based on ensemble empirical mode decomposition and self-zerospace projection analysis, *Journal of Sound and Vibration* 333(2): 3321–3331.
- Kar, C. & Mohanty, A. R. (2004). Application of ks test in ball bearing fault diagnosis, *Journal of Sound and Vibration* 269(2): 439–454.
- Kistler. (2015). Impulse force hammer; extended high force range, PUB 9728A\_000-275e-06.15.
- Lee, J. M., Kim, S. J., Hwang, Y. & Song, C. S. (2004). Diagnosis of mechanical fault signals using continuous hidden markov model, *Journal of Sound and Vibration* 276(21): 1065–1080.
- Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L. & Siegel, D. (2014). Prognostics and health management design for rotary machinery systems: reviews, methodology and applications, *Mechanical Systems and Signal Processing* .
- Li, C. & Liang, M. (2012). Continuous-scale mathematical morphology-based optimal scale band demodulation of impulsive feature for bearing defect diagnosis, *Journal of Sound and Vibration* 331(2): 5864–5879.
- Li, L. & Qu, L. (2003). Cyclic statistics in rolling bearing diagnosis, *Journal of Sound and Vibration* 267(20): 253–265.
- Li, Y., Liang, X., Liu, W. & Wang, Y. (2018). Development of a morphological convolution operator for bearing fault detection, *Journal of Sound and Vibration* 421(2): 220–233.
- Li, Y., Xu, M., Wang, R. & Huang, W. (2016). A fault diagnosis scheme for rolling bearing based on local mean decomposition and improved multiscale fuzzy entropy, *Journal of Sound and Vibration* 360(2): 277–299.
- Li, Z., He, Y., Chu, F., Han, J. & Hao, W. (2006). Fault recognition method for speed-up and speed-down process of rotating machinery based on independent component analysis and factorial hidden markov model, *Journal of Sound and Vibration* 291(21): 60–71.
- Liu, B. (2003). Adaptive harmonic wavelet transform with applications in vibration analysis, *Journal of Sound and Vibration* 262(21): 45–64.
- Liu, B. (2005). Selection of wavelet packet basis for rotating machinery fault diagnosis, *Journal of Sound and Vibration* 284(21): 567–582.

- Lu, S., Zhou, P., Wang, X., Liu, Y., Liu, F. & Zhao, J. (2018). Condition monitoring and fault diagnosis of motor bearings using undersampled vibration signals from a wireless sensor network, *Journal of Sound and Vibration* 414(2): 81–96.
- McFadden, P. D. (1986). A revised model for the extraction of periodic waveforms by time domain averaging, *Mechanical Systems and Signal Processing* 1(1): 83–95.
- McFadden, P. D. & Smith, J. D. (1984). Model for the vibration produced by a single point defect in a rolling element bearing, *Journal of Sound and Vibration* 96(1): 69–82.
- Mishra, C.; Samantaray, A. K. & Chakraborty. (2017). G. Rolling element bearing fault diagnosis under slow speed operation using wavelet de-noising, *Measurement* 103(1): 77–86.
- Monavar, H. M., Ahmadi, H. & Mohtasebi, S. S. (2008). Prediction of defects in roller bearings using vibration signal analysis. *World Applied Sciences Journal*, 4(1): 150–154.
- Ocak, H., Loparo, K. A. & Discenzo, F. M. (2007). Online tracking of bearing wear using wavelet packet decomposition and probabilistic modeling: A method for bearing prognostics, *Journal of Sound and Vibration* 302(21): 951–961.
- Peng, Z. K., Tse, P. W. & Chu, F. L. (2007). An improved Hilbert-huang transform and its application in vibration signal analysis, *Journal of Sound and Vibration* 286(21): 187–205.
- Qiu, H., Lee, J., Lin, J. & Yu, G. (2006). Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics, *Journal of Sound and Vibration* 289(21): 1066–1099.
- Rai, A. & Upadhyay, S. H. (2015). A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings, *Tribology International*.
- Randall, R. B. & Antoni, J. (2010). Rolling element bearing diagnostics - A tutorial, *Mechanical Systems and Signal Processing* 25(21): 485–520.
- Randall, R. B., Antoni, J. & Sawalhi, N. (2011). A comparison of methods for separation of deterministic and random signals, *The International Journal of Condition Monitoring* 1(1): 11–19.
- Samanta, B. & Al-Balushi, K. R. (2003). Artificial neural network based fault diagnostics of rolling element bearings using time-domain features, *Mechanical Systems and Signal Processing* 17(2): 317–328.
- Scheffer, C.; Girdhar, P. (2004). *Practical Machinery Vibration Analysis and Predictive Maintenance*. Oxford: Elsevier.
- Shao, Y. & Nezu, K. (2005). Design of mixture de-noising for detecting faulty bearing signals, *Journal of Sound and Vibration* 282(2): 899–917.
- Sheen, Y. T. (2004). A complex filter for vibration signal demodulation in bearing defect

- diagnosis, *Journal of Sound and Vibration* 276(2): 105–119.
- Sheen, Y. T. (2007). An analysis method for the vibration signal with amplitude modulation in a bearing system, *Journal of Sound and Vibration* 303(2): 538–552.
- Skf. (2018). SKF vibration sensors catalog, PUB CM/P1 11604/16 EN.
- Smith, J. S. (2005). The local mean decomposition and its application to eeg perception data, *Journal of the Royal Society Interface* 2(2): 443–454.
- Sreejith, B., Verma, A. K. & Srividya, A. (2008). Fault diagnosis of rolling element bearing using time-domain features and neural networks, *IEEE Region 10 Colloquium and the Third ICIIS, Kharagpur, INDIA* December 8-10.
- Sturm, A. & Kinsky, D. (1984). Diagnostics of rolling-element bearing condition by means of vibration monitoring under operating conditions, *Measurement* 2(2).
- Su, Y. T. & Lin, S. J. (1992). On initial fault detection of a tapered roller bearing: frequency and domain analysis, *Journal of Sound and Vibration* 155(1): 75-84.
- Suh, Y. & Murray, T. J. (1994). A tree-based approach for verifying completeness and consistency in rule-based systems, *Expert Systems With Applications* 7(2): 199-220.
- Tandon, N. & Choudhury, A. (1997). An analytical model for the prediction of the vibration response of rolling element bearings due to a localized, *Journal of Sound and Vibration* 205(3): 272–292.
- Tang, G., Wang, X., He, Y. & Liu, S. (2016). Rolling bearing fault diagnosis based on variational mode decomposition and permutation entropy, *13th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI), Xian, China*, pp. 626–631.
- Tang, G., Zhou, F. & Liaoi, X. (2016). Fault diagnosis for rolling bearing based on improved enhanced kurtogram method, *13th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI), Xian, China*, pp. 881–886.
- Wang, W., Golnaraghi, F. & Ismail, F. (2004). Condition monitoring of multistage printing presses, *Journal of Sound and Vibration* 270(2): 755–766.
- Wang, W., Golnaraghi, F. & Ismail, F. (2009). A demodulation method based on improved local mean decomposition and its application in rub-impact fault diagnosis, *Measurement Science and Technology* 20(2): 1–10.
- Wang, Y., He, Z. & Zi, Y. (2010). A comparative study on the local mean decomposition and empirical mode decomposition and their applications to rotating machinery health diagnosis, *Journal of Vibration and Acoustics* 132(2): 1–10.
- Xiao, Y. & Dong, Y. (2016). Local mean decomposition algorithm improved by decorrelation, *9th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), Datong, China*, pp. 1206–1210.
- Yang, W., Court, R., Tavner, P. J. & Crabtree, C. J. (2011). Bivariate empirical mode

decomposition and its contribution to wind turbine condition monitoring, *Journal of Sound and Vibration* 330(2): 3766–3782.

Yang, Y., Cheng, J. & Zhang, K. (2012). An ensemble local means decomposition method and its application to local rub-impact fault diagnosis of the rotor systems, *Measurement* 45(2): 561–570.

Yu, Y., Dejie, Y. & Junsheng, C. (2006). A roller bearing fault diagnosis method based on emd energy entropy and ann, *Journal of Sound and Vibration* 294(2): 269–277.

Zhan, Y. M. & Jardine, A. K. S. (2005). Adaptive autoregressive modeling of non-stationary vibration signals under distinct gear states. part 1: modeling, *Journal of Sound and Vibration* 286(2): 429–450.

Zhang, C., Li, Z., Hu, C., Chen, S., Wang, J. & Zhang, X. (2017). An optimized ensemble local mean decomposition method for fault detection of mechanical components, *Measurement Science and Technology* 28(3): 129–135.

Zhang, L. P., Liu, H. M. & Lu, C. (2016). Fault diagnosis technology of rolling bearing based on lmd and bp neural network, *Measurement Science and Technology* 28(2): 1–15.

Zhen, L., Zhengjia, H., Yanyang, Z. & Yanxue, W. (2008). Customized wavelet denoising using intra- and inter-scale dependency for bearing fault detection, *Journal of Sound and Vibration* 313(2): 342–359.

Žvokelj, M., Zupan, S. & Prebil, I. (2016). Eemd-based multiscale ica method for slewing bearing fault detection and diagnosis, *Journal of Sound and Vibration* .