

UNESP
Faculdade de Engenharia do Campus de Guaratinguetá

Guaratinguetá
2011

LUIS FERNANDO DE ALMEIDA

REDES NEURAIAS ARTIFICIAIS APLICADAS À MANUTENÇÃO BASEADA NA
CONDIÇÃO

Tese apresentada à Faculdade de Engenharia
do Campus de Guaratinguetá, Universidade
Estadual Paulista, para a obtenção do título
de Doutor em Engenharia Mecânica na área
de Projetos e Materiais.

Orientador: Prof. Dr. Mauro Hugo Mathias

Guaratinguetá

2011

A447r	Almeida, Luis Fernando de Redes neurais artificiais aplicadas à manutenção baseada na condição / Luis Fernando de Almeida - Guaratinguetá : [s.n.], 2011. 162 f. : il. Bibliografia: f. 138 Tese (doutorado) – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2011. Orientador: Prof. Dr. Mauro Hugo Mathias 1. Redes neurais (Computação) 2. Inteligência artificial I. Título CDU 681.3(043)
-------	--

LUIS FERNANDO DE ALMEIDA


ESTA TESE FOI JULGADA ADEQUADA PARA A OBTENÇÃO DO TÍTULO DE
“DOUTOR EM ENGENHARIA MECÂNICA”


PROGRAMA: ENGENHARIA MECÂNICA
ÁREA: PROJETOS

APROVADA EM SUA FORMA FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO


Prof. Dr. Marcelo dos Santos Pereira
Coordenador


BANCA EXAMINADORA:


Prof. Dr. MAURO HUGO MATHIAS
Orientador / Unesp-Feg


Prof. Dr. ÁLVARO MANOEL SOUZA SOARES
Unesp-Feg


Prof. Dr. JOSÉ ELÍAS TOMAZINI
Unesp-Feg


Prof. Dr. FRANCISCO CARLOS PARQUET BIZARRIA
UNITAU


Prof. Dr. CARLOS HENRIQUE NETTO LAHOZ
DCTA/IAE

Outubro de 2011

DADOS CURRICULARES

LUIS FERNANDO DE ALMEIDA

NASCIMENTO	03.01.1969 – TAUBATÉ/SP
FILIAÇÃO	Bendito Carlos de Almeida Maria Cleide Mariotto
1988/1989	Curso de Graduação Tecnólogo em Processamento de Dados – Universidade de Taubaté
1991/1994	Curso de Graduação Bacharel em Computação Científica – Universidade de Taubaté
2001/2003	Curso de Pós-Graduação em Engenharia Eletrônica e Computação, nível de Mestrado, Instituto Tecnológico da Aeronáutica.
2007/2011	Curso de Pós-Graduação em Engenharia Mecânica, nível de Doutorado, na Faculdade de Engenharia do Campus de Guaratinguetá da Universidade Estadual Paulista.

DEDICATÓRIA

Dedico esse trabalho a minha esposa Andrea, meus filhos Maria Fernanda e João Pedro, minha mãe Cleide e minha avó Joana.

AGRADECIMENTOS

Agradeço a todas as pessoas que direta ou indiretamente me ajudaram na realização desse trabalho:

- À minha esposa, pelo amor, dedicação e companheirismo, pela paciência e compreensão.
- Aos meus filhos, pela alegria que me trouxeram desde a sua concepção, por vocês serem a motivação maior de minha vida, e por me proporcionarem essa fantástica sensação de ser pai.
- À minha mãe, pela sua doação completa e incondicional em todos esses anos, vencendo as adversidades da vida, proporcionando todas as condições para que eu pudesse estar hoje aqui.
- À minha avó, pelo seu exemplo de vida e de fé, pelos valores a mim passados, me orientando sobre o certo e o errado, e pelo carinho o qual nunca serei capaz de retribuir com a mesma intensidade.
- Aos meus tios, pelas incontáveis ajuda ao longo dos anos.
- Ao amigo, professor Mauro, pela orientação, incentivo e amizade.
- Aos amigos Carlos e Walter, pelas sugestões, amizade e incentivo.
- Aos amigos, pelo apoio e palavras motivadores.

Deus abençoe a todos!

APOIO FINANCEIRO

Quero agradecer à Universidade de Taubaté pela bolsa de estudos concedida para auxílio no desenvolvimento das pesquisas realizadas nesse trabalho.

Igualmente, agradeço a UNESP/FEG pelo apoio financeiro concedido para participação de eventos científicos e congressos.

ALMEIDA, L. F. **Redes Neurais Artificiais Aplicadas a Manutenção Baseada em Condição**. 2011. 193 f. Tese (Doutorado em Engenharia Mecânica) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2011.

RESUMO

Um importante aspecto no processo produtivo é proporcionar o funcionamento das máquinas o maior tempo possível sem o comprometimento na qualidade final do produto. Nesse sentido, a utilização de uma política de manutenção adequada se torna necessária para o monitoramento do desgaste dos componentes das máquinas a fim de aumentar o tempo de sua utilização sem comprometer a qualidade do produto. A manutenção baseada em condição se apresenta como a abordagem mais apropriada para esse controle. Dentre as diversas abordagens utilizadas para o desenvolvimento de programas para esse tipo de manutenção, as técnicas baseadas em Inteligência Artificial vêm se destacando no que diz respeito ao seu desempenho. Diante desse contexto, essa tese propõe uma Rede Neural Artificial, a qual, devidamente parametrizada, possibilita sua aplicação tanto para análise de vibrações quanto análise de partículas de desgaste. Para tanto, foi implementado um protótipo denominado NEURALNET-CBM, subdividido em dois módulos, Vibrações e Partículas. Os resultados dos testes mostram a efetividade da rede proposta, com um índice de acerto acima de 90% na classificação e identificação de defeitos e partículas de desgaste.

PALAVRAS-CHAVE: Manutenção Baseada em Condição, Manutenção Preditiva, Partícula de Desgaste, Redes Neurais Artificiais, Vibração.

ALMEIDA, L. F. **Artificial Neural Networks Applied to Condition-Based Maintenance**. 2011. 193 f. Thesis (Doctorate in Mechanical Engineering) - Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2011.

ABSTRACT

An important aspect in the production process is to ensure the operability of a machine as long as possible without interfering on the final quality product. In this way, the use of a suitable maintenance policy is critical for monitoring the wear of the machine components in order to increase your useful life without any compromise of the product quality. The Condition-Based Maintenance is presented as the most appropriate approach for this control. Among several methods used to develop systems for this type of maintenance, techniques Artificial Intelligence has been standing out in relation their performance. Therefore, this thesis proposes a Artificial Neural Network, which, properly parameterized, it makes possible its application for both vibration and wear particle analysis. For this, we implemented a prototype named NEURALNET-CBM, divided into two modules: Vibration and Particle. The test results show the effectiveness of the proposed network, with accuracy rate greater than 90% in classifying and identification of defects and wear particles.

KEYWORDS: Condition-Based Maintenance, Predictive Maintenance, Wear Particle, Artificial Neural Networks, Vibration.

LISTA DE FIGURAS

Figura 1 – Tendências da visão sobre falha do equipamento	33
Figura 2 – Procedimento para teste de hipótese CBM	36
Figura 3 – Categorias para definição de IA.....	41
Figura 4 – Arquitetura básica de um agente inteligente	42
Figura 5 – Arquitetura de um SE típico.....	43
Figura 6 – Regras IF-THEN para representação do conhecimento.....	44
Figura 7 – Três passos em um programa CBM	51
Figura 8 – Exemplo de sensor de proximidade – modelo <i>Senturium</i>	54
Figura 9 – Exemplo de sensor de velocidade – modelo PZDC 4-20m	54
Figura 10 – Exemplo de acelerômetro – modelo PZHT <i>High Temperature Range</i>	55
Figura 11 – Exemplo de sinal no domínio do tempo.....	56
Figura 12 – Representação esquemática de mancal de rolamento	61
Figura 13 – Exemplo de partícula de desgaste por fricção.....	65
Figura 14 – Exemplo de partículas de desgaste por abrasão.....	66
Figura 15 – Exemplo de partículas de desgaste por fadiga	66
Figura 16 – Exemplo de partículas de desgaste por deslizamento severo	67
Figura 17 – Exemplo de partículas de materiais cristalinos	67
Figura 18 – Exemplo de partículas de desgaste por rolamento e deslizamento	67
Figura 19 – Relação entre características das partículas e o modo de desgaste.....	68
Figura 20 – Fotografia da caixa de fusíveis.....	70
Figura 21 – Análise termográfica da caixa de fusíveis.....	70
Figura 22 – Modelo de RNA de McCulloch Pitts	74
Figura 23 – Arquitetura genérica de uma RNA.....	75
Figura 24 – Neurônio artificial	76
Figura 25 – Exemplo de Rede Alimentada Adiante	77
Figura 26 – Exemplo de Rede Alimentada Adiante Multicamadas.....	78
Figura 27 – Exemplo de Rede Recorrente.....	79
Figura 28 – Exemplo de classes linearmente separáveis.....	83
Figura 29 – Exemplo de rede do tipo Perceptron.....	83

Figura 30 – Exemplo de rede MLP com uma camada oculta.....	85
Figura 31 – Exemplo de uma rede de Kohonen com dois nós de entrada e um mapa de saída de 3x3	87
Figura 32 – Arquitetura do protótipo NEURALNET-CBM.....	90
Figura 33 – Funcionamento do módulo Vibrações.....	92
Figura 34 – Funcionamento do módulo Partículas.....	93
Figura 35 – Janela principal do NEURALNET-CBM	95
Figura 36 – Janela do módulo Vibrações	96
Figura 37 – Janela para importação de dados.....	97
Figura 38 – Estrutura do arquivo de amostra .sam.....	97
Figura 39 – Exemplo de visualização de sinal	98
Figura 40 – Exemplo de visualização de sinal ampliado	99
Figura 41 – Janela para visualização das características.	100
Figura 42 – Janela para geração de dados de treinamento	101
Figura 43 – Janela para seleção de arquivo de dados.....	102
Figura 44 – Janela para identificação do estado do rolamento.....	102
Figura 45 – Janela de treinamento da RNA.....	103
Figura 46 – Janela para diagnóstico básico	104
Figura 47 – Janela para diagnóstico completo	104
Figura 48 – Janela do módulo Partículas.....	105
Figura 49 – Estrutura do arquivo do módulo Partículas.....	105
Figura 50 – Janela para importação de dados.....	106
Figura 51 – Janela para visualização de dados.....	107
Figura 52 – Janela para treinamento e teste da RNA	108
Figura 53 – Janela de análise de desempenho da RNA.....	108
Figura 54 – Janela para análise de partículas	109
Figura 55 – Estratégia dos testes	110
Figura 56 – Bancada utilizada para experimentos DATA-FEG1	111
Figura 57 – Bancada utilizada para experimentos DATA-CWRU	113
Figura 58 – Arquitetura de RNA para classificação básica - módulo Vibrações	117
Figura 59 – Arquitetura de RNA para classificação completa - módulo Vibrações..	117

Figura 60 – Arquitetura de RNA para classificação - módulo Partículas.....	118
Figura 61 – Processo de criação dos arquivos para treinamento e teste a partir de DATA-FEG1	120
Figura 62 – Processo de criação dos arquivos para treinamento e teste a partir de DATA-CWRU.....	126
Figura 63 – Processo de criação dos arquivos para treinamento e teste a partir de DATA-RANDALL	131
Figura 64 – Estrutura do arquivo de configuração da RNA para o classificador.....	134
Figura 65 – Classificador indicando presença de falha no rolamento.....	136
Figura 66 – Classificador indicando defeito acentuado na pista interna.....	136

LISTA DE TABELAS

Tabela 1 – Custo da manutenção em relação ao PIB.....	22
Tabela 2 – Aplicação de recursos com relação ao tipo de manutenção.....	23
Tabela 3 – Principais aplicações da informática na manutenção	25
Tabela 4 – Evolução da manutenção/expectativas	32
Tabela 5 – Mudanças das técnicas de manutenção.....	34
Tabela 6 – Origens de metais de desgaste	64
Tabela 7 – Especificação do rolamento do experimento DATA-FEG1.....	109
Tabela 8 – Configurações dos experimentos DATA-FEG1.....	109
Tabela 9 – Especificações dos rolamentos - medidas em polegadas.....	113
Tabela 10 – Especificações das falhas – em polegadas.....	114
Tabela 11 – Testes realizados utilizando para classificação básica - DATA-FEG1 ..	121
Tabela 12 – Testes realizados utilizando para classificação completa - DATA-FEG1.....	121
Tabela 13 – Resultados obtidos para TESTE_FE01.....	121
Tabela 14 – Resultados obtidos para TESTE_FE02.....	121
Tabela 15 – Resultados obtidos para TESTE_FE03.....	122
Tabela 16 – Resultados obtidos para TESTE_FE04.....	122
Tabela 17 – Resultados obtidos para TESTE_FE05.....	122
Tabela 18 – Resultados obtidos para TESTE_FE06.....	122
Tabela 19 – Resultados obtidos para TESTE_FE07.....	122
Tabela 20 – Resultados obtidos para TESTE_FE08.....	123
Tabela 21 – Resultados obtidos para TESTE_FE09.....	123
Tabela 22 – Resultados obtidos para TESTE_FE10.....	123
Tabela 23 – Resultados obtidos para TESTE_FE11	123
Tabela 24 – Resultados obtidos para TESTE_FE12.....	123
Tabela 25 – Resultados obtidos para TESTE_FE13.....	124
Tabela 26 – Resultados obtidos para TESTE_FE14.....	124
Tabela 27 – Resultados obtidos para TESTE_FE15.....	124
Tabela 28 – Resultados obtidos para TESTE_FE16.....	124

Tabela 29 – Resultados obtidos para TESTE_FE17.....	124
Tabela 30 – Resultados obtidos para TESTE_FE18.....	125
Tabela 31 – Resultados obtidos para TESTE_FE19.....	125
Tabela 32 – Resultados obtidos para TESTE_FE20.....	125
Tabela 33 – Resultados obtidos para TESTE_FE21.....	125
Tabela 34 – Testes realizados utilizando para classificação básica para dados DATA-CWRU.....	126
Tabela 35 – Testes realizados utilizando para classificação completa para dados DATA-CWRU.....	127
Tabela 36 – Resultados obtidos para TESTE_CW01	127
Tabela 37 – Resultados obtidos para TESTE_CW02	127
Tabela 38 – Resultados obtidos para TESTE_CW03.....	127
Tabela 39 – Resultados obtidos para TESTE_CW04.....	128
Tabela 40 – Resultados obtidos para TESTE_CW05.....	128
Tabela 41 – Resultados obtidos para TESTE_CW06.....	128
Tabela 42 – Resultados obtidos para TESTE_CW07.....	128
Tabela 43 – Resultados obtidos para TESTE_CW09.....	129
Tabela 44 – Resultados obtidos para TESTE_CW09.....	129
Tabela 45 – Resultados obtidos para TESTE_CW10.....	129
Tabela 46 – Resultados obtidos para TESTE_CW11	129
Tabela 47 – Resultados obtidos para TESTE_CW12.....	129
Tabela 48 – Resultados obtidos para TESTE_CW13.....	129
Tabela 49 – Resultados obtidos para TESTE_CW14.....	130
Tabela 50 – Resultados obtidos para TESTE_CW15.....	130
Tabela 51 – Resultados obtidos para TESTE_CW16.....	130
Tabela 52 – Testes realizados para classificação básica – DATA-RANDALL	131
Tabela 53 – Testes realizados para classificação completa – DATA-RANDALL	131
Tabela 54 – Resultados obtidos para TESTE_RA01.....	132
Tabela 55 – Resultados obtidos para TESTE_RA02.....	132
Tabela 56 – Resultados obtidos para TESTE_RA03.....	132
Tabela 57 – Resultados obtidos para TESTE_RA04.....	132

Tabela 58 – Resultados obtidos para TESTE_RA05.....	132
Tabela 59 – Resultados obtidos para TESTE_RA06.....	133
Tabela 60 – Resultados para DATA-FEG2 utilizando RNA com um neurônio na camada de entrada	133
Tabela 61 – Resultados para DATA-FEG2 utilizando RNA com dois neurônios na camada de entrada	134
Tabela 62 – Resultados para DATA-FEG utilizando RNA com três neurônios na camada de entrada	134
Tabela 63 – Identificação das características para módulo Vibrações	135
Tabela 64 – Identificação das características para módulo Partículas.....	135
Tabela 65 – Resumo dos resultados para módulo Vibrações	138
Tabela 66 – Resumo dos resultados para módulo Partículas.....	138
Tabela 67 – Rolamento sem defeito	160
Tabela 68 – Rolamento localizado na extremidade do acionamento (taxa de aquisição=12.000 rpm)	160
Tabela 69 – Rolamento localizado na extremidade do acionamento (taxa de aquisição=48.000 rpm)	161
Tabela 70 – Rolamento localizado na extremidade do ventilador.....	161
Tabela 71 – Características morfológicas das partículas contidas na base de dados DATA-FEG2	162

LISTA DE ABREVIATURAS E SIGLAS

ABRAMAN	- Associação Brasileira de Manutenção
AG	- Algoritmos Genéticos
CASPA	- <i>Computer-Aided Systematic Particle Analysis</i>
CBM	- <i>Condition-Based Maintenance</i>
CRM	- <i>Customer Relationship Management</i>
cps	- ciclos por segundo
CTM	- Custo Total da Manutenção
CW	- Partículas de desgaste por abrasão (<i>Cutting Wear</i>)
DATA-FEG1	- Dados de vibração provenientes de experimentos realizados no Departamento de Mecânica da Faculdade de Engenharia de Guaratinguetá
DATA-FEG2	- Dados de partícula de desgaste provenientes de experimentos realizados no Departamento de Mecânica da Faculdade de Engenharia de Guaratinguetá
DATA-CWRU	Dados de vibração provenientes de experimentos realizados no laboratório da <i>Case Western Reserve University</i> .
FCM	- Fuzzy C-Means
FFT	- <i>Fast Fourier Transform</i>
FW	- Partículas de desgaste por fadiga (<i>Fatigue Wear</i>)
HMM	- <i>Hidden Markov Models</i>
IA	- Inteligência Artificial
LF	- Lógica Fuzzy
MLP	- <i>Multi-Layer Perceptron</i>
MTS	- <i>Mahalanobis-Taguchi System</i>
NBR	- Norma Brasileira Registrada
PIB	- Produto Interno Bruto
PG	- Programação Genética
RAD	- <i>Rapid Application Development</i>

rms	- <i>Root Mean Square</i>
RNA	- Rede Neural Artificial
RUL	- <i>Remaining Useful Life</i>
rpm	- Rotações por Minuto
RW	- Partículas de desgaste por fricção (<i>Rubbing Wear</i>)
SHT	- <i>Structured Hypothesis Test</i>
SE	- Sistemas Especialistas
SOM	- <i>Self-Organizing Maps</i>
SPC	- <i>Statistical Process Control</i>
SSW	- Partículas de desgaste por deslizamento severo (<i>Severe Sliding Wear</i>)
SVC	- <i>Support Vector Clustering</i>
SVM	- <i>Support Vector Machine</i>
TI	- Tecnologia da Informação

SUMÁRIO

1 INTRODUÇÃO	21
1.1 Justificativas e objetivos.....	26
1.2 Metodologia.....	28
1.3 Estrutura do trabalho	29
2 LEVANTAMENTO BIBLIOGRÁFICO	31
2.1 Manutenção baseada em diagnóstico	35
2.1.1 Abordagens estatísticas	35
2.1.1.1 Teste de hipótese	35
2.1.1.2 Métodos SPC	36
2.1.1.3 Análise de grupos	37
2.1.1.4 Cadeias ocultas de Markov.....	40
2.1.2 Abordagens baseadas em IA	40
2.1.2.1 Sistemas Especialistas	42
2.1.2.2 Lógica Fuzzy	45
2.1.2.3 Redes Neurais Artificiais.....	45
2.1.2.4 Algoritmos Genéticos	47
2.2 Manutenção baseada em prognóstico	48
2.2.1 Estimativa RUL	48
2.2.2 Políticas de manutenção incorporando prognósticos	49
2.2.3 Especificação de intervalo de monitoramento de condição	50
3 MANUTENÇÃO BASEADA NA CONDIÇÃO	51
3.1 Monitoramento de vibração.....	53
3.1.1 Aquisição de dados.....	54
3.1.2 Processamento de sinais	55
3.1.2.1 Análise no domínio do tempo.....	55
3.1.2.2 Análise no domínio da frequência.....	59
3.1.3 Aplicações	60
3.2 Tribologia	62
3.2.1 Análise de óleo lubrificante.....	63

3.2.2 Análise espectrográfica	63
3.2.3 Ferrografia	64
3.2.4 Análise de partículas de desgaste	64
3.2.4.1 Tipos de partículas de desgaste	65
3.2.4.2 Classificação partículas de desgaste	69
3.3 Termografia	70
3.4 Inspeção visual	71
3.5 Ultrassonografia	71
4 REDES NEURAIS ARTIFICIAIS.....	73
4.1 Histórico	74
4.2 Arquitetura básica de uma RNA.....	75
4.2.1 Topologia da rede	77
4.2.2 Algoritmo de aprendizagem	79
4.2.2.1 Aprendizado por correção de erro	80
4.2.2.2 Regra de aprendizado Hebbiano.....	80
4.2.2.3 Regra de aprendizado competitivo	81
4.2.2.4 Regra de aprendizado de Boltzman.....	81
4.2.3 Esquema de codificação	82
4.3 Tipos de RNA.....	82
4.3.1 Perceptron.....	82
4.3.2 MLP	84
4.3.3 Kohonen.....	86
5 PROTÓTIPO NEURALNET-CBM	89
5.1 Arquitetura do sistema.....	90
5.2 RNA utilizada	93
5.3 Interface gráfica.....	94
5.3.1 Módulo Vibrações	95
5.3.1.1 Importar dados.....	96
5.3.1.2 Exibir sinal.....	98
5.3.1.3 Calcular características no domínio do tempo	99
5.3.1.4 Gerar dados para treinamento da RNA	100

5.3.1.5 Treinar e testar a RNA.....	102
5.3.1.6 Analisa dados.....	103
5.3.2 Módulo Partículas.....	104
5.3.2.1 Importar dados.....	105
5.3.2.2 Visualização dos dados.....	106
5.3.2.3 Treinamento e teste da RNA	107
5.3.2.4 Análise de partículas.....	109
6 TESTES E RESULTADOS	110
6.1 Arquivos de dados	110
6.1.1 DATA-FEG1	111
6.1.2 DATA-CWRU.....	113
6.1.3 DATA-RANDALL.....	114
6.1.4 DATA-FEG2	115
6.2 Definição dos parâmetros de entrada	115
6.2.1 Resultados para base de dados DATA-FEG1	119
6.2.2 Resultados para base de dados DATA-CWRU	125
6.2.3 Resultados para base de dados DATA-RANDALL.....	130
6.2.3 Resultados para base de dados DATA-FEG2	133
6.3 Configuração da RNA	134
7 CONSIDERAÇÕES FINAIS.....	137
REFERÊNCIAS	141
APÊNDICE A – RELAÇÃO COMPLETA DO EXPERIMENTO	
DATA-CWRU	160
APÊNDICE B – CARACTERÍSTICAS MORFOLÓGICAS DA BASE	
DE DADOS DATA-FEG2.....	162

1 INTRODUÇÃO

Atualmente, considerando a crescente competitividade do mercado, as empresas, cada vez mais, sentem a necessidade de buscar meios que permitam garantir uma posição de destaque. Nesse contexto podem ser citados vários aspectos para os quais elas devem se preocupar: *marketing*, gestão do relacionamento com o cliente ou CRM (*Customer Relationship Management*), controle de qualidade do produto, redução de custos e capacidade de produção em grande escala, dentre outros.

Com relação aos três últimos aspectos, muitas situações podem prejudicar sua efetividade e, no caso de empresas que fazem uso de máquinas industriais, um fator real é aquele relacionado às paradas de uma linha de produção decorrentes, por exemplo, de falhas em máquinas ou mesmo por causa de manutenções preventivas programadas.

A NBR5462 (1994) define manutenção como a combinação de todas as ações técnicas e administrativas destinadas a manter ou recolocar um item em um estado no qual possa desempenhar uma função requerida. Mobley (2002) ressalta que ela deve garantir que todo o equipamento seja mantido em condições ótimas de operação. Mobley (2002) destaca, ainda, que os custos de manutenção representam a maior parte do custo operacional total das empresas de manufatura ou produção, variando entre 15% a 60%, dependendo da indústria específica.

Pinto e Xavier (2001) destacam a missão da manutenção, ou seja, garantir a disponibilidade da função dos equipamentos e instalações de modo a atender a um processo de produção ou serviço, com confiabilidade, segurança, preservação do meio ambiente e custo adequados.

Dhilon (2002) apresenta alguns fatos relevantes com relação aos gastos com a manutenção de máquinas, podendo-se ressaltar os que seguem:

A cada ano são gastos cerca de 300 bilhões de dólares em manutenção e funcionamento de fábricas pela indústria americana, e estima-se que, aproximadamente, 80% deste valor são utilizados para corrigir falhas crônicas de máquinas, sistemas e pessoas. Em 1968 estimou-se que práticas de manutenção mais eficientes no Reino Unido poderiam ter salvado aproximadamente 300 milhões de libras por ano relativas à perda de produção devido a equipamentos indisponíveis (DHILON, 2002, p.2).

No Brasil, a Associação Brasileira de Manutenção (ABRAMAN) a cada dois

anos divulga o resultado de pesquisas referentes a alguns aspectos relacionados à manutenção no país. Um item analisado é o custo da manutenção em relação ao faturamento das empresas e o Produto Interno Bruto (PIB). O documento emitido em setembro de 2009, mostra que os custos com a manutenção no Brasil, considerando as empresas analisadas, representaram 4,14% do PIB, o equivalente a aproximadamente, 102 bilhões de reais para 2009, conforme apresentando na Tabela 1.

Tabela 1 – Custo da manutenção em relação ao PIB (fonte: ABRAMAN, 2009)

Ano	Custo Total da Manutenção /Faturamento Bruto (em %)	Valores em milhões de reais
2009	4,14	102.060
2007	3,89	90.326
2005	4,10	72.537
2003	4,27	57.475
2001	4,47	49.226
1999	3,56	32.545
1997	4,39	34.193
1995	4,26	14.876

A definição de uma política adequada para manutenção do conjunto de máquinas em uma empresa é um fator importante no auxílio à obtenção de maiores índices de produtividade. Nesse caso, uma política ideal deve ter como objetivo o funcionamento das máquinas no maior tempo possível e que seus componentes possam ser utilizados até alcançarem um estado de real necessidade de substituição, sem o comprometimento na qualidade do produto final manufaturado.

No que diz respeito aos tipos de tarefas de manutenção, Higgins e Mobley (2002) definem três abordagens: corretiva, preventiva e preditiva. A principal diferença entre elas está no fato de quando a tarefa de manutenção é implementada:

- Corretiva: pode ser definida como a “manutenção efetuada após a ocorrência de uma pane destinada a recolocar um item em condições de executar uma função requerida.” (NBR5462, 1994). Mobley (2002, p.2) resume sua aplicabilidade nas seguintes frases: “quando uma máquina quebrar conserte-a” e “se não está quebrado, não repare”.
- Preventiva: é aquela “efetuada em intervalos predeterminados, ou de acordo com critérios prescritos, destinada a reduzir a probabilidade de falha ou a degradação do funcionamento de um item.” (NBR5462, 1994). Um aspecto negativo neste tipo de manutenção é grande possibilidade em substituir componentes que ainda estejam adequados para uso (SCHEFFER;

GIRDHAR, 2004, p.2).

- Preditiva: também citada como Manutenção Baseada na Condição (CBM – *Condition-Based Maintenance*) (SCHEFFER; GIRDHAR, 2004) baseia-se “na aplicação sistemática de técnicas de análise, utilizando-se de meios de supervisão centralizados ou de amostragem, para reduzir ao mínimo a manutenção preventiva e diminuir a manutenção corretiva.” (NBR5462, 1994). Um aspecto relevante relacionado à manutenção preditiva é a possibilidade de maior aproveitamento da vida útil dos componentes da máquina, permitindo a reposição somente dos itens realmente necessários.

Com base nessas definições, uma filosofia de manutenção desejável seria aquela centrada na abordagem preditiva com o intuito de se aproveitar ao máximo os componentes de máquinas utilizados e de se evitar paradas inoportunas com manutenções corretivas. Entretanto, a adoção de técnicas preditivas exige a disponibilidade de recursos e de pessoal qualificado a fim de se obter informações confiáveis a respeito do estado dos equipamentos monitorados.

Com relação às causas de falhas mais frequentes no meio industrial, Blischke e Murthy (2003) “incluem o estresse excessivo, tais como fratura, empenamento, deformação e falta de aderência e o desgaste, tais como, corrosão, difusão, rachadura e radiação”. (BLISCHKE; MURTHY, 2003, p.17, tradução nossa).

Outro item da pesquisa realizada pela ABRAMAN (2009) aborda o total de recursos aplicados na manutenção considerando essas diferentes abordagens. A Tabela 2 apresenta o percentual aplicado em recursos para os tipos de manutenção citados. Nos dados apresentados nota-se que a manutenção preditiva ainda ocupa uma parcela menor em sua utilização dentro das empresas brasileiras.

Tabela 2 – Aplicação de recursos com relação ao tipo de manutenção (ABRAMAN, 2009)

Ano	Corretiva %	Preventiva %	Preditiva %	Outros %
2009	29,85	38,73	13,74	17,68
2007	25,61	38,78	17,09	18,51
2005	32,11	39,03	16,48	12,38
2003	29,98	35,49	17,76	16,77
2001	28,05	35,67	18,87	17,41
1999	27,85	35,84	17,17	19,14
1997	25,53	28,75	18,54	27,18
1995	32,80	35,00	18,64	13,56

Isso pode ser associado a diversos fatores dentre os quais aqueles relacionados à natureza das técnicas de manutenção preditiva. Marcorin e Lima (2003) e Scheffer e Girdhar (2004, p.8) argumentam o fato dela se caracterizar por uma manutenção de acompanhamento, exigindo, assim, um alto custo de investimento com mão-de-obra mais qualificada e instrumentos de medição. Entretanto, os mesmos autores classificam esse alto custo como “aparente”, pois o retorno é alcançado com os resultados obtidos com a relação custo-benefício.

A manutenção preditiva é dependente de recursos que possibilitem obter-se resultados confiáveis, os quais possam representar o real estado da máquina monitorada. Sendo assim, para que isso ocorra, um ponto crucial e muito importante é o apoio gerencial ao departamento de manutenção com a disponibilização dos instrumentos necessários, sejam equipamentos ou recursos de *software*, bem como treinamento adequado da equipe.

Atualmente, uma área que se torna mais inserida no contexto das empresas é a Tecnologia da Informação (TI), que está relacionada aos recursos de *hardware*, de *software*, de rede e de administração de banco de dados dedicados ao armazenamento, processamento e comunicação da informação (O'BRIEN, 2006, p.5). Comumente, esse conceito é associado ao termo informática ou computação.

Dentre as inúmeras vantagens proporcionadas pela aplicação da TI na manutenção, podem ser destacadas: redução de custos, maior acesso à informação, melhor planejamento e aumento no controle das operações relacionadas à manutenção (HINGINS, MOBLEY, 2002).

A ABRAMAN (2009) destaca a utilização da TI nas diversas atividades que envolvem o processo de manutenção, conforme mostrado na Tabela 3. Desde as primeiras pesquisas a informática tem sua presença como recurso de auxílio às tarefas de manutenção. A partir do relatório emitido em 2009, devido à nova forma de coleta de dados estabelecida, os valores das séries sofreram variações as quais podem comprometer uma análise de tendência (ABRAMAN, 2009). Uma particularidade desta nova forma está no fato da inserção do item “Manutenção Preditiva” nos dados analisados.

Tabela 3 – Principais aplicações da informática na manutenção (ABRAMAN, 2009)

Ano	Planejamento, Programação, Acompanhamento e Serviços (%)	Gerenciamento de Paradas de Manutenção (%)	Manutenção Preditiva (%)	Análise de Falhas (%)	Controle de Custo (%)	Gestão de Estoque (%)	Outros (%)
2009	29,82	18,25	15,42	12,60	20,31	3,60	0,00
2007	28,24	17,75	14,12	14,12	19,27	2,10	1,53
2005	26,46	-	-	24,07	23,02	21,16	0,79
2003	23,93	-	-	23,46	21,09	19,91	3,32
2001	24,21	-	-	21,06	20,87	19,49	4,72
1999	26,19	-	-	19,84	20,11	20,63	4,76
1997	25,00	-	-	21,75	21,50	20,00	4,25
1995	25,87	-	-	21,54	22,04	20,03	3,84

Kobbacy e Murthy (2008, p.43) enfatizam a grande importância da TI no apoio à decisão para os gerentes de manutenção por meio de sistemas computadorizados de gerenciamento de manutenção (CMMS, do inglês *Computerized Maintenance Management Systems*). Trata-se de uma ferramenta avançada para gerenciamento da manutenção “capaz de controlar todos os processos e procedimentos de gerência de manutenção, auxiliando a empresa na execução das operações mais eficientes e analisando o equipamento para posterior otimização de seu desempenho.” (MATHER, 2003, p.2). Entretanto, Campbell e Jardini (2001, p.98) destacam um aspecto importante desses sistemas que é a tendência de serem organizados com funções embutidas de manutenção preditiva e manutenção centrada em confiabilidade.

Portanto, a TI vem se tornando cada vez mais uma ferramenta fundamental para empresas no que diz respeito à manutenção. Higgins e Mobley (2002, p. 123) destacam quatro tipos de benefícios relacionados à utilização da TI na manutenção: redução de custos, maior acesso à informação, melhor planejamento e aumento no controle das operações de manutenção por meio, por exemplo, do monitoramento constante do equipamento utilizando programas específicos. Por sua vez, Bloch e Geitner (2005, p.20) justificam a importância no incentivo aos sistemas computacionais de apoio a manutenção com base em vários aspectos, dentre os quais, pode-se destacar o aperfeiçoamento no grau de confiabilidade do equipamento dedicado à manutenção preditiva.

1.1 Justificativa e objetivos

Na manutenção preditiva ou CBM, um aspecto muito importante é a aplicação de programas no auxílio da análise dos dados coletados das máquinas, principalmente, no diagnóstico e no prognóstico de falhas em uma máquina. Um exemplo é o sistema *Watchdog Agent-based Real-time Remote Machinery Prognostics and Health Management* ou, simplesmente, R²M-PHM, desenvolvido pelo IMS Center.

Diversas abordagens vêm sendo estudadas a fim de prover programas de apoio à detecção de falhas, e, as técnicas baseadas em Inteligência Artificial (IA) são apontadas como interessantes abordagens no que diz respeito ao seu desempenho, comparado com as abordagens tradicionais (JARDINI; LIN; BANJEVIC, 2006, REIS; PATI, 2000).

Dentre as técnicas de IA, as Redes Neurais Artificiais (RNA) vêm se destacando como uma das principais abordagens no apoio ao monitoramento de máquinas rotativas, em especial, em duas técnicas de manutenção baseada em condição: monitoramento de vibrações e tribologia.

Na área de vibrações, uma linha de pesquisa engloba a aplicação de RNAs associadas a características no domínio do tempo. Neste caso, as diversas arquiteturas de redes propostas são voltadas, estritamente, ou para detecção de presença/ausência de falha (SAMANTA, AL BALUSHI, 2003; SAMANTA, 2004; SREEJITH, VERMA, SRIVIDYA, 2008; HARIHARAN, SRINIVASAN, 2009) ou para identificação do tipo de falha (JACK, NANDI, 2000; LI ET AL, 2000; AL-RAHEEM, ABDUL-KAREM, 2010). Já na tribologia, as RNAs vêm sendo aplicadas, principalmente, na análise de partículas de desgaste por meio de seus diversos atributos (XU; LUXMOORE, 1997; LAGHARI, MENON, KHUWAJA, 2004; MENON, LAGHARI, 2005; ALBIDEWI, 2008).

Todavia, cada trabalho citado propõe uma RNA específica para o problema tratado, com configurações e parâmetros visando melhor obtenção dos resultados esperados. Desse modo, essa tese propõe uma única RNA genérica, do tipo *Multi Layer Perceptron*, a qual, devidamente parametrizada, possibilita sua aplicação tanto para análise de vibrações quanto para análise de partículas de desgaste. A arquitetura

da RNA proposta apresenta as seguintes características:

- A quantidade de neurônios da camada de entrada é definida pela quantidade de características que será utilizada no processo de classificação (Vibrações) e identificação (Partículas).
- A quantidade de neurônios da camada de saída é definida pela quantidade falhas em rolamentos a qual a RNA é capaz de classificar (Vibrações) e pela quantidade de tipos de partículas de desgaste previstas para identificação (Partículas).
- A camada oculta apresenta 5 neurônios.
- A função de ativação utilizada é a sigmóide bipolar.
- Os pesos iniciais são gerados utilizando o método proposto por Nguyen e Widrow (1990).

Para tanto, foi implementado um protótipo denominado NEURALNET-CBM, subdividido em dois módulos, Vibrações e Partículas, que apresenta as características/funcionalidades:

- No módulo Vibrações é possível importar e, conseqüentemente, analisar dados de diferentes sistemas de aquisição de dados. Para isso, é necessário que o arquivo de entrada esteja no formato texto, padrão ASCII, ou no formato do programa MATLAB.
- No módulo Partículas de desgaste é possível analisar dados de diferentes arquivos de imagens. Para isso, é necessário que o arquivo de entrada esteja no formato texto, padrão ASCII, contendo a características previstas no protótipo.
- A parametrização possibilita sua aplicação para diferentes bases de dados, permitindo a escolha da configuração de parâmetros que proporciona a classificação com maior taxa de acerto, dentre as disponibilizadas.
- A parametrização consiste na definição do número de neurônios das camadas de entrada e saída.
- O número de neurônios da camada de entrada está relacionado ao total de características a ser utilizado para a geração do classificador neural. Atualmente, o módulo Vibrações permite a análise de 16 características no

domínio do tempo e o módulo Partículas 10 atributos morfológicos.

- O processo de definição da melhor configuração para a camada de entrada é realizado de forma automática, ou seja, o protótipo analisa todas as configurações possíveis, executando o treinamento da RNA para cada configuração, e identifica aquela que proporciona maior taxa de acerto no processo de identificação da falha/partícula.
- O número de neurônios da camada de saída está condicionado ao total de falhas/partículas ao qual a RNA se propõe analisar.

Em suma, o aspecto inovador apresentado nessa tese está concentrado, especificamente, na proposta de uma RNA genérica que pode ser aplicada tanto para monitoramento de vibração, incluindo detecção de presença de defeito e identificação do tipo da falha, quanto para análise de partículas de desgaste. Sua aplicação é validada pela implementação do protótipo NEURALNET-CBM que permite a manipulação de sinais de vibração provenientes de diferentes sistemas de aquisição de dados e parâmetros morfológicos referentes a partículas de desgaste previamente calculados por um sistema de processamento de imagens.

1.2 Metodologia

Para o desenvolvimento da tese foram realizadas as seguintes etapas:

- Definição do problema: nessa etapa foi realizada uma revisão bibliográfica visando o estudo e a análise dos aspectos fundamentais para o monitoramento de condição de máquinas focando sistemas de previsão e de prognóstico.
- Definição dos elementos de máquinas a serem estudados e dos mecanismos de falhas: essa fase consistiu na definição dos elementos de máquinas a serem monitorados, no caso, a pesquisa focou em engrenagens e mancais de rolamento. Além disso, foram analisados e definidos os tipos de falhas a serem tratados.
- Escolha das características a serem utilizadas: com base na literatura foram definidos os parâmetros a serem utilizados para o processo de classificação.

- Definição das técnicas de IA: essa etapa consistiu no aprofundamento das técnicas de IA, analisando suas características fundamentais para identificar como cada técnica poderia ser aplicada como recurso de auxílio na solução do problema tratado.
- Coleta de dados: essa etapa consistiu na obtenção dos dados, sendo os mesmos provenientes de experimentos realizados na Faculdade de Engenharia de Guaratinguetá (FEG) bem como de banco de dados disponíveis na internet.
- Implementação do protótipo: a fim de avaliar a RNA proposta, esta fase se propôs ao desenvolvimento de um protótipo que disponibiliza funções desde a adequação dos dados para sua análise por meio de um processo de importação até uma interface gráfica para avaliação da rede testada.
- Análise de resultados: essa fase consistiu na execução de todas as combinações de atributos para cada base de dados analisada a fim de se obter a configuração mais adequada.
- Considerações finais: aqui, também rotulado como uma etapa, com base nos resultados obtidos e na literatura e pesquisas em diversas áreas, são apresentadas algumas propostas para aperfeiçoamento da pesquisa realizada.

1.3 Estrutura da tese

A presente tese está dividida em sete capítulos. O primeiro é dedicado a apresentar a problemática envolvida, a motivação pela temática e o objetivo da abordagem.

O segundo capítulo diz respeito ao estado da arte referente à manutenção baseada em condição apresentando diferentes abordagens para tratamento do problema.

O terceiro capítulo introduz conceitos referentes à manutenção baseada em condição como os passos para desenvolvimento de um programa CBM e os tipos de técnicas existentes, dando uma ênfase maior ao monitoramento de vibrações e tribologia, foco deste trabalho.

O quarto capítulo é dedicado às Redes Neurais Artificiais, os conceitos envolvidos, os tipos de redes existentes e o processo de treinamento.

O quinto capítulo apresenta a arquitetura do protótipo NEURALNET-CBM implementado, a arquitetura da RNA proposta, e toda a interface gráfica desenvolvida.

O sexto capítulo é dedicado à apresentação dos testes realizados para validação da RNA proposta quanto a sua aplicação no monitoramento de vibrações e análise de partícula de desgaste, identificando as bases de dados utilizadas, e aos resultados obtidos.

O sétimo capítulo finaliza este trabalho realizando uma explanação sobre a pesquisa desenvolvida, sua contribuição, seus aspectos positivos e considerações sobre tópicos a serem, futuramente, incorporados ao trabalho.

2 LEVANTAMENTO BIBLIOGRÁFICO

Desde o surgimento da Revolução Industrial, na qual diversos gêneros de produtos passaram a ser fabricados dentro de fábricas por meio de um processo produtivo baseado, essencialmente, em máquinas, tornou-se necessária a aplicação de técnicas e conceitos capazes de possibilitar o funcionamento contínuo dessas máquinas visando maior utilização de sua capacidade produtiva.

Dhillon (2006, p.2) aponta que o desenvolvimento da máquina a vapor pelo escocês James Watt (1736–1819), em 1769, pode ser considerado o marco inicial da engenharia de manutenção moderna. Ele, também, destaca o surgimento da revista “*Factory*” em 1882 e a publicação do livro “*Maintenance of Railways*” de Marshall Monroe Kirkman em 1886 como relevantes fatores no desenvolvimento da manutenção. Todavia, é Moubray (1997, p.2) quem propõe uma divisão da evolução da manutenção em três gerações distintas.

A primeira geração compreende no período anterior à Segunda Guerra Mundial, o qual se caracteriza por uma indústria não muito mecanizada e, conseqüentemente, com pequena necessidade de mecanismos de prevenção de falhas nos equipamentos. Nesse caso, a ideia de manutenção limitava-se a simples rotinas de limpeza e lubrificação dos equipamentos ou, em casos mais extremos, consistia em uma abordagem corretiva, ou seja, efetuar a manutenção somente quando houvesse uma quebra no equipamento.

Com a Segunda Guerra Mundial, uma necessidade intensa de bens de consumo refletiu na constatação da incapacidade das fábricas em suprir a demanda. Isso resultou em um aumento significativo na mecanização do processo produtivo por meio da introdução de grande número de máquinas mais complexas. Essa maior dependência das máquinas despertou uma maior preocupação com a possibilidade de falhas nos equipamentos. Assim, nos anos 50 surgiu o conceito de manutenção preventiva (DHILON, 2006, p.2), e, em 1957, Morrow publicou um seu livro sobre a engenharia de manutenção (MORROW, 1957). Moubray (1997, p.2), destaca que a segunda geração pode ser caracterizada pela introdução de técnicas de manutenção preventiva em busca de um maior aproveitamento do maquinário e da aplicação de

uma política de planejamento e controle de manutenção visando uma redução de custos.

Na terceira geração é introduzido o conceito de manutenção preditiva ou CBM, visando, dentre outros aspectos, uma maior qualidade nos produtos produzidos e maior tempo de vida útil do maquinário.

Uma análise mais pormenorizada da evolução da manutenção com relação às três gerações mencionadas é proposta por Moubray (1997), destacando três aspectos que permitem identificar as mudanças entre estas gerações – expectativas, pesquisas e técnicas.

A Tabela 4 apresenta a evolução com relação às expectativas com manutenção, ilustrando uma tendência de conserto após uma quebra ocorrida para uma realidade atual baseada em uma grande preocupação em alguns pontos importantes: qualidade do produto, maior aproveitamento do tempo das máquinas e segurança do trabalho.

Tabela 4 – Evolução da manutenção/expectativas (Fonte: Moubray, 1997)

Primeira Geração	Segunda Geração	Terceira Geração
Conserto após quebra	Maior disponibilidade das máquinas. Maior vida útil dos equipamentos. Custos menores.	Maior disponibilidade e confiabilidade. Maior Segurança. Melhor qualidade dos produtos. Ausência de danos ao ambiente. Maior vida útil dos equipamentos. Maior efetividade nos custos.

Com relação à evolução das pesquisas as mudanças decorrentes baseiam-se na visão das falhas e seus aspectos relacionados ao tempo de vida do maquinário. A Figura 1 apresenta a evolução da visão da falha. Inicialmente, a crença estava centrada em uma probabilidade maior de ocorrência de falha para os equipamentos com maior tempo de vida. A terceira geração apresenta uma tendência de falha baseada a qual considera seis padrões:

- Padrão A: também conhecido a curva da banheira, devido ao seu formato visual, apresenta uma elevada tendência de falhas no início e término de uma operação ou do tempo de vida da máquina, e, geralmente, corresponde a erros de projeto, de instalação, de especificação, de fabricação de peças, de montagem.
- Padrão B: apresenta uma probabilidade constante de falha, seguida de uma

zona de uma acentuada tendência de falha no fim da sua vida útil da máquina ou da operação. Geralmente, está relacionado a falhas decorrentes de desgaste de uma máquina devido ao final de seu tempo de vida útil.

- Padrão C: apresenta acréscimos lineares nas falhas, não indicando uma zona definida de desgaste. Geralmente, está relacionado ao acúmulo de fadiga no transcorrer do tempo.
- Padrão D: apresenta uma probabilidade crescente inicial de falha seguida de uma faixa constante. Geralmente, está relacionado a um período inicial de acomodação de um item novo até uma estabilização dentro do processo.
- Padrão E: apresenta uma taxa de falha constante. Geralmente, refere-se a falhas sucessivas as quais são independentes entre si, ou seja, a falha mais recente não é afetada pela mais anterior.
- Padrão F: apresenta um alto índice de falha no início para depois se estabilizar em valores constantes. Geralmente, está relacionado a erros de projeto, de fabricação ou procedimentos de montagem e instalação.




Figura 1 – Tendências da visão sobre falha do equipamento (Fonte: Moubray, 1997, p.4)

Por fim, com relação às mudanças referentes às técnicas de manutenção, a primeira geração caracteriza-se pelo conceito de manutenção corretiva, evoluindo para o conceito de agenda de tarefas de manutenção, ou seja, aplicação de manutenção preventiva, para uma tendência atual de procedimentos de monitoramento de máquinas por meio da manutenção preditiva. Isso é ilustrado na Tabela 5.

Tabela 5 – Mudanças das técnicas de manutenção (Fonte: Moubray, 1997, p.4)

Primeira Geração	Segunda Geração	Terceira Geração
Conserto após quebra	Revisões programadas. Sistemas para planejamento e controle do trabalho. Computadores grandes e lentos.	Monitoramento de Condição de Máquina. Projetos voltados para confiabilidade e manutenabilidade. Análise de Risco. Computadores pequenos e rápidos. Análise dos efeitos e dos tipos de falhas. Sistemas Especialistas. Grupos de trabalho e profissionais polivalentes.

Portanto, atualmente, destacam-se os estudos voltados a sistemas e técnicas de apoio à manutenção os quais possibilitem um acompanhamento do maquinário para uma possível previsão de falhas e defeitos futuros. Sendo assim, a manutenção baseada em condição ou manutenção preditiva torna-se a metodologia mais adequada a essa realidade, principalmente, por meio da utilização de sistemas e programas computadorizados.

Neste caso, buscam-se recursos que auxiliem na detecção antecipada de possíveis falhas que possam surgir no maquinário a fim de sustentar tomadas de decisão de manutenção no momento e nos componentes apropriados.

Devido à importância das técnicas de CBM, alguns autores propõem estudos focando em diferentes áreas de aplicação e, adicionalmente, agrupando-as em categorias conforme um determinado critério. Por exemplo, Hameed et al (2009) apresentam as diferentes abordagens de monitoramento de condição voltadas a turbinas eólicas.

Por outro lado, Jardini, Lin e Banjevic (2006), de um modo geral, propõem a divisão dos programas voltados à CBM em duas categorias: diagnóstico, o qual busca a detecção, isolamento e identificação da falha quanto essa ocorre e prognóstico, cuja meta é a previsão de uma falha antes de sua ocorrência. Para cada categoria eles sugerem uma subdivisão relacionada ao tipo de abordagem utilizada na busca de um sistema de apoio a manutenção. As seções seguintes apresentam cada uma dessas subdivisões, apontando suas características e alguns dos diversos trabalhos já desenvolvidos.

2.1 Manutenção baseada em diagnóstico

Para a categoria de programas voltados para o diagnóstico, dois tipos de abordagens se destacam (JARDINI; LIN; BANJEVIC, 2006): abordagens estatísticas e abordagens baseadas em técnicas de IA.

2.1.1 Abordagens estatísticas

Os métodos baseados em abordagens estatísticas, associados a ferramentas da qualidade, são aplicados à medição e avaliação de um processo. Para isso, tais métodos concentram-se no monitoramento dos pontos críticos do processo por meio de suas variáveis, buscando um ajuste a fim de minimizar a produção de itens defeituosos (ABDALLAH, 1997). Dentre as abordagens estatísticas, podem ser citados: teste de hipótese, métodos de controle de processos estatísticos (SPC, do inglês *Statistical Process Control*), análise de grupos e cadeias de Markov.

2.1.1.1 Teste de hipótese

Em sua forma mais simples, as abordagens estatísticas baseiam-se em técnicas estatísticas que tratam a detecção de falha como um problema de teste de hipótese. Conforme o próprio termo sugere, esse teste decide se uma dada hipótese formulada está correta por meio da escolha entre duas decisões: aceitar ou rejeitar a referida hipótese (LEHMANN; ROMANO, 2005, p. 56). No caso do monitoramento de falhas em máquinas, analisa-se a hipótese nula, H_0 , para presença de falha contra uma hipótese alternativa, H_1 , a qual indica a ausência da falha.

Nesse contexto, Ma e Li (1995) utilizam um procedimento baseado em teste de hipótese para detecção de falhas em rolamentos. No esquema proposto, ilustrado pela Figura 2, a partir de um conjunto de dados coletados são efetuados cálculos estatísticos utilizados no teste de hipótese final, o qual determina a ausência ou presença de uma

possível falha. Uma vantagem destacada nesse trabalho é a possibilidade de implementação *on-line* devido ao baixo custo computacional requerido.



Figura 2 – Procedimento para teste de hipótese CBM (MA; LI, 1995)

Nyberg (2001), por sua vez, apresenta um sistema de diagnóstico baseado em um teste de hipótese estruturado (SHT, do inglês *Structured Hypothesis Test*), o qual se baseia na combinação de diferentes testes de hipóteses binários na tentativa de resolver problemas de diagnósticos mais complicados, os quais, no contexto desse trabalho, abordam a detecção de falhas em máquinas.

2.1.1.2 Métodos SPC

Métodos SPC compreendem um conjunto de recursos - tais como fluxogramas de processo, histogramas, gráficos de controle - para gerenciamento de processos e gerenciamento e monitoramento da qualidade das saídas de uma organização (OAKLAND, p.20). No contexto da manutenção, tais métodos visam medir o desvio do sinal atual com relação a um sinal de referência o qual representa a condição normal do equipamento monitorado (JARDINI; LIN; BANJEVIC, 2006).

Segundo Fugate, Sohn e Farrar (2001) os métodos SPC apresentam-se como importantes recursos na detecção de defeitos em máquinas. Para isso, eles propõem um controle baseado em gráficos para monitoramento de medidas de aceleração por meio da média e da variância dos sinais analisados. A proposta concentra-se na observação desses gráficos para verificar possíveis variações em seus valores os quais podem apontar anormalidades no equipamento.

Deloux, Castanier e Béranger (2009) apresentam um sistema baseado em métodos SPC para monitorar um sistema com dois mecanismos de falhas devido a um alto nível de deterioração e a um impacto devido a um ambiente estressante. O monitoramento proposto, realizado por meio da introdução das variáveis de processo de deterioração cumulativo e co-variável do estresse, possibilita a inspeção e a substituição de elementos de acordo com o nível de deterioração observado.

2.1.1.3 Análise de grupos

A análise de grupos consiste em um conjunto de técnicas matemáticas e estatísticas as quais dividem dados em grupos com características semelhantes (RUD, 2001, p.203). Jardini, Lin e Banjevic (2006) destacam que um caminho natural para realização desse agrupamento é por meio da utilização de medidas de distâncias entre dois sinais, dentre as quais podem ser citadas: Euclidiana, Mahalanobis (MAHALANOBIS, 1936), Kullback-Leibler (KULLBACK; LEIBLER, 1951), representadas pelas equações (1), (2) e (3), respectivamente.

$$D_E = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Na equação (1), x_i e y_i correspondem às coordenadas dos pontos X e Y no espaço euclidiano n-dimensional.

$$D_M(x) = \sqrt{(x - \mu)^T \times \Sigma^{-1}(x - \mu)} \quad (2)$$

A distância Mahalanobis é considerada com um procedimento clássico para detectar observações anormais (*outliers*) em dados multivariados (WEBB, 2002, p. 414). Na equação (2), o termo x representa um conjunto de amostras enquanto que μ e Σ representam, respectivamente, a média e a matriz de covariância das amostras.

$$D_{KL}(p, q) = \sum_i p_i \times \log_2 \left(p_i / q_i \right) \quad (3)$$

Na equação (3), os termos p_i e q_i representam as distribuições de probabilidades entre as quais se deseja determinar a distância.

Uma abordagem baseada em transformada *wavelet* e lógica *fuzzy* para diagnóstico de falhas em rolamentos (LOU; LOPARO, 2004) faz uso da distância

Euclidiana como método para decisão de diagnóstico. No caso são considerados rolamentos sem defeitos e rolamentos com defeitos na pista interna e esfera.

Staszewski, Worden e Tomlinson (1997) aplicam a distância Mahalanobis como medida para identificação de presença ou não de defeitos em engrenagens, justificando sua utilização devido aos valores calculados aumentarem monotonicamente com o avanço do defeito. Já Portari (1997) avalia dois métodos de diagnósticos, um baseado na distância Euclidiana e outro na distância Mahalanobis, aplicados a um conjunto moto-bomba em três condições operacionais relacionadas a diferentes velocidades de rotação do motor elétrico.

A medida de distância Mahalanobis também é aplicada como função de critério para identificação da condição de um rolamento e seu padrão de falhas (CHENG, YU, YU, 2006). E, mais recentemente, Hu et al (2009) propõem um método de detecção de falhas mecânicas incipientes em bombas de óleo utilizando uma combinação de teoria multifractal e sistema Mahalanobis-Taguchi, a partir de agora referenciado como MTS, do inglês *Mahalanobis-Taguchi System*. Esse sistema inclui dois passos fundamentais: construção da escala de distância Mahalanobis e utilização da taxa de sinal-ruído para avaliar a qualidade das medidas. Para o problema estudado os resultados demonstraram uma precisão de 100% na identificação final.

Outra categoria de métodos estatísticos para análise de grupos são os algoritmos de agrupamento. Jardini, Lin e Banjevic (2006) destacam o algoritmo do vizinho mais próximo (*nearest neighbour algorithm*) como o mais usado. Trata-se de um método que busca identificar o vizinho mais próximo de um conjunto de vetores de treinamento para um dado vetor observado, classificando-o conforme a classe a qual esse vizinho se identifica (WEBB, 2002, p. 95).

Dentro desta linha, Mechefeske e Mathew (1992) aplicam um esquema de classificação baseado no algoritmo do vizinho mais próximo utilizando a medida distância Kullback-Leibler para diagnóstico de falhas em rolamentos a partir de sinais de vibração coletados em baixas velocidades, no caso, velocidades abaixo de 100 rpm.

Dutton et al (2001) apresenta um *software* de reconhecimento de padrão chamado AEGIS PR para análise e classificação de dados de emissão acústica obtidos de testes de lâminas de turbina eólicas. O intuito do *software* desenvolvido é identificar

possíveis problemas relacionados com a fadiga por meio da análise de determinadas características dos sinais, tais como, amplitude, energia, duração, dentre outras.

Outra classe de algoritmos de agrupamento são aqueles baseados na abordagem de vetor suporte, a partir de agora referida como SVC, do inglês *Support Vector Clustering*. Esses algoritmos utilizam uma função para mapear objetos de um espaço de dados para um espaço de características de elevada dimensão. A partir disso, procuram-se pelas menores hiper-esferas as quais reúnem dentro de si um considerável número de pontos, sendo cada hiper-esfera classificada como uma classe distinta (XU; WUNSCH, 2009, p.170). Em algoritmos SVC o aprendizado é realizado por meio da técnica máquinas de vetor suporte, a partir de agora referida como SVM, do inglês *Support Vector Machine*, proposta por Vapnik (1995), cuja proposta central é o ajuste de uma função discriminante de tal modo que proporcione a informação referente ao limite entre as classes a serem identificadas (SÁ, 2001, p.312).

Abbasion et al (2007) aplicam SVM associado a *wavelets* em busca de um método computacionalmente eficiente tanto para análise no domínio do tempo quanto para o domínio da frequência. Os testes são realizados com dados extraídos de dois rolamentos contidos em um motor elétrico, sendo considerados, para cada rolamento quatro estados possíveis – sem defeito e defeitos na pista interna, pista externa e elemento de rolamento.

Esses métodos também têm sido aplicados no monitoramento de falhas em robôs industriais. Datta et al (2006) apresentam um sistema automático de diagnóstico de falhas utilizando SVM para um manipulador robótico em uma indústria de semicondutores. Os testes realizados, em modo *off-line*, apresentaram um considerável desempenho do sistema proposto com média de 95% de acerto para os diagnósticos indicados.

Recentes trabalhos têm buscado o aprimoramento de métodos baseados em SVM no monitoramento de condição de máquinas. Destacam-se neste ponto, Zeng et al (2006), Yuan e Chu (2007) e Zhang, Chen e He (2009), os quais abordam aspectos relacionados à seleção de subconjunto de características dentre o conjunto global disponível e à otimização dos parâmetros utilizados na aplicação de SVM. O objetivo final é a busca de um algoritmo mais eficiente com relação aos quesitos de tempo e de

resposta obtida.

2.1.1.4 Cadeias ocultas de Markov.

Segundo Fraser (2008, p.13) os Modelos Ocultos de Markov, a partir de agora referenciada como HMM, do inglês *Hidden Markov Models*, têm sua origem em aplicações voltadas a problemas na área de processamento de fala e de texto. Estes modelos consistem em um processo estocástico duplo, sendo um processo oculto, não observável que se manifesta por meio de outro processo estocástico que produz a sequência símbolos observados (SANTOS ET AL, 2006).

Um HMM, o qual pode ser representado pela expressão $H = (N, M, p, q, r)$ é caracterizado pelos seguintes elementos: um conjunto N de todos os estados do modelo; um conjunto M de observações distintas por estado; uma distribuição inicial p de probabilidades dos estados; uma distribuição q de probabilidades de transição de estados; e, uma distribuição r das probabilidades de ocorrência de cada observação para cada estado.

Motivados pelo bom desempenho dessa abordagem em processamento de fala, Purushothama, Narayanana e Prasad (2005) propõem HMM combinado com *wavelet* no reconhecimento de padrões para monitoramento de falhas em rolamentos enquanto que Bunks, McCarthy e Tal-Ani (2000) analisam a eficiência desses modelos aplicando-os em dados coletados a partir de dois acelerômetros acoplados na caixa de câmbio do helicóptero Westland.

Outra aplicação em que se pode destacar a utilização de HMM corresponde ao diagnóstico de falhas de máquinas rotativas considerando um processo não estacionário, ou seja, situações as quais a velocidade do maquinário tende a aumentar ou diminuir durante o processo de monitoramento (LI ET AL, 2005; LI ET AL, 2006).

2.1.2 Abordagens baseadas em IA

O termo Inteligência Artificial tem sua origem em 1956, em um seminário

realizado no *Dartmouth College*, em *New Hampshire*, Estados Unidos, o qual contou com a presença de dez pesquisadores. Atualmente, existem inúmeras definições para IA, entretanto, Russell e Norvig (2004, p.2) sugerem quatro categorias as quais estas definições podem ser agrupadas de acordo com pensamento ou comportamento e desempenho humano ou racional, conforme apresentado na Figura 3. As setas indicam as características dos sistemas, conforme a categoria a qual a pesquisa de IA aborda, ou seja, sistemas que pensam ou que agem, no sentido vertical, e sistemas humanos ou racionais, no sentido horizontal.




Figura 3 – Categorias para definição de IA

No entanto, uma clássica definição é aquela a qual apresenta a IA como uma área de conhecimento a qual visa o projeto de sistemas inteligentes capazes de executar tarefas as quais, atualmente, o ser humano desempenha melhor (RICH; KNIGHT, 1994, p.1).

Já Russell e Norvig (2004, p.3) enfatizam o aspecto no qual o campo da IA tenta construir entidades inteligentes, introduzindo o conceito de agentes inteligentes, cuja arquitetura proposta, em sua forma simplificada, é ilustrada na Figura 4. Nesse caso, um agente básico possui um conjunto de sensores responsáveis em obter informações do ambiente, um conjunto de procedimento que processam essas informações, que podem ser simples regras de percepção-ação, até modelos sofisticados de aprendizado dinâmico e um conjunto de atuadores que permite com que o agente interaja e modifique o ambiente. Portanto, as abordagens baseadas em técnicas de IA buscam o desenvolvimento de sistemas inteligentes no contexto mencionado anteriormente.




Figura 4 – Arquitetura básica de um agente inteligente (RUSSELL; NORVIG, 2004, p.34)

Phan e Phan (2001) destacam cinco recursos da IA que, constantemente, vêm sendo aplicadas na área de engenharia e manufatura: Sistemas Baseados em Conhecimento ou Sistemas Especialistas, Lógica Fuzzy, Redes Neurais Artificiais, Algoritmos Genéticos e Aprendizado Indutivo. Especificamente, as quatro primeiras técnicas se destacam na área de manutenção preditiva.

2.1.2.1 Sistemas Especialistas

Um Sistema Especialista (SE) consiste em um sistema construído pela extração do conhecimento adquirido por um especialista humano, codificando-o de uma forma que um computador possa aplicar a problemas similares (LUGER, 2004, p.40). A arquitetura de um SE típico pode ser visualizada na Figura 5. Conforme ilustrado nessa figura, um SE típico é composto pelos seguintes elementos:

- Interface Homem-Máquina: consiste na interface que permite a interação do usuário final com o sistema.
- Editor da Base de Conhecimento: possibilita a correção de possíveis erros na execução do sistema especialista por meio, por exemplo, da inclusão de conhecimento novo, verificação da sintaxe das regras.
- Motor de Inferência: contém as técnicas de busca necessárias para pesquisa dentro da base de conhecimento.
- Base de Conhecimento: contém o conhecimento específico necessário para resolver um dado problema.

- Módulo de Explicação: possibilita a explicação do raciocínio do sistema especialista com relação às consultas realizadas pelo usuário.




Figura 5 – Arquitetura de um SE típico (LUGER, 2004, p.243)

Reys e Pati (2000) destacam a aplicação da IA em quase todos os campos da engenharia, incluindo a manutenção preditiva, por meio da utilização de SEs, apresentando alguns desenvolvidos nos Estados Unidos e no Japão.

Um SE para diagnóstico de falhas chamado EMFDES é proposto por Liu e Liu (2003). O sistema consiste em um SE híbrido o qual combina um sistema especialista, para construção da base de conhecimento representada por uma árvore de decisão, com um método de tomada de decisão baseado em lógica fuzzy, para definir as prioridades de diagnóstico de cada nó da árvore.

Kumar e Prabhu (2000) propõem um SE *off-line* para previsão de condição de um rotor elétrico, a partir das características de vibração extraídas do sistema de rolamento do rotor. Sua base de conhecimento é representada por regras IF-THEN, conforme Figura 6, onde $\text{antecedente}_1 \dots \text{antecedente}_N$ representam os fatos e $\text{consequente}_1 \dots \text{consequente}_M$ representam as conclusões conhecidas. Outro SE baseado em regras IF-THEN é proposto por FAI (2007). O sistema proposto é aplicado ao diagnóstico de falhas em uma máquina automática de soldagem de fios em uma indústria de semicondutores.

IF	(antecedente ₁)
AND	(antecedente ₂)
...	
AND	(antecedente _N)
THEN	(consequente ₁)
AND	(consequente ₂)
AND	(consequente _M)

Figura 6 – Regras IF-THEN para representação do conhecimento (KUMAR, PRABHU, 2000)

Com relação à análise de partículas de desgaste, Roylance et al (1992) e Xu e Luxmoore (1997) apresentam um SE chamado CASPA (*Computer-Aided Systematic Particle Analysis*). A identificação das partículas é realizada por meio de seus atributos morfológicos, tais como cor, espessura, tamanho, textura da superfície, detalhe de borda, que são passados para o sistema CASPA que é capaz de tratar três situações diferentes:

- A partícula é identificada e devidamente classificada.
- Mais de um tipo de partícula é identificado, sendo, para esse caso, executado um procedimento de priorização para decidir qual a classificação final.
- A partícula não pode ser identificada, sendo retornado ao operador um alerta para verificação dos valores inseridos para os atributos morfológicos.

Peng (2002) propõe um sistema inteligente para análise de partícula de desgaste composto por três módulos:

- Sistema de análise de partículas tridimensional: responsável em fornecer alguns atributos, tais como, contagem de partículas, tamanho e forma das partículas, aspereza e textura da superfície, dentre outros.
- Sistema de classificação automático de partículas: responsável em fornecer a classificação das partículas.
- Sistema especialista: responsável em estimar a condição da máquina a qual o óleo foi coletado.

2.1.2.2 Lógica Fuzzy

A Lógica Fuzzy (LF) tem por finalidade o estudo dos princípios formais do raciocínio aproximado (OLIVEIRA JUNIOR ET AL, 2007, p. 1). Consiste em um sistema lógico baseado na manipulação de conjuntos fuzzy, sendo que suas principais regras incluem definições para intersecções, uniões e complementos. Um conjunto fuzzy A consiste em um conjunto de objetos X com elementos denotados por $m(A,x)$, onde cada elemento x tem um correspondente no intervalo $(0,1)$ no conjunto A (RAYNOR, 1999, p.114).

Motivados pela habilidade da LF em simular o processo de decisão humano, Goddu et al (1998) aplicam-na no diagnóstico da condição de rolamento de motores baseando-se em características de frequência de vibração.

Já Marçal e Susin (2005), utilizando o programa Matlab, apresentam um método baseado em LF para detectar falhas incipientes em máquinas rotativas, no caso desbalanceamentos, baseado no padrão de vibração do sistema rotativo analisado, considerando, para isso, a frequência de rotação do eixo volante e as amplitudes de vibrações inerentes. O sistema proposto prevê como resposta quatro situações possíveis: normal, falha incipiente, manutenção e perigo.

Fujimoto (2005) propõe duas metodologias baseadas em LF para automatizar um diagnóstico de falhas: sistema de inferência fuzzy e algoritmo Fuzzy C-Means, a partir de agora referenciado como FCM. O primeiro consiste, simplesmente, em sistemas que utilizam LF (RAYNOR, 1999, p.114). O segundo trata-se de um algoritmo para se obter grupos de similaridades em um conjunto de dados. Nesse caso, cada elemento do banco de dados pertence a um grupo por um determinado grau de pertinência (FUJIMOTO, 2005).

2.1.2.3 Redes Neurais Artificiais

Uma Rede Neural Artificial (RNA) consiste em um modelo computacional baseado na estrutura do cérebro humano, envolvendo, desse modo, o conceito de neurônios e sinapses. Visto que o foco desta pesquisa estar centrado na aplicação de

RNAs, maiores detalhes serão apresentados no Capítulo 4 deste trabalho. Devido a sua natureza apropriada à classificação de padrão, algumas pesquisas têm se voltado para a aplicação dessa técnica para problemas relacionados à CBM em diversos setores.

No setor aeronáutico podem ser citados os trabalhos de Hu et al (2003) e Al-Garni et al (2006). O primeiro avalia uma RNA do tipo Perceptron de Multi-Camadas (MLP, do inglês *Multi-Layer Perceptron*), para diagnóstico de condição de máquina utilizando dados de vibração coletados de sensores em um motor de avião. A RNA proposta busca prever o desequilíbrio do rotor do sistema de propulsão da aeronave. Já o trabalho de Al-Garni et al (2006) propõe uma RNA para previsão de taxa de falhas em pneus do avião de modelo De Havilland Dash-8 fabricado pela empresa canadense Bombardier Aerospace.

No setor marítimo, Morgan et al (2008), em seu sistema denominado *Maersk SEA Mate*, destacam o módulo *Human-Machine Interface* cujo objetivo é proporcionar um aviso de possível mau funcionamento dos motores diesel de curso marítimo. Para isso, é aplicada uma RNA conhecida como Mapas Auto-Organizáveis, a partir de agora referida como SOM, do inglês *Self-Organizing Maps*, que, a partir de dados extraídos de um espectrômetro, executa uma análise de óleo, tendo como base a concentração de ferro e de cobre encontrada na amostra.

Gilabert e Arnaiz (2006) apresentam um estudo de caso no qual propõem um sistema de monitoramento e diagnóstico de um elevador baseado em um RNA sem qualquer conhecimento prévio de problemas existentes.

Para o setor nuclear, por exemplo, Góes, Alvarenga e Melo (2005) apresentam um sistema chamado NAROAS (*Neural Network Advanced Reliability Advisory System*) para monitoramento de aplicações em uma usina de energia nuclear. O programa desenvolvido é um sistema de apoio a decisão para situações de falha de componentes, determinando teste e políticas de manutenção durante o estado normal de operação da usina e controle de diferentes configurações do sistema para intervenções o mais rápido possível na usina, quando necessárias.

Ainda no âmbito nuclear, a fim de evitar uma possível queda de desempenho da manutenção devido ao desgaste mental da equipe de engenheiros de manutenção Liang et al (2009) propõem um modelo baseado em uma RNA para prever a carga de

trabalho mental dos engenheiros em sistemas de manutenção digitais e possibilitar a organização dos recursos humano para as tarefas diárias de manutenção

Com relação à análise de óleo, as RNAs vêm se destacando como técnica principal de IA nas pesquisas relacionadas à análise de óleo. Nesse sentido, destacam-se os trabalhos do Dr. Mohammad Shakeel Laghari do Departamento de Engenharia Elétrica da Universidade dos Emirados Árabes Unidos (LAGHARI, 2003, LAGHARI; MENON; KHUWAJA, 2004, MENON; LAGHARI, 2005; MENON; LAGHARI, 2007).

Outro foco no qual as RNAs se destacam é monitoramento de máquina baseado em sinais de vibração. McCormick e Nandi (1997), Samanta e Al-Balushi (2003) utilizam características do domínio do tempo como entrada de uma RNA do tipo MLP com duas camadas ocultas para detecção de ausência ou presença defeitos em rolamentos de máquinas rotativas. Rafiee et al (2007) apresentam uma MLP para reconhecimento de falhas em engrenagens e rolamentos de um sistema de engrenagem considerando quatro condições: normal, desgaste suave e médio e dentes quebrados.

2.1.2.4 Algoritmos Genéticos

A Computação Evolutiva é uma área da Ciência da Computação que engloba um amplo conjunto de técnicas de resolução de problemas que se baseiam na simulação computacional de processos derivados da biologia como reprodução e evolução, à luz da teoria de Darwin (GEN; CHENG, 1997, p. 1). Dentre os algoritmos que compõem a Computação Evolutiva destacam-se: Programação Evolutiva (FOGEL ET AL, 1966), Estratégias Evolutivas (RECHENBERG, 1973), Programação Genética (KOZA, 1992) e os Algoritmos Genéticos (HOLLAND, 1972).

Dentre esses algoritmos os Algoritmos Genéticos (AG) podem ser considerados os mais conhecidos e utilizados (GEN; CHENG, 1997, p. 1). Man e Tang (1997) descrevem a abrangência de aplicações envolvendo AG na área de controle e processamento de sinais.

Nas pesquisas voltadas à manutenção preditiva, AG se destacam como métodos para seleção de configuração ideal de parâmetros para entrada de RNAs buscando um

melhor desempenho no processo de diagnóstico executado por essas redes (JACK; NANDI, 2003, SAMANTA, 2004).

Outra técnica evolucionária com interessantes resultados é a Programação Genética (PG). Nesse aspecto, pode-se citar o trabalho de Chen et al (2005) que propõe um algoritmo baseado em PG para diagnóstico de falhas em máquina utilizando características de espectro de potência.

2.2 Manutenção baseada em prognóstico

Para a categoria de programas voltados para o prognóstico Jardine, Lin e Banjevic (2006) enfatizam o menor número de pesquisas nesta área, apresentando três tipos básicos: estimativa do tempo de vida útil restante da máquina, a partir de agora referida com RUL, do inglês *Remaining Useful Life*, políticas de manutenção incorporando prognósticos e determinação de intervalo de monitoramento de condição.

2.2.1 Estimativa RUL

A estimativa RUL compreende na previsão do tempo restante de um sistema, uma estrutura ou um componente antes deste se tornar incapaz de executar a sua função (JARDINE; LIN; BANJEVIC, 2006). Os mesmos autores classificam em três tipos as abordagens para esse tipo de prognóstico: estatísticas, IA e baseada em modelos.

Um modelo estatístico utilizando SPC é apresentado por Goode, Roylance e Moore (1998). O modelo é utilizado para definição do padrão de falha dividido em duas fases distintas: estável e instável. Na zona estável utiliza-se uma formulação para monitoramento das medidas a fim de prever o tempo de vida da máquina; na zona instável, ou seja, quando um problema é encontrado, aplica-se uma formulação a fim de estimar o tempo para que a falha ocorra.

Na linha de IA, Goh et al (2006) destacam as técnicas AG, LF, RNA e SE. Por exemplo, Xue et al (2008) investigam modelos fuzzy a fim de estimar o RUL de uma

máquina ou de seus componentes. O modelo proposto define um agrupamento de pares, cada qual sendo uma instância da máquina com características operacionais comparáveis. Desse modo, a estimativa RUL é obtida pela agregação fuzzy destes pares. Zi e Di Maio (2010) apresentam uma arquitetura computacional projetada para integração *on-line* de dados monitorados em um cenário dinâmico de falha de uma usina nuclear. Seu funcionamento baseia-se em um conjunto padrão de falhas coletado em uma biblioteca de referência da qual se executa uma análise de similaridade orientada a dados baseada em LF a fim de se prever a vida restante de uma trajetória de falha.

Uma interessante aplicação baseada em IA é proposta por Tian, Wong e Safaei (2010). Neste trabalho, é desenvolvida uma RNA utilizando histórico de monitoramento de condição de falhas e de interrupção como entrada da rede, tendo como saída uma estimativa da porcentagem relativa ao tempo de vida da máquina.

Li e Lee (2005) propõem um método baseado em modelo para prever o tempo de vida restante de uma engrenagem com uma trinca de fadiga o qual considerou um modelo embutido para identificar a rigidez da engrenagem, estimar o tamanho da trinca, simular a dinâmica da engrenagem e prever o tempo de vida baseado no tamanho da trinca estimado e da carga dinâmica.

2.2.2 Políticas de manutenção incorporando prognósticos

Uma política de manutenção incorporando prognósticos consiste em otimizar as políticas de manutenção de acordo com um determinado critério tal como, risco, custo, confiabilidade e disponibilidade (JARDINE; LIN; BANJEVIC, 2003).

Maillart e Pollock (2002) analisam uma política de manutenção de minimização de custos para determinar quando o monitoramento deveria ser realizado e para definir alocação de recursos para sistemas múltiplos. A solução proposta baseia-se na decomposição do custo esperado em dois componentes: o custo devido a ações de manutenção e o custo esperado devido a ações de monitoramento.

Outro modelo baseado em custo é proposto por Barros, Bérenguer e Grall (2003). A proposta concentra-se em um modelo de custo estocástico desenvolvido para

calcular e otimizar o desempenho da política de manutenção de acordo com o custo de manutenção total esperado.

2.2.3 Especificação de intervalo de monitoramento de condição

Jardine, Lin e Banjevic (2003) definem intervalo de monitoramento de condição como o intervalo P-F dividido por um inteiro. O intervalo P-F consiste no intervalo de tempo entre uma falha potencial (P) e uma falha funcional (F) (MOUBRAY, 1997, p.145).

Wang (2003) sugere um procedimento a ser executado em dois estágios. Primeiramente, é proposto um modelo estático usado para determinar um intervalo de monitoramento de condição sobre a vida do item. Quando a informação monitorada indicar a possibilidade de alguma anormalidade deste item, uma abordagem dinâmica é aplicada para determinar a próxima marca de monitoramento no ponto atual dado que o item não esteja agendado para uma troca preventiva antes deste tempo.

Goode, Roylance e Moore (2000) utilizam um modelo de padrão de falhas dividido em duas fases, estável e instável, utilizado em pesquisas anteriores (GOODE; ROYLANCE; MOORE, 1998, GOODE; MOORE; ROYLANCE, 2000), para determinar o tamanho do próximo intervalo de monitoramento de condição para um dado nível de risco.

3 MANUTENÇÃO BASEADA NA CONDIÇÃO

Segundo Mobley (2002, p. 4) existem diferentes definições para a manutenção preditiva ou CBM, dependendo da abordagem utilizada – dados de vibração, imagem infravermelha. Contudo, pode-se destacar aquela apresentada por Kobacy e Murthy (2008, p. 52): “é uma estratégia baseada na política do limite da falha, na qual a manutenção é realizada somente quando uma taxa de falha ou outro índice de confiabilidade de uma unidade alcança um nível pré-determinado”.

Devido à filosofia desse tipo de manutenção estar centrada no acompanhamento do estado da máquina, Reis e Pati (2000) apontam quatro vantagens marcantes da CBM: prolongamento do período de troca de peça de um equipamento, melhoria nas condições de segurança de trabalho, prevenção de acidentes e aumento na confiabilidade.

Kobacy e Murthy (2008, p.52) enfatizam que “o sucesso de um programa CBM depende da integração de várias informações: dados de diagnóstico e de desempenho disponíveis, histórico de manutenção, registro de operadores de máquinas e dados de projetos para tomada de decisões sobre requisitos de manutenção de equipamentos críticos”. Segundo Lee et al (2004) um programa de CBM ideal pode ser dividido em três passos básicos, aquisição de dados, processamento de dados e tomada de decisão de manutenção, conforme ilustrado pela Figura 7.




Figura 7 – Três passos em um programa CBM (LEE ET AL, 2004).

A aquisição de dados é o processo no qual as informações sobre o estado de um equipamento são coletados por meio de sensores diversos. Em geral, um sensor pode ser definido como um dispositivo que converte uma quantidade física em uma quantidade elétrica (voltagem, corrente ou resistência) (AUSTERLITZ, 2003, p. 2). Dentre os inúmeros tipos de sensores pode-se citar: acelerômetros, sensores ultrassônicos, sensores de temperatura, sensores ópticos, dentre outros. Jardine, Lin e

Banjevic (2006) identificam os dados coletados em três categorias:

- Valor: caracterizam-se por ser um valor único, incluindo-se nessa classe, dados de análise de óleo, de temperatura e de pressão.
- Forma de Onda: consiste em uma série de dados coletados em um dado intervalo de tempo, sendo esses considerados como um todo, podendo-se incluir nessa classe, dados de vibração e dados acústicos.
- Multidimensional: são dados de mais de uma dimensão, representados, geralmente, por meio de matrizes, incluindo-se nessa categoria dados de imagem.

O processamento de dados, também conhecido como processamento de sinais, quando esses são dos tipos em forma de onda ou multidimensionais, consiste em analisar, modificar ou extrair informações desses dados (KUO, LEE, 2001, p. 1). Nessa etapa é possível eliminar possíveis ruídos decorrentes de defeitos de sensores ou de agentes externos e obter características relevantes dos dados coletados por meio de uma determinada técnica (HAYES, 1996, p. 1).

Jardine, Lim e Banjevic (2006) caracterizam esta etapa em duas tarefas distintas: limpeza e análise dos dados. A primeira visa eliminar possíveis erros nos dados coletados, tais como, fatores humanos, ruídos, falhas nos sensores e a segunda consiste na aplicação de algoritmos e modelos para melhor entendimento e interpretação dos dados. Nesse caso o tipo de algoritmo ou modelo a ser aplicado depende, essencialmente, do tipo de dado coletado.

A última etapa, a tomada de decisão de manutenção, compreende em analisar as características geradas e estabelecer o estado atual da máquina, procurando identificar possíveis problemas.

Para a implementação de um programa CBM, Mobley (2002, p. 99) sugere as seguintes técnicas: monitoramento de vibração, tribologia, termografia, inspeção visual, ultrassonografia. As seções seguintes apresentam os detalhes das duas primeiras técnicas, foco deste trabalho, e um breve descritivo das demais técnicas.

3.1 Monitoramento de vibração

Esta técnica é descrita como a principal e a mais utilizada na manutenção preditiva (MOBLEY, 2002, p. 99; SCHEFFER, GIRDHAR, 2004, p. 8; MOBLEY, 2008, p. 2.22; KOBACY, MURTHY, 2008, p. 113) e, às vezes, até citada como sinônimo de manutenção preditiva (MOBLEY, 2002, p.114).

Vibração pode ser definida como uma flutuação de um sistema mecânico ou estrutural sobre uma posição de equilíbrio iniciada quando um elemento de inércia é deslocado de sua posição de equilíbrio devido a uma energia transmitida ao sistema por meio de uma fonte externa (KELLY, 2000, p. 1). Uma vibração é um movimento periódico ou que se repete após um dado intervalo de tempo denominado de período T da vibração. O inverso do período é chamado de frequência, f , da vibração, expresso em ciclos por segundo (cps) ou *Hertz* (Hz).

O monitoramento de vibração consiste, basicamente, em se determinar duas quantidades: a magnitude da vibração e a faixa de frequência. A primeira é utilizada para descrever a severidade da vibração enquanto que a segunda está relacionada à sua causa ou origem (KOBACY, MURTHY, 2008, p. 113).

Esta abordagem se baseia no conceito que vibrações mecânicas de diversas frequências que estão relacionadas às origens identificáveis na máquina e podem ser utilizadas para fornecer uma indicação da condição de máquina (NANDI; TOLIYAT, 1999), destacando-se a detecção de defeitos ou deterioração em rolamentos, de folga mecânica e de desgaste e trinca em engrenagens (SCHEFFER, GIRDHAR, 2004, p. 8).

Portanto, pode-se dizer que o objetivo da análise de vibrações é possibilitar a separação e identificação de todas as vibrações, separando-as em frequências e associando-as a suas respectivas origens, visando identificar o que e onde algo está ocorrendo. Segundo Scheffer e Girdhar (2004, p. 89) os seguintes defeitos de máquinas podem ser detectados utilizando monitoramento de vibrações: desbalanceamento de rotor, eixo dobrado, excentricidade, desalinhamento, folga, problemas de acionamento de correias, defeitos em engrenagens e rolamentos, falhas elétricas, cavitação e rachaduras de eixos.

3.1.1 Aquisição de dados

No que diz respeito ao monitoramento de vibrações a coleta de dados é realizada com a utilização de sensores ou transdutores de vibração que convertem movimentos físicos da máquina, na qual são fixados, em sinais elétricos. Os três tipos de sensores mais comuns são:

- Sensor de proximidade: é utilizado para medir a distância entre a extremidade da sonda do sensor a um determinado ponto alvo no eixo da máquina. Converte deslocamento para milésimo de polegada (mils) ou milésimo de milímetro (microns). A Figura 8 ilustra um exemplo de sensor de proximidade, no caso o sensor *Senturium* desenvolvido pela empresa inglesa *Sensonics Ltd*.



Figura 8 – Exemplo de sensor de proximidade – modelo *Senturium* (SENSONICS, 2010).

- Sensor de velocidade (*pickup*): mede a velocidade em polegadas por segundo ou milímetros por segundo. Consiste de uma bobina ou fio metálico e um ímã dentro de um revestimento não condutivo que produz um sinal que proporcional à vibração ou movimento inicial. A Figura 9 ilustra um exemplo de sensor de velocidade, no caso o sensor *PZDC 4-20mA Loop Powered* desenvolvido pela empresa inglesa *Sensonics Ltd*.



Figura 9 – Exemplo de sensor de velocidade – modelo *PZDC 4-20m* (SENSONICS, 2010).

- Acelerômetro: mede a aceleração em termos da aceleração da gravidade (g).

Em sua forma mais simples, consiste de um cristal piezo-elétrico disposto entre sua base e uma quantidade pré-determinada de massa que produz um sinal elétrico quando um movimento físico é aplicado ao sensor. A Figura 10 ilustra um exemplo de acelerômetro, no caso o modelo PZHT *High Temperature Range* desenvolvido pela empresa inglesa *Sensonics Ltd*.



Figura 10 – Exemplo de acelerômetro – modelo PZHT *High Temperature Range* (SENSONICS, 2010).

3.1.2 Processamento de sinais

Uma importante questão quando se aplica técnicas de reconhecimento de padrão para análise de vibrações é decidir qual método para extração de características a ser utilizado, sendo este processo considerado crítico para uma efetiva detecção e diagnóstico de falhas (UNAL, 1994). A literatura apresenta dois principais tipos para análise de dados de vibração: análise no domínio do tempo, análise no domínio da frequência (BADAoui ET AL, 2001; PAN, VAN BRUSSEL, 2003; CHEFFER, GIDAR, 2004, p. 19; NIU, ZHU, DING, 2005; HE, KONGA, YAN, 2007; MOBLEY, 2008). As seções seguintes apresentam um breve descritivo sobre a essência com relação a cada tipo de análise.

3.1.2.1 Análise no domínio do tempo

Um sinal no domínio do tempo ou na forma de onda no tempo, em termos de vibração, consiste em um gráfico do deslocamento, velocidade ou aceleração com relação ao tempo (SCHEFFER, GIRDHAR, 2004, p. 64). A Figura 11 ilustra um exemplo de sinal representado no domínio do tempo.




Figura 11 – Exemplo de sinal no domínio do tempo

Para uma análise no domínio do tempo bem conduzida, é necessária a configuração de um conjunto de parâmetros a fim de se obter dados que permitam uma boa análise da amplitude da vibração. Scheffer e Girdhar (2004, p. 66) destacam os seguintes parâmetros:

- Unidade de medida: refere-se à característica de vibração de interesse, no caso, deslocamento medido em microns, velocidade em mm/s-pk ou aceleração em g. Essa medida está associada ao tipo de sensor utilizado para coleta dos dados.
- Tempo de amostragem: para se obter um conjunto de dados utilizáveis para análise, o instrumento deve se ajustado para medir 5 ou 10 ciclos da onda de vibração ou rotações da máquina sendo medida. Deste modo, o total de tempo de amostragem, em microsegundos (ms), desejado pode ser calculado pela equação 4. Por exemplo, para uma máquina com velocidade de 1200 rpm e considerando número de rotações de 5 ciclos, o tempo mínimo de amostragem necessário seria de 250 ms.

$$\text{Tempo de Amostragem} = 60000 \times \text{número de rotações /rpm} \quad (4)$$

- Resolução: está relacionada à quantidade de pontos utilizada para divisão da amostra total em segmentos para análise. A literatura sugere segmentos de tamanho 1024 (MENDEL ET AL, 2008, SAMANTA; AL-BALUSHI, 2003)

ou 2048 (MACCORMICK, NANDI, 1997, SAMANTA, 2004, WANG ET AL, 2008).

- Média: técnica utilizada em análise de sinais com o objetivo de eliminar frequências não síncronas, tais como interferência de outras máquinas ou ruído.
- Janela: consiste em uma operação matemática realizada durante o processamento dos dados amostrais com o objetivo de reduzir erros provocados pelo truncamento - a amostragem insuficiente de um sinal para defini-lo com precisão.

A técnica mais direta para análise no domínio do tempo consiste na inspeção visual de porções de forma de onda no domínio do tempo. Entretanto, McFadden (1990) destaca ser pouco provável identificar determinados defeitos, como por exemplo, rachaduras em rolamentos, por uma simples inspeção visual.

Como consequência da limitação, anteriormente citada, Niu, Zhu e Ding (2005) ressaltam a necessidade de técnicas mais sofisticadas como a utilização de determinados parâmetros estatísticos calculados a partir dos dados coletados. Alguns autores apontam as características estatísticas como importantes ferramentas para monitoramento de condição de máquinas para previsão e detecção de falhas (PAPOULIS, 1991, NIKIAS; MENDEL, 1993, NANDI, 1999).

Diversas pesquisas (MCFADDEN, 1990, MCCORMICK; NANDI, 1997, JACK, NANDI, 2000, SAMANTA; AL-BALUSHI, 2003, SAMANTA, 2004, NIU; ZHU; DING, 2005, JARDINI, LIN, BANJEVIC, 2006, RAFIEE ET AL, 2007) propõem, considerando um conjunto de amostras x_i de tamanho N , os seguintes parâmetros estatísticos: média, variância, curtose, assimetria, momentos de ordem superior (quinta a nona ordem), valor quadrático médio (rms do inglês *root mean square*), valor de pico, valor pico-a-pico, fator de crista, fator de impulso, fator de forma, fator de folga. As equações 5 a 16 apresentam, respectivamente, a formulação de cada um destes parâmetros.

$$\mu = \frac{\sum_{i=1}^N x_i}{N} \quad (5)$$

$$\sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N} \quad (6)$$

$$cur = \frac{\frac{\sum_{i=1}^N (x_i - \mu)^3}{N}}{\sigma^3} \quad (7)$$

$$ass = \frac{\frac{\sum_{i=1}^N (x_i - \mu)^3}{N}}{\sigma^3} \quad (8)$$

$$m^k = \frac{\frac{\sum_{i=1}^N (x_i - \mu)^k}{N}}{\sigma^k} \quad (9)$$

$$rms = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (10)$$

$$vpi = \text{MAX}(x_1, \dots, x_N) \quad (11)$$

$$vpp = \text{MAX}(x_1, \dots, x_N) - \text{MIN}(x_1, \dots, x_N) \quad (12)$$

$$fcr = \frac{vpi}{rms} \quad (13)$$

$$fim = \frac{pv}{\frac{\sum_{i=1}^N |x_i - \mu|}{N}} \quad (14)$$

$$ffr = \frac{rms}{\frac{fim}{N}} \quad (15)$$

$$ffl = \frac{pv}{\frac{\left(\sqrt{\sum_{i=1}^N |x_i - \mu|}\right)^2}{N}} \quad (16)$$

Almeida (2007) identifica alguns aspectos relevantes dos parâmetros estatísticos com relação à análise de vibrações:

- O valor de pico tem sua importância na medida das respostas dos sistemas a choques mecânicos.
- O valor rms relaciona diretamente com a energia do sinal explicitando a capacidade destrutiva da vibração.
- O fator de crista permite detectar falhas em rolamentos por meio de relações de amplitudes dos sinais de vibrações.
- A curtose apresenta valor próximo de 3 para componentes em estado normal e esse valor aumenta conforme a degradação do componente também aumenta, ou seja, conforme uma falha torna-se mais acentuada.
- O valor pico a pico é útil nas considerações de folgas e tensões dinâmicas geradas pela vibração.
- O fator de folga é sensível para detecção de fragmentação por fadiga incipiente.

3.1.2.2 Análise no domínio da frequência

Dados no domínio da frequência são obtidos pela conversão de dados no domínio do tempo por meio de uma técnica matemática conhecida como Transformada Rápida de Fourier (FFT - *Fast Fourier Transform*) (MOBLEY, 1999, p. 10). Resumidamente, Smith (1999, p. 228) descreve o algoritmo da FFT da seguinte forma:

“A FFT funciona, inicialmente, decompondo um sinal composto por N pontos no domínio do tempo em N sinais no domínio do tempo, cada qual composto por um simples ponto. O segundo passo é calcular os N espectros de frequência correspondentes a estes N sinais no domínio do tempo. No último passo, os N espectros são resumidos em um simples espectro de frequência.” (SMITH, 1999, p. 228, tradução nossa).

Mobley (2002, p. 149) destaca que a vantagem da análise no domínio da frequência é a habilidade de normalizar cada componente de vibração tal que um espectro de conjunto de máquina pode ser dividido em componentes discretos, o que permite simplificar o isolamento e análise de degradação mecânica dentro do conjunto de máquina.

A técnica de análise no domínio da frequência mais comumente utilizada é a análise de espectro por meio da FFT (MACFADDEN; SMITH, 1984, BANISTER, 1985, MECHEFSKE; MATHEW, 1992, CHEN ET AL, 2005), cuja ideia principal é ou analisar o espectro como um todo ou para determinados componentes de interesse, extraindo características do sinal (JARDINE; LIN; BANJEVIC, 2006). Adicionalmente, os mesmos autores citam o espectro de potência como a ferramenta mais utilizada na análise de espectro.

Outro método de análise no domínio da frequência é a análise de envelope. Ela oferece um mecanismo para se extrair excitação periódica ou modulação de amplitude da ressonância (HOWARD, 1994). Detecção de envelope ou demodulação de amplitude consiste na técnica de extrair a modulação do sinal a partir de um sinal de amplitude modulado. O resultado é a evolução temporal da modulação do sinal (KONSTANTIN-HANSEN, 2011).

Courrech e Eshleman (2002) apontam as seguintes vantagens na utilização da análise de envelope:

- O uso de filtros passa banda elimina ruídos de fundo resultantes de outras fontes de vibração, tais como, desequilíbrio ou vibração de engrenagem.
- Não é necessária análise de alta frequência uma vez que somente o envelope do sinal é importante.
- É possível efetuar o diagnóstico visto que as frequências de impacto são determinadas e podem ser relacionadas a uma fonte.

3.1.3 Aplicações

Equipamentos mecânicos, incluindo todos os tipos de máquinas rotativas, alternativas, e outros equipamentos ou sistemas que são compreendidos de componentes em movimento ou ações dinâmicas relacionadas a processos, podem ser avaliados utilizando-se técnicas de monitoramento de vibrações (MOBLEY, 2008), entretanto, as máquinas rotativas se destacam como a fonte mais comum de vibrações (MOBLEY, 2002, p. 122).

Segundo IAEA (2007, p. 19) e Scheffer e Girdhar (2004, p.89), a análise de vibração possibilita o monitoramento das seguintes condições de máquinas rotativas:

- Rachadura, corrosão e aspereza em rolamentos.
- Desbalanceamento de partes de máquinas rotativas.
- Desalinhamento de eixo.
- Problemas na transmissão por correia.
- Problemas de acoplamento.
- Dobra e rachaduras em eixos.
- Desgaste do rolamento.
- Peças soltas.
- Dentes de engrenagens desalinhados ou danificados.
- Deterioração causada por quebra ou peças soltas.
- Deterioração causada por erosão e corrosão.
- Ressonância de componentes.
- Falhas elétricas.

Contudo, estudos apontam que a maioria dos problemas em máquinas rotativas é causada devido a falhas nos mancais de rolamentos e alguns autores enfatizam que esses representam 40% das ocorrências de falhas dentro de uma máquina (BONALDI; OLIVEIRA; SILVA, 2008, LI; WU, 1989, NIU; ZHU; DING, 2005, SHIROISHI ET AL, 1997).

Existem diversos tipos de mancais de rolamentos cada qual com sua geometria única, entretanto, o princípio para cálculo das características desta geometria é único. Uma representação esquemática de um típico mancal de rolamento é apresentada na Figura 12, onde: D corresponde ao diâmetro primitivo do mancal de rolamento; D_i ao diâmetro da pista interna; D_o ao diâmetro da pista externa; α ao ângulo de contato, d ao diâmetro da esfera; ω_i à velocidade angular da pista interna, ω_o à velocidade angular da pista externa; ω_c à velocidade angular da esfera; V_i à velocidade tangencial da pista interna; V_o à velocidade tangencial da pista externa; e V_c à velocidade tangencial da esfera.




Figura 12 – Representação esquemática de mancal de rolamento (WANG, 1996).

Segundo Taylor (1994), os pontos mais comuns de falhas em mancais de rolamentos são: pista externa, pista interna, esfera e gaiola. Considerando que na maioria das vezes a pista externa do mancal de rolamento é estacionária, suas equações de frequência podem ser representadas pelas equações 17 a 20 (WANG, 1996), respectivamente, onde: Z corresponde ao número de elementos rolantes e f_i a frequência da pista interna.

$$f_{dpi} = \frac{zf_i}{2} \left(1 + \frac{d}{D} \cos(\alpha) \right) \quad (17)$$

$$f_{dpe} = \frac{zf_i}{2} \left(1 - \frac{d}{D} \cos(\alpha) \right) \quad (18)$$

$$f_{de} = \frac{f_i D}{2 d} \left(1 - \left(\frac{d}{D} \cos(\alpha) \right)^2 \right) \quad (19)$$

$$f_{dg} = \frac{f_i}{2} \left(1 - \frac{d}{D} \cos(\alpha) \right) \quad (20)$$

3.2 Tribologia

De forma sucinta, Brushan (2001, p. 5) define Tribologia como o estudo da interação entre superfícies de contato. Stachowiak e Batchelor (2001, p. 2) propõem uma definição mais detalhada sobre seu objeto de estudo, apresentando-a com uma área que se concentra na fricção, no desgaste e na lubrificação de superfícies interagindo em movimento relativo. Essa nova área foi definida em 1967 por um comitê da Organização para Cooperação e Desenvolvimento Econômico – entidade fundada em 1961 com o objetivo de estimular o progresso econômico e o comércio mundial (OECD, 2010), e seu nome tem sua origem da palavra grega *tribos* cujo significado é fricção ou deslizamento.

De fato, o desgaste pode ser apontado como um fator em potencial que pode ocasionar desperdício de material e perda de desempenho do maquinário e Stachowiak e Batchelor (2001, p. 2) destacam a fricção como o principal causador de desgaste e dissipação de energia. Nesse sentido, a devida lubrificação se torna fundamental para a redução da fricção e controle do desgaste de máquinas.

Diminuindo a força empregada para determinada tarefa, é reduzida também a energia consumida, de forma que, se todas as indústrias empregassem estudos de tribologia em seus processos, o consumo de energia seria menor, beneficiando o meio ambiente. O consumo de energia tem se tornado uma preocupação global; é estimado que mais de um terço de toda energia produzida do mundo é consumida por fricção excessiva e desgaste em produtos existentes e em tecnologias de manufatura (DELAWARE, 2011).

Dentre as técnicas de Tribologia para CBM podem ser citadas: análise de óleo

lubrificante, análise espectrográfica, ferrografia e análise de partículas de desgaste. Essas serão descritas nas subseções seguintes, dando-se ênfase na análise de partículas de desgaste pelo fato de ser um dos focos deste trabalho.

3.2.1 Análise de óleo lubrificante

Conforme está implícito no nome, essa técnica se baseia na análise de óleos lubrificantes utilizados em equipamentos mecânicos e elétricos. As atividades primárias para aplicação dessa técnica são o controle de qualidade, a redução de inventário de lubrificação de óleo e a determinação de um maior intervalo de custo efetivo para troca de óleo (MOBLEY, 2002, p. 108).

Ai e Moyer (2001, p. 1056) destacam que a contaminação de óleo lubrificante é uma das principais causas de danos na superfície de rolamentos. Como técnica preditiva a análise de óleo lubrificante pode ser utilizada como suporte para alterações nos intervalos de troca de óleo com base em análises periódicas de sua condição.

Mobley (2008b) apresenta 10 testes a serem conduzidos em se tratando de análise de óleo lubrificante: viscosidade, contaminação, diluição do combustível, teor de sólidos, fuligem de combustível, oxidação, nitração, número ácido total, número base total, contagem de partículas.

3.2.2 Análise espectrográfica

A análise espectrográfica consiste de um método que permite obter precisão e rápidas medidas de muitos dos elementos presentes em óleo lubrificante, tais como, metais de desgaste, contaminantes e aditivos. A Tabela 6 apresenta um resumo dos metais que podem ser identificados utilizando-se técnicas espectrográficas bem como as possíveis origens.

Tabela 6 – Origens de metais de desgaste (COWAN; WINER, 2001, tradução nossa)

Elemento	Possível origem
Alumínio	Rolamento, mancal de pedestal, palheta de compressor, ventoinha, pistão, palheta de bomba, rotor.
Antimônio	Rolamento, graxa.
Cromo	Válvula exausta, engrenagem, mancal de borracha, anel do mancal, biela, rolamento, retentor, eixo
Cobre	Mancal, casquilho, revestimento do cilindro, arruela de tração.
Ferro	Mancal, mancal de pedestal, eixo de transmissão do came, embreagem, cilindro, manivela do eixo, engrenagem, mancal de borracha, pistão, bomba, anel, eixo, tem de válvula
Chumbo	Rolamento, aditivo de óleo, retentor, solda
Magnésio	Aditivos de óleo, eixo, válvula
Molibdênio	Aditivos de óleo, anel de segmento
Níquel	Engrenagem, rolamento de esfera, eixo de transmissão, palheta de turbina
Silício	Junta, sujeira, selante.
Prata	Rolamento, eixo de transmissão, solda
Estanho	Rolamento, casquilho, retentor, solda, engrenagem helicoidal
Titânio	Rolamento, palheta de compressor, palheta de turbina
Zinco	Rolamento, refrigerador, aditivo de óleo

3.2.3 Ferrografia

Ferrografia consiste em uma técnica na qual as partículas de desgaste são separadas do lubrificante e organizadas conforme o tamanho em um substrato transparente para análise, o qual permite posterior observação das partículas. O tamanho da partícula varia entre 1 a 100 μm (LAGHARI, 2003).

Esta técnica se assemelha com a espectrografia, tendo como diferença dois aspectos importantes:

- Ela separa as partículas de contaminação utilizando um campo magnético ao invés da queima de uma dada amostra como é feita na análise espectrográfica.
- Ela é capaz de separar e analisar partículas de contaminação maiores que 100 microns proporcionando uma melhor representação da contaminação total do óleo, diferente da análise espectrográfica que só manipula partículas de até 10 microns.

3.2.4 Análise de partículas de desgaste

Desgaste pode ser definido como a progressiva perda de substância resultante da interação mecânica de duas superfícies de contato (NEALE, 1995). Partículas

microscópicas de desgaste são produzidas em todas e quaisquer máquinas que possuam partes que se movimentam e ficam em contato uma com a outra. Nos primeiros momentos em que uma nova máquina é utilizada ou novas peças são inseridas e/ou trocadas na mesma, uma quantidade muito grande de partículas é gerada devido ao contato com essas peças novas.

Contudo, após um período de uso da referida máquina, um estado de equilíbrio existe e, conseqüentemente, uma quantidade relativamente menor de partículas é gerada. Qualquer desequilíbrio que possa existir nesse estado também poderá afetar a quantidade relativamente normal de partículas geradas e, a partir desse ponto, profissionais recolhem uma amostra do óleo que transporta essas partículas para uma posterior análise (LAGHARI, 2003).

3.2.4.1 Tipos de partículas de desgaste

A seguir, são descritos alguns exemplos de partículas de desgaste (LAGHARI, 2003; NEALE, 1995):

- Partículas por fricção: são as mais comuns na análise do lubrificante das máquinas. Geralmente, são geradas por deslizamento normal entre peças, usualmente em forma de plaquetas, e possuem um tamanho máximo de 15 μ m, além de uma textura suave em sua superfície (NEALE, 1995; MOBLEY, 2008b). A Figura 13 ilustra um exemplo de partícula de desgaste por fricção.



Figura 13 – Exemplo de partícula de desgaste por fricção (LUBROSOFT, 1997)

- Partículas por abrasão, *cutting wear*: geradas após a superfície de um determinado objeto penetrar a superfície de outro. Possuem a forma geométrica de espirais, curvas ou longos fios curvados. A presença desse tipo de partícula

indica que a máquina em questão está prestes a apresentar algum tipo de defeito e seu tamanho pode variar entre 2 a 5 μm de largura e 25 a 100 μm de comprimento (NEALE, 1995; MOBLEY, 2008b). A Figura 14 ilustra um exemplo de partícula de desgaste por abrasão.



Figura 14 – Exemplo de partículas de desgaste por abrasão (LUBROSOFT, 1997)

- Partículas por fadiga, *fatigue wear*: surgem de superfícies que estão sob tensão, e podem ser encontradas, tanto em formato esférico, quanto em formato de lâminas. As esféricas são associadas a rolamentos na superfície sob tensão e se desprendem de aberturas que se formaram nessa, possuindo um tamanho máximo de 3 μm de diâmetro. As que são em formato de lâminas são partículas muito finas e se desprendem da superfície sob tensão, apresentando uma dimensão entre 20 a 50 μm . (NEALE, 1995; MOBLEY, 2008b). A Figura 15 ilustra um exemplo de partícula de desgaste por fadiga.




Figura 15 – Exemplo de partículas de desgaste por fadiga (LUBROSOFT, 1997)

- Partículas por deslizamento severo, *severe sliding wear*: são partículas que geralmente possuem estrias em sua superfície, causadas por carga ou calor excessivo em um sistema de engrenagem e medem em média cerca de 20 μm , além de possuir bordas retas (NEALE, 1995; MOBLEY, 2008b). A Figura 16 ilustra um exemplo de partícula de desgaste por deslizamento severo.



Figura 16: Exemplo de partículas de desgaste por deslizamento severo (LUBROSOFT, 1997)

- Partículas de materiais cristalinos, *crystalline material*: são partículas brilhantes como, por exemplo, grãos de areia, que podem ser percebidos quando a direção da luz incidente na amostra analisada varia. Podem ser encontradas no atrito de materiais metálicos contra materiais cerâmicos (NEALE, 1995). A Figura 17 ilustra um exemplo de partículas referente a metais cristalinos.




Figura 17 – Exemplo de partículas de materiais cristalinos (NEALE, 1995)

- Partículas por rolamentos e deslizamentos, *rolling and sliding wear*: não são tão comuns quanto às outras citadas anteriormente, e surgem devido à combinação de fadiga com deslizamentos e, geralmente, estão associadas com engrenagens (NEALE, 1995; MOBLEY, 2008b). A Figura 18 ilustra um exemplo de partículas referente a desgaste por rolamento e deslizamento.




Figura 18 – Exemplo de partículas de desgaste por rolamento e deslizamento (NEALE, 1995)

O relacionamento entre as propriedades das partículas de desgaste e a condição de máquina a qual é responsável por sua geração e pode ser classificado de várias maneiras. Segundo Laghari (2003) partículas podem ser divididas em termos de: seu tamanho, que fornece a taxa, o tipo e a severidade referente ao fator gerador destas partículas; sua quantidade, que fornece a severidade e a taxa referente ao fator gerador destas partículas; seu formato, que indica a fonte, o tipo e a taxa de geração; e sua composição, que indica a fonte geradora das partículas. A Figura 19 apresenta um diagrama de blocos da relação entre características das partículas e o modo de desgaste.




Figura 19 – Relação entre características das partículas e o modo de desgaste (GONÇALVES, 2010)

A análise de partículas de desgaste, normalmente, é realizada em dois estágios (MOBLEY, 2008b; XU; LUXMOORE; DERAVID, 1997). Primeiramente, realiza-se uma rotina de monitoramento do lubrificante da máquina em termos de quantidade, composição e tamanho das partículas. Uma máquina normal deve conter níveis baixos

de sólidos e de tamanho menor que 10 μm . O segundo estágio envolve a análise do tipo de partícula em cada amostra coletada de óleo.

3.2.4.2 Classificação das partículas de desgaste

Para fins de análise, Laghari (2003) propõe a classificação das partículas de desgaste em termos de dois grupos de atributos: composição e morfológicos.

Os atributos de composição indicam se uma dada partícula é classificada como metálica ou não metálica. No caso das metálicas, as partículas podem ser subdivididas em ferrosas e não ferrosas.

Por outro lado, a análise morfológica consiste em um procedimento *off-line* o qual visa caracterizar as partículas em termos de seis atributos morfológicos - tamanho, forma, detalhe de borda, cor, razão de espessura e textura, relacionando-os com os modos de desgastes conhecidos. O atributo forma é definido por meio da especificação de vários sub-atributos da partícula:

- área total da partícula, excluindo-se os possíveis buracos que ela possa possuir dentro de si;
- perímetro: comprimento do contorno de toda a partícula;
- largura e comprimento da partícula;
- diâmetros primário e secundário da elipse mais apropriada para envolver a partícula em sua totalidade;
- arredondamento: medida que determina o quão próximo esta partícula se assemelha a um círculo, sendo esse valor igual a 1 para partículas totalmente circulares;
- alongamento: comparação entre os eixos primário e o secundário, sendo seu valor igual a 0 quando estes possuem valores iguais;
- razão de aspecto: consiste na razão entre o maior diâmetro e o menor diâmetro da partícula;
- diâmetro de Feret: a maior distância entre dois pontos localizado no perímetro da partícula;

- arredondamento: medida que determina o quão próximo a partícula se assemelha a um círculo (ASTM F1877-05, 2006).

3.3 Termografia

A termografia é uma técnica de inspeção que efetua a detecção da radiação infravermelha emitida naturalmente pelos elementos com intensidade proporcional a sua temperatura. Por meio dela é possível identificar regiões onde a temperatura está alterada. Essa técnica é empregada em elementos elétricos para visualizações de temperaturas elevadas, evitando futuros defeitos e interrupções de áreas da empresa (PELIZZARI ET AL, 2006).

A Figura 20 ilustra uma fotografia de uma caixa de fusíveis com dois componentes que futuramente apresentarão problemas, e a Figura 21 representa a análise termográfica da referida caixa indicando o fusível quatro e cinco, da esquerda para a direita, com temperaturas acima do normal (MHF, 2009).



Figura 20 – Fotografia da caixa de fusíveis (MHF, 2009)




Figura 21 – Análise termográfica da caixa de fusíveis (MHF, 2009)

Segundo Scheffer e Ghirdar (2004, p. 229) essa técnica é útil nos seguintes casos:

- Não faz contato com a superfície.
- Não envolve nenhuma ação de risco.
- Pode ser utilizada em zonas de risco.
- Não é afetada por ondas eletromagnéticas.
- É utilizada com os sistemas em operação.
- Fornece informação instantânea.
- Os dados podem ser coletados e armazenados em forma digital.

3.4 Inspeção visual

Esta técnica consiste no primeiro método utilizado para a manutenção preditiva (MOBLEY, 2002, p.111). Ela pode ser definida como:

“...processo de examinar e avaliar sistemas e componentes usando o sistema sensorial humano auxiliado somente por recursos mecânicos para entrada sensorial tais como, lentes de aumento, estetoscópio, e semelhantes. O processo de inspeção pode se feito utilizando condutas como olhar, ouvir, sentir, cheirar, balançar e flexionar. Ele inclui um componente cognitivo no qual observações são correlacionadas com o conhecimento de estrutura e com descrições e diagramas da literatura” (SPENCER, 1996).

Dois aspectos importantes com relação a esta técnica são o baixo custo envolvido em sua aplicação e a possibilidade de detecção de problemas não percebidos por outras técnicas de monitoramento de condição. Por outro lado, a inspeção visual requer pessoas devidamente treinadas e bem familiarizadas com os equipamentos monitorados para sejam capazes de detectar possíveis alterações.

3.5 Ultrassonografia

Assim como o monitoramento de vibrações esta técnica se baseia em ruídos da máquina para estabelecer as condições atuais do sistema. A diferença é que a primeira monitora ondas de baixa frequência, entre 1 a 20 Hz enquanto que a ultrassonografia monitora faixas entre 20 a 100 kHz.

Scheffer e Girdhar (2004, p. 222) destacam que as seguintes propriedades do ultrassom podem ser úteis para fornecer informação antecipada em casos de:

- Detecção de vazamentos em sistemas de pressão e vácuo.
- Inspeção de rolamentos.
- Inspeção de purgadores.
- Integridade de vedações e juntas em tanques e sistemas de tubulação.
- Cavitação em bombas.
- Detecção de descargas em comutadores.
- Análise de válvulas de compressor.

4 REDES NEURAIS ARTIFICIAIS

Um aspecto importante no projeto de agentes inteligentes é a questão do aprendizado de máquina, o qual segundo Luger (2004, p. 45) “permanece sendo uma área desafiadora para a IA”. De fato, ao se desenvolver um agente inteligente, espera-se que esse apresente algumas características tais como mecanismos para interação com o ambiente (sensores e atuadores), capacidade de representação do conhecimento e habilidade de aprender.

Dentro da IA se destacam dois paradigmas de aprendizado:

- Simbólico: utiliza símbolos para representar entidades e relações de um domínio do problema e algoritmos de inferência na tentativa de descobrir generalizações novas, válidas e úteis.
- Conexionista: representa o conhecimento como padrões de atividades em redes de pequenas unidades de processamento individuais. O aprendizado se dá por meio da modificação de sua estrutura e/ou dos valores dos pesos em resposta aos dados de treinamento. Esse paradigma é, também, conhecido por meio de outras denominações como Processamento Distribuído Paralelo, Sistemas Neuromórficos e, tradicionalmente, como Redes Neurais Artificiais.

Com relação às RNA, Haykin (1994, p.2-4) enfatiza as seguintes propriedades úteis:

- não linearidade;
- capazes de reconhecer e classificar padrões e formas físicas;
- inspiradas no modelo biológico do cérebro humano;
- aprendem por exemplos por meio da inferência estatística não paramétrica;
- adaptabilidade e generalização;
- tolerância a falhas;
- implementação rápida e natureza propícia para processamento paralelo.

Devido a estas propriedades, as RNA vêm sendo aplicadas em diversas áreas, tais como: classificação, reconhecimento de padrão, otimização, controle, aproximação de função e mineração de dados.

4.1 Histórico

Entre os pioneiros nas pesquisas sobre RNA destacam os trabalhos de McCulloch e Pitts (1943). Em seus estudos eles analisaram o potencial da interconexão de um modelo de um neurônio, ilustrado pela Figura 22, propondo um modelo computacional baseado em um simples neurônio capaz de calcular qualquer função lógica básica do tipo AND e OR.




Figura 22 – Modelo de RNA de McCulloch Pitts (Adaptado de McCulloch e Pitts (1943))

Outro grande desenvolvimento na evolução de RNA foi o livro *The Organization of Behavior* em 1949, do psicólogo canadense Donald Olding Hebb, que foi a fonte de inspiração para o desenvolvimento dos modelos computacionais de aprendizado e sistemas adaptativos (HAIKEN, 1994, p. 37).

Na década de 50, Roseblatt (1958) idealizou um algoritmo de treinamento para um modelo de RNA de camada única denominado *Perceptron* (ROSENBLAT, 1958). Apesar do entusiasmo inicial com classe de algoritmo para problemas de reconhecimento de padrão, Nilsson (1965) e Minsk e Papert (1969) demonstraram a limitação do *Perceptron* para solução de problemas difíceis devido a sua capacidade de somente resolver problemas linearmente separáveis.

Com relação às regras de aprendizagem podem ser citados os trabalhos de:

- Widrow e Hoff (1960) que se baseia a minimização do erro quadrático entre o valor de saída desejado e a ativação da rede;
- de Barto, Sutton e Anderson (1983) com o conceito de aprendizado por reforço que, em sua essência, consiste na aplicação de penalidades e recompensas conforme a saída dada pelo agente esteja correta ou não, respectivamente;

- de Rumelhart, Hinton e Williams (1986a, 1986b) que introduziu uma regra de aprendizagem, apoiada na aplicação de funções de ativação, denominada regra delta e o algoritmo retropropagação, respectivamente;
- de Kohonen (1984) e Hecht-Nielsen (1987) que apresentaram o conceito de aprendizado competitivo, no qual os neurônios da RNA competem entre si, sendo somente o neurônio vencedor ativado.

4.2 Arquitetura básica de uma RNA

Haykin (1999, p.2) define RNA como “um processador distribuído massivamente paralelo que tem uma tendência para armazenamento de conhecimento experimental e torná-lo disponível para uso”. Sua semelhança com o cérebro se dá pelos seguintes fatores:

- o conhecimento é adquirido pela rede por um processo de aprendizado;
- sua unidade básica é o neurônio;
- a força da conexão entre os neurônios é usada para armazenar conhecimento.

Portanto, uma RNA é formada por um conjunto de estruturas elementares chamadas neurônios dispostos em três camadas diferentes - entrada, oculta e saída, conectados entre si por meio de sinapses ou pesos. A arquitetura genérica de uma RNA, ilustrada pela Figura 23, pode ser vista como um grafo dirigido onde os nós representam os neurônios artificiais e as arestas representam as sinapses ou pesos.




Figura 23 – Arquitetura genérica de uma RNA




Figura 24 – Neurônio artificial

Ao neurônio artificial, ilustrado na Figura 24, estão associados os seguintes componentes:

- Sinais de entrada – x_i : valores numéricos provenientes do ambiente ou de outros neurônios.
- Bias: determina o nível de ativação de entrada necessário para que o neurônio se torne ativo. Geralmente, o seu valor é igual a 1.
- Conjunto de pesos – w_{ij} : valores reais que descrevem a força da conexão entre os N neurônios da camada anterior com o neurônio j . Geralmente, seus valores iniciais são atribuídos, aleatoriamente, por números reais entre o intervalo aberto $(-1,1)$, excluindo-se o valor zero.
- Nível de ativação - z : dado pela soma ponderada das entradas de um neurônio, conforme a equação 21.

$$z_j = \sum_{i=1}^N w_{ij} * x_i \quad (21)$$

- Função de ativação - f : determina o estado final do neurônio, ou seja, o valor de sua saída, tendo como entrada do nível de ativação. As principais funções de ativação utilizadas são a linear, linear por partes, sigmóide, sigmóide bipolar, apresentadas, respectivamente, pelas equações 22 a 25.

$$f(z) = \begin{cases} 1 & \text{se } z > 0 \\ 0 & \text{caso contrário} \end{cases} \quad (22)$$

$$f(z) = \begin{cases} 1 & \text{se } z \geq 1/2 \\ z & \text{se } 1/2 > z > -1/2 \\ 0 & \text{se } z \leq -1/2 \end{cases} \quad (23)$$

$$f(z) = \frac{1}{1 + \exp(-\lambda z)} \quad (24)$$

$$f(z) = \frac{2}{1 + \exp(-\lambda z)} - 1 \quad (25)$$

Segundo Luger (2004, p. 394), além das características inerentes ao neurônio artificial, uma RNA pode ser especificada pelas seguintes propriedades: topologia da rede, algoritmo de aprendizagem e esquema de codificação.

4.2.1 Topologia da rede

A topologia da rede define a forma com que os neurônios da RNA estão estruturados. Haykin (1999, p. 43) sugere três tipos básicos: redes alimentadas-adiante de camada única (*single-layer feed-forward networks*), redes alimentadas-adiante de multicamadas (*multilayer feed-forward networks*) e redes recorrentes (*recurrent networks*).

Uma rede alimentada adiante de camada única, cuja arquitetura típica é ilustrada pela Figura 25, corresponde a um conjunto de neurônios conectados entre si dispostos em duas camadas, entrada e saída, no qual o fluxo da informação ocorre somente na direção da esquerda para a direita, ou seja, da camada de entrada para a camada de saída.




Figura 25 – Exemplo de Rede Alimentada Adiante (Haykin, 1999, p.21)

Já uma rede alimentada adiante multicamadas, ilustrada pela Figura 26 apresenta o mesmo conceito do tipo anterior com relação ao fluxo da informação, diferenciando-se pela presença de uma ou mais camadas adicionais denominadas camadas ocultas.




Figura 26 –Exemplo de Rede Alimentada Adiante Multicamadas (Haykin, 1999, p.22)

Em uma rede recorrente, cuja arquitetura típica é ilustrada pela Figura 27, o qual o fluxo da informação inicia-se na direção da esquerda para a direita, ou seja, da camada de entrada para a camada de saída. Entretanto, algumas informações provenientes das camadas de saída podem ser utilizadas como valores de realimentação para os neurônios da camada de entradas, formando um ciclo.




Figura 27 – Exemplo de Rede Recorrente (Haykin, 1999, p.23)

4.2.2 Algoritmo de aprendizagem

Haykin (1999, p.50) define o aprendizado das RNA como “um processo pelo qual os parâmetros livres da rede são adaptados por um processo de estímulo proveniente do ambiente no qual a rede está conectada”. Em outras palavras, consiste em um procedimento pelo qual todos os pesos que compõem a rede sejam estimados de tal forma que ela seja capaz de realizar sua função de forma mais precisa possível.

O tipo de aprendizado é determinado pela forma na qual os parâmetros da rede são alterados. Desse modo, os algoritmos de aprendizagem podem ser divididos em duas grandes classes principais:

- Supervisionado: neste tipo de treinamento são passados para a camada de entrada da rede pares de treinamento do tipo $\{X, d\}$, onde X corresponde ao vetor com os dados de entrada da rede e d corresponde a saída desejada, a

qual se espera que a rede forneça. Deste modo, algoritmos desta classe efetuam o treinamento por meio do ajuste do erro entre a saída desejada com a saída real dada pela rede.

- Não-Supervisionado: para esse tipo de treinamento somente é passado o vetor X com os dados de entrada. Deste modo, a rede tem como principal objetivo descobrir as similaridades entre estes dados reunindo-os em grupos com dados semelhantes entre si.

Outra forma na qual uma RNA pode ser classificada é pela regra de aprendizado utilizada. Neste sentido, destacam-se quatro regras básicas: correção de erro, Hebbiano, competitivo e de Boltzmann.

4.2.2.1 Aprendizado por correção de erro

Trata-se de um aprendizado supervisionado no qual o princípio básico é utilizar o sinal de erro dado pela diferença entre a saída desejada e a saída real para modificar os valores dos pesos e, gradualmente, reduzir esse erro. Sendo assim, dados o valor de entrada x_i do neurônio, a saída desejada d , a saída real y e a constante de treinamento α , sua formulação básica é definida pela equação 26.

$$w_{ij}^{t+1} = w_{ij}^t + \alpha * (d - y) * x_i \quad (26)$$

4.2.2.2 Regra de aprendizado Hebbiano

Trata-se da regra de aprendizado mais antiga baseada na proposta desenvolvida por Hebb (1949): “dois neurônios em ambos os lados de uma sinapse são ativados sincronamente e simultaneamente, então a força daquela sinapse é seletivamente aumentada”. Este processo de treinamento é feito localmente, ajustando o peso das conexões baseado nas atividades dos neurônios.

Pela regra de aprendizagem proposta por Hebb o peso é incrementado se os neurônios fonte e destino forem ativados e os pesos são aumentados de acordo com o produto dos níveis de excitação destes neurônios. Matematicamente, ela pode ser

definida conforme a equação 27, onde x_i e y_i são os valores de saídas dos neurônios conectados pela sinapse w_{ij} .

$$w_{ij}^{t+1} = w_{ij}^t + \alpha * y_j * x_i \quad (27)$$

4.2.2.3 Regra de aprendizado competitivo

Neste modelo de aprendizagem os neurônios da camada de saída são forçados a competir entre si. Em uma dada iteração, somente um neurônio permanecerá ativo, neste caso, aquele que tiver o menor ou maior valor, sendo chamado de vencedor. Sua formulação é dada pela equação 28.

$$w_{ij}^{t+1} = w_{ij}^t + \alpha * (x_j - w_{ij}) \quad (28)$$

Basicamente, pode ser elencada a presença de três componentes característicos desta regra de aprendizado:

- Um conjunto de neurônios idênticos, conectados por pesos de valores distribuídos, inicialmente, de modo aleatório.
- Um valor máximo bem definido, o qual faz com que um neurônio seja ativado.
- Um processo responsável pela competição entre os neurônios pelo direito de permanecerem ativados.

4.2.2.4 Regra de aprendizado de Boltzman

Esse modelo pode ser visto como um procedimento de aprendizagem não-supervisionado para modelar uma distribuição de probabilidade. Nesta regra os neurônios são estocásticos, podendo residir em dois estados possíveis, ligado representado pelo valor +1 e desligado pelo valor -1, sendo divididos em dois grupos distintos, presos e livres (HAYKIN, 1999, p.61).

A atualização dos pesos é realizada conforme equação 29, onde ρ_{ij}^+ representa a correlação entre os estados dos neurônios i e j, com a rede em sua condição presa, e ρ_{ij}^- a correlação com a rede em sua condição livre.

$$w_{ij}^{t+1} = w_{ij}^t + \alpha(\rho_{ij}^+ - \rho_{ij}^-) \quad (29)$$

4.2.3 Esquema de codificação

De acordo com Luger (2004, p. 394) o esquema de codificação corresponde à interpretação que se dá aos dados fornecidos para a rede e ao resultado do seu processamento. Neste sentido, Andina et al (2007, p. 51) classifica a forma dessa entrada-saída em três tipos:

- Contínuos: todos os dados, entrada e saída, apresentam valores reais.
- Digitais: todos os dados, entrada e saída, apresentam valores binários.
- Híbrido: os dados de entrada são contínuos e os de saída digitais.

4.3 Tipos de RNA

Existem diversos tipos de RNA conforme a arquitetura selecionada e, conseqüente, regra de treinamento aplicada. Dentre aquelas mais comumente utilizadas destacam-se três tipos: Perceptron, Multi-Layer Perceptron e Kohonen.

4.3.1 Perceptron

Este tipo de RNA é uma rede de camada única alimentada adiante caracterizada pela conexão direta entre os neurônios da camada de entrada com os neurônios da camada de saída, não possuindo, conseqüentemente, a camada oculta. Esta RNA foi, inicialmente, proposta por Rosembat (1958) e utiliza o modelo de McCulloch-Pitts (MCCULLOCH; PITTS, 1943) para os neurônios.

Por tratar-se do tipo mais simples de rede ela possui a limitação de poder ser aplicada somente a problemas de classificação de padrões linearmente separáveis, ou seja, classes as quais podem somente ser separadas por meio de uma reta, conforme ilustrado na Figura 28.




Figura 28 – Exemplo de classes linearmente separáveis




Figura 29 – Exemplo de rede do tipo Perceptron

O Perceptron, cuja arquitetura básica é ilustrada pela Figura 29, utiliza uma função de ativação linear e um algoritmo de aprendizado para treinamento da rede do tipo supervisionado aplicando a regra de correção de erros para o ajuste dos pesos. Considerando a arquitetura apresentada na Figura 29 o algoritmo de treinamento pode ser descrito pelos seguintes passos:

1. Iniciar os valores dos pesos w_{ij} .
2. Enquanto condição de parada for falsa faça:
 - i) Selecionar aleatoriamente um par de treinamento $\{X, d\}$, onde X é o vetor de entrada e d é a saída desejada.
 - ii) Calcular o valor de entrada y_{in} para o nó da camada de saída pela equação 30 dada a seguir. Neste caso, w_{01} refere-se ao peso que conecta o *bias* com o nó de saída.

$$y_{in_1} = w_{01} + \sum_{i=1}^N x_i * w_{i1} \quad (30)$$

iii) Calcular a saída real y da rede utilizando a função de ativação, conforme equação 31.

$$y_1 = f(y_{in_1}) \quad (31)$$

iv) Se $d \neq r$ atualizar valores dos pesos pela regra dada pela equação 32:

$$w_{ij} = w_{ij} + \alpha * (d - r) * x_i \quad (32)$$

v) Voltar ao passo 2.

4.3.2 MLP

Uma rede MLP é composta por um conjunto de neurônios dispostos em diversas camadas, contendo pelo menos uma camada interna ou escondida. Esse tipo de estrutura consegue resolver problemas mais complexos, inclusive problemas de classificação não linear sendo, por isso, o modelo mais utilizado.

O algoritmo de aprendizagem para este tipo de RNA é semelhante àquele utilizado no Perceptron. Um diferencial, neste caso, é que podem existir vários neurônios na camada de saída, sendo necessário se calcular o valor de saída para cada um destes neurônios.

Na fase de treinamento da rede MLP (Figura 30), utiliza-se, normalmente, uma função de ativação sigmóide e o aprendizado é supervisionado e realizado por meio do algoritmo de retropropagação, cujo funcionamento, em sua forma básica, é constituído de duas fases:

- Propagação do sinal: nesta fase os dados de entrada são aplicados aos neurônios da unidade de entrada e propagados para aqueles das outras camadas até a camada de saída, a fim de produzir a saída da RNA. Nessa fase os pesos são mantidos inalterados.
- Propagação do erro: dependendo da saída produzida, ou seja, se esta não coincidir com a saída esperada, é calculado um erro que é propagado dos

neurônios da camada saída para os neurônios da entrada a fim de corrigir os pesos gerados do erro.




Figura 30 – Exemplo de rede MLP com uma camada oculta

Considerando a rede MLP com uma camada oculta apresentada pela Figura 30, o algoritmo de treinamento pode ser descrito pelos seguintes passos:

1. Iniciar os valores dos pesos w_{ij} e v_{ij} .
2. Enquanto condição de parada for falsa faça:
 - i) Selecionar aleatoriamente um par de treinamento $\{X, D\}$, onde X é o vetor de entrada e D é o vetor de saída desejada.
 - ii) Calcular o valor de entrada z_in para cada neurônio da camada oculta conforme equação 33. Neste caso, w_{0j} refere-se ao peso que conecta o *bias* com o neurônio j da camada oculta.

$$z_in_j = w_{0j} + \sum_{i=1}^N x_i * w_{ij} \quad (33)$$

- iii) Calcular a saída de cada neurônio da camada oculta utilizando a função de ativação, conforme equação 34

$$z_j = f(z_in_j) \quad (34)$$

- iv) Calcular o valor de entrada y_in para cada neurônio da camada de saída pela equação (35). Neste caso, v_{0j} refere-se ao peso que conecta o *bias* com o neurônio j da camada de saída.

$$y_in_j = v_{0j} + \sum_{i=1}^M z_i * v_{ij} \quad (35)$$

- v) Calcular a saída de cada neurônio da camada de saída utilizando a função de ativação, conforme equação 36.

$$y_j = f(y_{in_j}) \quad (36)$$

- vi) Se $D \neq Y$ executar retropropagação do erro pelos passos:

- a. Calcular erro da camada de saída conforme equação 37:

$$er_{y_j} = (d_j - y_j) * f'(y_{in_j}) \quad (37)$$

- b. Propagar o erro dos neurônios da camada de saída para os da camada oculta conforme equação 38.

$$er_{z_{in_i}} = \sum_{j=1}^P v_{ij} * er_{y_j} \quad (38)$$

- c. Propagar o erro dos neurônios da camada de saída para o bias da camada oculta pela equação 39.

$$er_{bias_{in}} = \sum_{j=1}^P v_{0j} * er_{y_j} \quad (39)$$

- d. Calcular erro da camada oculta conforme equação 40:

$$er_{z_j} = er_{z_{in_j}} * f'(z_{in_j}) \quad (40)$$

- e. Calcular erro do bias da camada oculta conforme equação 41:

$$er_{bias} = er_{bias_{in}} \quad (41)$$

- f. Atualizar os pesos w_{ij} e v_{ij} pelas equações 42 a 45:

$$v_{ij} = v_{ij} + \alpha * er_{y_j} * z_i \quad (42)$$

$$w_{ij} = w_{ij} + \alpha * er_{z_j} * x_i \quad (43)$$

$$v_{0j} = v_{0j} + \alpha * er_{y_j} \quad (44)$$

$$w_{0j} = w_{0j} + \alpha * er_{z_j} \quad (45)$$

4.3.3 Kohonen

O algoritmo da RNA do tipo Kohonen, proposto por Teuvo Kohonen (KOHONEN, 1982), consegue identificar e organizar conjuntos complexos de dados em grupos, de acordo com a relação existente entre eles. Possui uma estrutura parecida com o aprendizado não-supervisionado do tipo competitivo, utilizando apenas duas camadas: entrada e saída, onde ocorre o processamento para a classificação do padrão de entrada. Cada nó da primeira camada está, obrigatoriamente, conectado com todos

os nós da camada de saída, conforme ilustrado pela Figura 31.




Figura 31 – Exemplo de uma rede de Kohonen com dois nós de entrada e um mapa de saída de 3x3

A classificação neste tipo de RNA é do tipo não supervisionado e é realizada pela geração de um mapa, sendo por isto, este tipo de RNA chamado de Mapas Auto-Organizáveis. Diferentemente das RNA mais simples, como o *Perceptron*, essas redes conseguem resolver problemas não-lineares de alta dimensionalidade, além de ser um dos modelos representativos mais realísticos de cérebro humano, mesmo que extremamente simplificado (DE CASTRO; VON ZUBEN ET AL, 1999).

Haykin (1999, p. 475) destaca os seguintes parâmetros fundamentais para este tipo de rede:

- Um espaço de entrada de padrões de ativação que são generalizados de acordo com uma distribuição de probabilidade.
- Uma topologia de saída na forma de uma matriz de neurônios definindo um espaço de saída discreto.
- Uma função de atualização da vizinhança variável no tempo ao redor de um nó vencedor.
- Um parâmetro para a taxa de aprendizagem que começa com um valor inicial determinado e, gradativamente, diminui chegando próximo de zero.

Um dos objetivos desta rede é reduzir a dimensionalidade dos dados preservando as relações métricas e topológicas do espaço de entrada. Como consequência, informações semelhantes tende a serem mapeadas em neurônios próximos, caracterizando o agrupamento do espaço de entrada. Portanto, no processo de aprendizado da rede é gerado um mapa de saída o qual, na maioria das

implementações, consiste em uma matriz retangular bi-dimensional.

O aprendizado é feito apenas a partir de exemplos encontrados em padrões na entrada fornecidos, sendo que a própria rede conseguirá identificá-los sem a necessidade de serem informados de qualquer outra forma. Desta forma, o algoritmo de treinamento pode ser descrito pelos seguintes passos:

1. Iniciar os valores dos pesos w_{ij} .
2. Enquanto condição de parada for falsa faça:
 - i) Selecionar aleatoriamente uma entrada X para treinamento.
 - ii) Calcular o estado de ativação de cada neurônio da camada de saída utilizando-se do cálculo da distância euclidiana, conforme a equação 46.

$$d_j = \sqrt{\sum_{i=1}^N (x_i - w_{ij})^2} \quad (46)$$

- iii) Determinar o nó vencedor utilizando a equação 47.

$$vencedor_c = \min\{d_j\} \quad (47)$$

- iv) Atualizar os pesos do neurônio vencedor c , assim como seus vizinhos, utilizando as equações 48 e 49. Os parâmetros α e β são constantes de treinamento positivas menores que 0, satisfazendo a restrição $\alpha > \beta$.

$$w_{ic} = w_{ic} + \alpha * (x_i - w_{ic}) \quad (48)$$

$$w_{i(c+j)} = w_{i(c+j)} + \beta * (x_i - w_{i(c+j)}) \quad (49)$$

5 PROTÓTIPO NEURALNET-CBM

O foco principal ao qual essa tese se propõe é a aplicação de RNA no processo de manutenção preditiva. A proposta, em questão, é a implementação de arquitetura única de RNA do tipo MLP a ser utilizada tanto para monitoramento de vibrações como para análise de partículas de desgaste. Para o monitoramento de vibrações essa RNA é aplicada para a classificação de ausência ou presença de falhas e para a identificação do tipo de falha e para análise de partículas ela é aplicada para identificação do tipo de partícula de desgaste com base em seus atributos morfológicos.

A arquitetura única referida nessa tese corresponde na utilização o mesmo tipo de RNA, no caso MLP, com uma camada oculta, na uniformidade para a geração dos pesos, incluindo o processo de otimização proposto por Nguyen e Widrow (1990), na função de ativação aplicada, no número de neurônios da camada oculta, na normalização dos dados de entrada e no algoritmo de aprendizado para treinamento da RNA. Os elementos parametrizáveis, que resultam em variações na arquitetura da RNA, correspondem à especificidade do problema, ou seja, a quantidade de características utilizadas e o total de falhas/partículas a ser identificadas, sendo associadas, respectivamente, ao número de neurônios da camada de entrada e de saída.

Contudo, o presente estudo não se limita somente a uma análise de possíveis configurações de arquiteturas de redes e seus respectivos resultados, mas, também, no desenvolvimento de um protótipo que, futuramente, se tornará um recurso de *software* para apoio no diagnóstico/prognóstico de falhas em máquinas rotativas.

Um protótipo pode ser definido como uma versão inicial de um sistema utilizado para demonstrar conceitos, experimentar opções do projeto e, geralmente, conhecer mais sobre os problemas e suas possíveis soluções (SOMMERVILLE, 2006, p. 409). Nesse sentido, o protótipo desenvolvido visa apresentar a aplicação da RNA como uma possível solução para a CBM. Sommerville (2006, p. 410), ainda destaca, por exemplo, que, no processo de engenharia de requisitos, o protótipo pode auxiliar no levantamento e validação dos requisitos do sistema.

Nas seções seguintes, inicialmente, será apresentada uma descrição genérica do protótipo, denominado NEURALNET-CBM, avançando para uma pormenorização da

RNA implementada e, concluindo com a apresentação da interface gráfica desenvolvida e suas funcionalidades.

5.1 Arquitetura do protótipo

O protótipo NEURALNET-CBM tem como principal característica disponibilizar um recurso de *software* para apoio ao monitoramento de condição de máquina por meio da utilização de técnicas de IA, no caso, RNA. A proposta é oferecer uma ferramenta adaptável capaz de analisar dados provenientes de diferentes sistemas de aquisição de dados, importando os dados para um formato padrão que pode ser reconhecido e manipulado pelo programa. A arquitetura do protótipo proposto é apresentada na Figura 32 e é dividido em dois módulos: Módulo Vibrações e Módulo Partículas.




Figura 32 – Arquitetura do protótipo NEURALNET-CBM

Na arquitetura do protótipo NEURALNET-CBM, apresentada na Figura 32, é composta pelos seguintes componentes:

- Conversão de Dados: converte os dados de vibração, no formato ASCII, gerados por um sistema de aquisição de dados para um formato reconhecido pelo protótipo.

- Exibe Sinal: Permite exibir o gráfico de um sinal a partir do arquivo gerado pelo componente Conversão de Dados.
- Calcula Características: calcula as características no domínio do tempo a partir do arquivo gerado pelo componente Conversão de Dados.
- Módulo RNA (Vibração): efetua o treinamento e teste da RNA a ser utilizada pelo classificador neural para o Sistema de Diagnóstico para monitoramento de vibrações.
- Módulo RNA (Partículas): efetua o treinamento e teste da RNA a ser utilizada pelo classificador neural emitir resultado do diagnóstico referente às partículas de desgaste identificadas em uma dada amostra.

O módulo Vibrações tem como principal objetivo efetuar a análise de sinais de vibração provenientes de um sistema de aquisição de dados. A funcionalidade desse módulo, representada na Figura 33, dá-se da seguinte forma:

- A partir dos dados coletados por um sistema de aquisição, são calculadas as características no domínio do tempo que podem ser utilizadas ou para treinamento da RNA para geração dos classificadores ou para classificação dos dados coletados utilizando-se os classificadores existentes.
- A utilização das características para treinamento da RNA consiste na geração de dois classificadores: básico, para se determinar a existência ou não de uma falha, e completo, para se identificar o tipo da falha.
- No processo de aplicação dos classificadores, primeiramente, as características são submetidas ao classificador básico. Se esse determinar ausência de falha, então, o processo se encerra com uma mensagem indicando o estado normal do rolamento. No caso de indicação de falha, essas características são submetidas ao classificador completo que tem a incumbência de identificar o tipo de falha.




Figura 33 – Funcionamento do módulo Vibrações

No NEURALNET-CBM, para esse módulo foram implementados os seguintes componentes:

- Conversão de Dados: realiza a conversão dos dados originais para o formato reconhecido pelo protótipo NEURALNET_CBM.
- Exibe Sinal: possibilita a visualização do sinal referente a um arquivo de dados.
- Calcula Características: permite calcular as características estatísticas no domínio do tempo tendo como base os trabalhos de Zhang, Jack e Nandi (2005), Samanta e Al-Balushi (2003) e Samanta (2004).
- Módulo RNA: efetua o treinamento de uma RNA para um determinado conjunto de arquivos de sinais sendo os dados da rede treinada armazenados em um arquivo de configuração que pode ser exportado para um sistema de diagnósticos ou utilizado, no próprio NEURALNET-CBM para diagnóstico.

Já o módulo Partículas disponibiliza uma RNA para análise de partículas de desgaste tendo como base suas propriedades morfológicas obtidas, previamente, em sistema de processamento de imagens. A Figura 34 ilustra o funcionamento desse módulo. A partir de um arquivo contendo os atributos morfológicos das partículas identificadas por um sistema de processamento de imagem, é possível efetuar o treinamento da RNA para geração do classificador de partícula ou submeter esses

dados a um classificador, previamente gerado, para identificação de cada uma das partículas as quais os atributos se referem.




Figura 34 – Funcionamento do módulo Partículas

A seção 5.3 apresenta toda interface gráfica para interação com os módulos apresentados na Figura 32.

5.2 RNA utilizada

Em ambos os módulos foi utilizada uma RNA do tipo MLP, ou seja, com três camadas: entrada, oculta e de saída. Para as camadas de entrada e oculta, os números de neurônios foram variados a fim de alcançar uma configuração ideal capaz de fornecer uma classificação mais precisa.

Para a camada de entrada, a quantidade de neurônios é determinada pelo número de características utilizadas: um neurônio nessa camada representa a utilização de apenas uma característica; dois neurônios, duas características; e, assim por diante.

Já para a camada oculta foram exploradas algumas configurações avaliando-se a precisão na classificação retornada. Ao final, foi definida a utilização de 5 neurônios para essa camada.

Para a camada de saída o número de neurônios é determinado pelo tipo de classificação que se deseja fazer. Sendo assim, para o caso no qual se deseja apenas determinar se existe ou não um defeito, sem se preocupar em identificá-lo, é utilizado apenas um neurônio nesta camada. Todavia, para análises as quais se deseja identificar

o tipo de defeito a quantidade de neurônios é igual à quantidade de defeitos que se deseja tratar.

O procedimento padrão para iniciar os valores dos pesos é utilizar uma rotina aleatória que gere números no intervalo (-1,1), excetuando-se o 0. Entretanto, é utilizado o processo de iniciação de valores proposto por Nguyen e Widrow (1990) que sugerem uma pequena modificação do procedimento padrão proporcionando um aprendizado mais rápido da rede. O procedimento consiste nos seguintes passos:

a) Para os pesos w_{ij} entre a camada de entrada e camada oculta:

i. Iniciar seus valores entre -0,5 e 0,5.

ii. Calcular:

$$w_j = \sqrt{w_{1j}^2 + w_{2j}^2 + \dots + w_{Nj}^2} \quad (50)$$

$$\beta = 0,7 \times M^{1/N} \quad (51)$$

iii. Reiniciar os valores dos pesos:

$$w_{ij} = \beta \frac{w_{ij}}{w_j} \quad (52)$$

iv. Reinicia os valores dos pesos do bias entre β e $-\beta$.

b) Para os pesos entre a camada oculta e camada de saída:

i. Iniciar seus valores entre -0,5 e 0,5.

Para o cálculo da saída de um neurônio foi utilizada a função de sigmóide bipolar apresentada na equação 25, da seção 4.1 deste documento.

5.3 Interface gráfica

A interface gráfica do protótipo NeuraNet_CBM foi projetada utilizando-se o ambiente de desenvolvimento de aplicações visuais em ambiente Windows desenvolvido pela empresa Borland, chamado Borland C++ Builder 6. Uma das grandes vantagens desse pacote de *software* no desenvolvimento de aplicações visuais é que ele disponibiliza um ambiente de ferramentas para Desenvolvimento Rápido de Aplicações, a partir de agora referida como RAD, do inglês *Rapid Application Development*, utilizando as facilidades do conceito de orientação a objeto, ou seja,

reutilização de código, neste caso, por meio da linguagem C++.



Figura 35 – Janela principal do NEURALNET-CBM

A janela de entrada, ilustrada na Figura 35, consiste na identificação do sistema e contém os seguintes botões de interação:

- *Vibration Module*: abre a janela para utilização do Módulo Vibrações e suas funcionalidades.
- *Wear Particle Module*: abre a janela para utilização do Módulo Partículas e suas funcionalidades.
- *Exit*: finaliza o programa.
- *Tutorial*: apresenta um pequeno tutorial de auxílio na utilização do protótipo Neural_Net-CBM.

As seções seguintes apresentam um descritivo das interfaces gráficas referentes aos dois módulos desenvolvidos no protótipo.

5.3.1 Módulo Vibrações

Este módulo tem por objetivo disponibilizar ferramentas para diagnóstico de máquinas baseados em características estatísticas do domínio do tempo. Em sua janela principal, ilustrada na Figura 36, é possível utilizar as seguintes funcionalidades:

importar dados para o formato padrão definido no NEURALNET-CBM; calcular características no domínio do tempo; exibir o gráfico do sinal no domínio do tempo; gerar dados para treinamento da RNA; treinar e testar uma RNA; e, analisar dados utilizando uma RNA devidamente treinada.




Figura 36 – Janela do módulo Vibrações

5.3.1.1 Importar dados

Esta funcionalidade, cuja janela é apresentada pela Figura 37, pode ser acessada pela opção de menu *Import* e possibilita converter os dados gerados por um sistema de aquisição de dados para o formato padrão estabelecido para o NEURALNET-CBM. Sua utilização baseia-se na execução da seguinte sequência:

- No canto superior esquerdo da janela deve-se selecionar a pasta onde os arquivos originais se encontram que serão exibidos, automaticamente, na janela à direita.
- Depois de selecionado o arquivo a ser importado é necessário especificar sua origem. Na versão atual foram disponibilizadas duas fontes de dados: a primeira referente a dados coletados no laboratório do Departamento de Mecânica da Faculdade de Engenharia de Guaratinguetá (FEG), utilizando o programa AQDADOS da empresa Lynx Tecnologia Eletrônica Ltda; a

segunda disponibilizada na internet pela *Case Western Reserve University*, fruto do trabalho de pesquisa liderado pelo professor Dr. Kenneth A. Loparo (CWRU, 2008). Esses dados serão descritos com mais detalhes no Capítulo 6 dessa tese. O nome do arquivo selecionado será exibido no campo “*Selected File*”, para fins de conferência.

- Por fim, deve-se selecionar o botão *Import* que os dados serão convertidos para o formato reconhecido pelo programa.




Figura 37 – Janela para importação dos dados

O formato definido para o programa trata-se de um arquivo de extensão “.sam”, uma abreviatura para *samples*, amostras em inglês, e sua estrutura, ilustrada pela Figura 38, consiste de um cabeçalho contendo algumas informações do processo de aquisição de dados como número de sensores utilizados, quantidade de pontos coletados.

Numero de canais
Quantidade de pontos
Valor1
Valor2
...
ValorN

Figura 38 – Estrutura do arquivo de amostra .sam

5.3.1.2 Exibir sinal

Um recurso disponibilizado pelo programa é a possibilidade de visualização do sinal referente ao conteúdo de um arquivo “.sam”. Para isso é necessária a execução dos seguintes passos:

- Abrir a janela de visualização do sinal selecionando a opção *Signal Visualization* do menu *Vibration*.
- Selecionar o botão “File Selection” para selecionar o arquivo o qual se deseja visualizar sinal. Após este passo, o referido sinal será exibido conforme ilustrado pela Figura 39.




Figura 39 – Exemplo de visualização de sinal

Após o sinal ser exibido é possível ampliar uma determinada parte da onda pela simples ação de selecionar a região desejada com o ponteiro do mouse. A Figura 40 apresenta um exemplo de uma ampliação da região entre o intervalo 0,1 a 0,3 segundos do sinal ilustrado na Figura 39.




Figura 40 – Exemplo de visualização de sinal ampliado

5.3.1.3 Calcular características no domínio do tempo

Atualmente, o protótipo baseia-se na utilização em características estatísticas do domínio do tempo com base nos trabalhos de Zhang, Jack e Nandi (2005), Samanta e Al-Balushi (2003) e Samanta (2004). Sendo assim, a opção *Time Domain* do menu *Vibration* possibilita a visualização dos valores das características de um determinado sinal coletado. Para isso, a interação é realizada por meio da janela apresentada pela Figura 41 tendo como orientação os seguintes passos:

- Selecionar quais características que se deseja visualizar seus valores, selecionando as respectivas opções.
- Definir o número de segmentos que se deseja calcular as caracterísitca e o tamanho de cada um.
- Selecionar o arquivo de dados selecionando o botão *File Selection*. Após esse último passo os valores das características desejadas serão exibidos no formato de uma tabela.




Figura 41 – Janela para visualização das características.

5.3.1.4 Gerar dados para treinamento da RNA

O principal objetivo do NEURALNET-CBM é disponibilizar um sistema classificador baseado em uma RNA que seja capaz de analisar um arquivo de sinais com relação a dois aspectos: se estes sinais se referem a um componente com defeito ou não, e, quando for o caso, identificar o tipo de defeito ao qual se refere.

Para isso, conforme descrito em capítulos anteriores, inicialmente, é necessário treinar a RNA para que, posteriormente, possa ser aplicada a um sistema classificador. Sendo assim, a opção *Create Data Training* do menu *Neural Network* possibilita, a partir dos arquivos de dados “.sam” criar arquivos para treinamento e teste da rede, denominados training.rna e test.rna, respectivamente.




Figura 42 – Janela para geração de dados de treinamento

A janela de apoio para execução das funcionalidades descritas, anteriormente, é apresentada na Figura 42. Sua utilização baseia-se na execução dos seguintes passos:

- Definir a configuração dos dados a serem inseridos no arquivo de treinamento, sendo:
 - *Number of Files*: estabelece o número de arquivos de dados a ser utilizado. Cada arquivo refere-se a um tipo de falha a ser considerada e aprendida pela RNA.
 - *Segment Length*: determina o tamanho de cada segmento ao qual será efetuado o cálculo das estatísticas.
 - *Number of Segments*: determina a quantidade de segmentos a ser extraída de cada arquivo.
- Finalizada a etapa de configuração, o último passo consiste em, simplesmente, clicar no botão *Generate Data for Training*. Assim, proporcionalmente ao número de arquivo, será solicitado selecionar o nome do arquivo contendo os dados e o tipo de falha o qual esse arquivo se refere. As Figuras 43 e 44 apresentam as respectivas janelas com estas funcionalidades.




Figura 43 – Janela para seleção de arquivo de dados



Figura 44 – Janela para identificação do estado do rolamento

5.3.1.5 Treinar e testar a RNA

A interface destinada ao treinamento da RNA, ilustrada pela Figura 43, consiste de uma janela dividida em três partes:

- Configuração da RNA: essa área, identificada na Figura 45 por *ANN Configuration*, possibilita definir a quantidade de neurônios das camadas de entrada, oculta e saída por meio das opções *Input Layer*, *Hidden Layer* e *Output Layer*, respectivamente.
- Definição dos dados de entrada: nesse item devem ser especificadas quais características serão utilizadas como dados de entrada para treinamento da rede. A quantidade de características deve, obrigatoriamente, ser igual ao número de neurônios definido para a camada de entrada. Somente quando

esta condição for satisfeita o botão *Execute Training* será habilitado.

- Resultado do treinamento: nessa região da janela é apresentado um gráfico circular ou do tipo pizza indicando o percentual de acerto da RNA treinada, ou seja, sua precisão.




Figura 45 – Janela de treinamento da RNA

5.3.1.6 Analisar dados

Após a RNA treinada, a proposta deste trabalho é disponibilizar um arquivo de configuração contendo as informações necessárias para que, futuramente, possa ser exportado para um sistema de diagnóstico portátil. Entretanto, também no protótipo NEURALNET-CBM, foi desenvolvido um módulo de diagnóstico o qual utiliza esta configuração de RNA previamente treinada. Estão previstos dois tipos de análise diagnóstica:

- Básica: que simplesmente indica se há ou não um defeito. Sua interface é ilustrada pela Figura 46. Quando um problema é detectado o círculo é exibido em cor vermelha, e, também, é apresentada a mensagem “*Problem Detect*”. Caso contrário, exibe-se a mensagem “*No Fault*” e um círculo em cor verde.




Figura 46 – Janela para diagnóstico básico

- Completa: que especifica o tipo de falha encontrado. Sua interface é ilustrada pela Figura 47. Essa janela exibe os tipos de problemas para os quais a RNA está treinada e qual problema, atualmente, foi detectado, colorindo com vermelho a região correspondente.




Figura 47 – Janela para diagnóstico completo

5.3.2 Módulo Partículas

Assim como o módulo Vibrações, este módulo utiliza uma RNA para classificação das partículas de acordo com um determinado tipo de desgaste. Sua interface gráfica, ilustrada pela Figura 48, apresenta as opções: visualização dos dados referentes às partículas; treinamento e teste da RNA; e análise de partículas para

determinação do tipo de desgaste. A funcionalidade destas opções serão detalhadas nas subseções seguintes.



Figura 48 – Janela do módulo Partículas

5.3.2.1 Importar dados

Os dados de entrada deste módulo consistem nos parâmetros referentes a um determinado tipo de análise, atualmente, parâmetros morfológicos. Esses dados são convertidos para o formato reconhecido pelo módulo Vibrações do NEURALNET-CBM, descrito na Figura 49. O formato divide-se em duas partes distintas: cabeçalho e dados. No cabeçalho, são especificados o número de partículas analisadas, identificada pela variável N, e a quantidade de parâmetros utilizados, identificada pela variável P. Os dados consistem em um conjunto de N registros, cada qual contendo os P parâmetros de partícula.

```
N
P
Registro1
Registro2
...
RegistroN
```

Figura 49 – Estrutura do arquivo do módulo Partículas

A importação dos dados é realizada utilizando-se a janela apresentada pela Figura 50, por meio dos seguintes passos:

- No canto superior esquerdo da janela deve-se selecionar a pasta onde os arquivos originais se encontram e que serão exibidos, automaticamente, na janela à direita.
- Depois de selecionado o arquivo a ser importado é necessário especificar sua origem. Apesar de que na janela constem as opções de análise por composição e análise por forma, somente a segunda está devidamente implementada. O nome do arquivo selecionado será exibido no campo “*Selected File*”, para fins de conferência.
- O último passo consiste em se clicar no botão *Import* para que seja gerado o arquivo com os dados devidamente importados.




Figura 50 – Janela para importação de dados

5.3.2.2 Visualização dos dados

Os valores dos parâmetros de todas as partículas podem ser visualizados para fins de verificação ou outra necessidade desejada. A Figura 51 apresenta a janela resultante para esta opção. A última coluna corresponde ao tipo de partícula de desgaste ao qual a informação se refere.



area	perimeter	width	height	major	minor	circularity	roundness	ratio	feret	angle	tipo
16411,369	555,570	180,360	126,380	178,910	116,800	0,670	4,760	1,430	184,720	12,990	1
14430,560	586,630	180,360	122,700	181,860	101,030	0,530	3,500	1,470	184,720	8,820	1
17799,020	614,740	180,360	153,370	175,450	129,170	0,590	6,580	1,180	184,720	21,470	1
14413,620	553,750	166,870	126,380	161,360	113,740	0,590	5,780	1,320	174,240	20,800	1
17742,939	569,650	180,360	132,510	179,620	125,770	0,690	5,670	1,360	184,720	6,290	1
12210,390	505,660	165,640	116,560	173,440	89,640	0,800	3,140	1,420	173,410	15,400	1
8824,580	677,420	131,350	155,670	152,020	73,910	0,240	2,890	0,840	167,300	120,490	1
8325,540	617,950	131,350	147,020	145,570	72,820	0,270	3,000	0,890	166,940	125,030	1
14943,550	595,640	180,360	126,380	179,530	105,980	0,530	3,880	1,430	184,720	18,640	1
16546,859	653,620	194,470	126,380	204,640	102,950	0,490	3,020	1,540	212,100	21,320	1
1802,900	235,380	40,820	70,990	60,190	38,140	0,410	4,460	0,580	71,620	86,530	2
1769,330	234,280	40,630	70,650	59,620	37,790	0,410	4,460	0,580	71,280	86,540	2
1760,370	248,220	41,570	72,290	61,270	37,000	0,360	4,050	0,580	72,930	86,150	2
1726,670	256,740	41,570	72,290	61,120	35,970	0,330	3,860	0,580	72,930	85,130	2
1544,290	265,160	40,590	70,590	59,780	32,890	0,280	3,450	0,580	71,210	89,320	2
1763,670	263,260	48,240	70,590	56,460	39,770	0,320	5,770	0,680	71,210	92,060	2
2109,690	273,130	58,240	70,590	55,860	48,090	0,360	13,380	0,830	71,210	89,280	2

Figura 51 – Janela para visualização de dados

5.3.2.3 Treinamento e teste da RNA

O treinamento e teste da RNA são executados utilizando-se uma interface conforme apresentada na Figura 52. O processo completo consiste nos seguintes passos:

- Definir a arquitetura da RNA, ou seja, número de neurônios das camadas oculta, de saída e de entrada. Essa configuração alterando os valores das opções “*Hidden layer*”, “*Output layer*” e “*Input layer*”, respectivamente.
- Selecionar quais parâmetros serão utilizados como entrada para a RNA. Essa quantidade deve corresponder ao valor especificado para o campo “*Hidden Layer*”.
- Executar o treinamento e o teste clicando-se no botão *Configuration Test*. Essa opção realizará o treinamento da RNA gerando um arquivo de configuração da rede treinada. Para fins de verificação da precisão da RNA um gráfico circular é exibido apresentando, em azul, a precisão da rede na identificação correta das partículas de desgaste.




Figura 52 – Janela para treinamento e teste da RNA.




Figura 53 – Janela de análise de desempenho da RNA.

Um parâmetro fundamental no treinamento de uma RNA é o tempo de execução do processo. Conforme descrito no Capítulo 4, o treinamento de uma RNA consiste em um processo repetitivo. Deste modo, torna-se importante determinar qual a quantidade mínima de repetições necessárias para que o resultado obtido no treinamento, especificado pelo gráfico circular, mantenha-se estável. A Figura 53 apresenta um exemplo de resultado de desempenho o qual a estabilidade foi alcançada com, aproximadamente, 1000 épocas.

5.3.2.4 Análise de partículas

Com a rede devidamente treinada, é gerado um arquivo de configuração da RNA com relação à sua arquitetura, número de neurônios de cada camada, e as informações de entrada. Essa configuração é utilizada em uma interface específica para análise de partículas, apresentada na Figura 54.




Figura 54 – Janela para análise de partículas.

O procedimento para análise de um conjunto de partículas é simples, consistindo nos seguintes passos:

- Importar os dados para o formato reconhecido pelo NEURALNET-CBM, conforme descrito na subseção 5.3.2.1
- Selecionar a opção de menu “*WP Analysis*” da janela principal do módulo Partículas. Após isso, automaticamente, será exibida uma janela semelhante à descrita pela Figura 54, identificando as partículas na amostra analisada.

6 TESTES E RESULTADOS

Para a realização dos testes foi adotada a estratégia descrita na Figura 55. A sequência de processamento é dividida nas seguintes fases:

- Arquivo de Dados: essa etapa consiste em criar os arquivos no formato padrão reconhecido pelo protótipo NEURALNET-CBM a partir dos arquivos de dados gerados por um dado sistema de aquisição
- Parâmetros de Entrada: essa fase consiste no ajuste das melhores configurações de parâmetros de entrada capazes de proporcionar maior precisão da classificação. Aqui são consideradas RNAs com um, dois, três, quatro e cinco neurônios de entrada, com cada neurônio representando um parâmetro específico
- Configuração da RNA: definidos os parâmetros mais adequados a proporcionar uma classificação mais precisa, é gerado um arquivo de configuração da RNA para ser, posteriormente, utilizado pelo classificador.
- Análise dos Dados: essa última fase consiste na aplicação, de fato, do classificador no processo de monitoramento de condição de máquina.




Figura 55 – Estratégia dos testes.

As seções seguintes descrevem os dados utilizados nos testes e cada uma das etapas ilustradas na Figura 55.

6.1 Arquivos de dados

Para a realização de todos os testes foram utilizados três conjuntos específicos de amostras, duas específicas para análise de vibrações e uma para análise de partículas de desgaste. A fim de identificação esses dados foram nomeados de DATA-FEG1,

DATA-FEG2, DATA-RANDALL e DATA-CWRU, sendo os caracteres finais identificadores da origem dos experimentos que geraram as respectivas amostras.

6.1.1 DATA-FEG1

Este conjunto de amostras é proveniente de experimentos realizados no laboratório do Departamento de Mecânica da Universidade Paulista Júlio Mesquita, no campus da Faculdade de Engenharia de Guaratinguetá. Os dados foram coletados a partir da bancada ilustrada pela Figura 56. Ela é composta por um motor WEG de potência 1/2 cv (1), um mancal de rolamento (2), dois acelerômetros (3) de carga modelo B&K4371, com sensibilidade 9,77 pC/g, colocados na posição horizontal e vertical a fim de coletar dados importantes das vibrações de um rolamento (ZHANG ET AL, 2005).




Figura 56 – Bancada utilizada para experimentos DATA-FEG1.

Os sinais de saídas dos acelerômetros são condicionados através de um pré-amplificador de sinais da ENDEVCO modelo 133 (4). A saída do pré-amplificador de

senais foi conectada à entrada de uma placa de aquisição de dados (5) da empresa Lynx Tecnologia Eletrônica Ltda e os dados coletados foram manipulados pelo programa AQDADOS, resultando em um arquivo no formato ASCII, sendo esse o arquivo a ser importado para o formato NEURALNET-CBM. As informações referentes ao rolamento utilizado são descritas na Tabela 7.

Tabela 7 – Especificação do rolamento do experimento DATA-FEG1.

Rolamento	Diâmetro Interno	Diâmetro Externo	Espessura	Diâmetro da Esfera	Diâmetro Primitivo
NSK6205	0,9843	2,0472	0,5906	0,3126	1,537

Os experimentos foram realizados considerando cinco condições diferentes para um rolamento: sem defeito (R0), defeito suave na pista externa (R1), defeito acentuado na pista externa (R2), defeito suave na pista interna (R3) e defeito acentuado na pista interna (R4). Para cada condição foram aplicadas três velocidades diferentes, 1.200, 2100 e 3000 rpm, resultando em um total de 15 configurações distintas, identificadas na Tabela 9.

Tabela 8 – Configurações dos experimentos DATA-FEG1.

Identificação	Descrição do Rolamento	Velocidade do motor (rpm)
R0_V20	Sem defeito	1200
R1_V20	Defeito suave na pista externa	1200
R2_V20	Defeito acentuado na pista externa	1200
R3_V20	Defeito suave na pista interna	1200
R4_V20	Defeito acentuado na pista interna	1200
R0_V35	Sem defeito	2100
R1_V35	Defeito suave na pista externa	2100
R2_V35	Defeito acentuado na pista externa	2100
R3_V35	Defeito suave na pista interna	2100
R4_V35	Defeito acentuado na pista interna	2100
R0_V50	Sem defeito	3000
R1_V50	Defeito suave na pista externa	3000
R2_V50	Defeito acentuado na pista externa	3000
R3_V50	Defeito suave na pista interna	3000
R4_V50	Defeito acentuado na pista interna	3000

A taxa de amostragem aplicada à coleta dos dados para cada configuração foi de 20.000 amostras por segundo por um período de 5 segundos, totalizando, aproximadamente, 100.000 pontos coletados em cada arquivo.

6.1.2 DATA-CWRU

Esta base de dados trata-se dos experimentos desenvolvidos pela *Case Western Reserve University* com o apoio da *Rockwell Science Center* e da *Office of Naval Research* (CWRU, 2008), tendo como pesquisador principal o Dr. Kenneth A. Loparo. Estes experimentos foram realizados utilizando uma bancada, ilustrada pela Figura 57, constituída de um motor de indução trifásico modelo *Reliance Electric 2HP IQPreAlert*, um transdutor de torque, um dinamômetro (CWRU, 2008).




Figura 57 – Bancada utilizada para experimentos DATA-CWRU (CWRU, 2008).

Os dados foram coletados por meio de acelerômetros fixados com bases magnéticas na posição vertical, próximos aos rolamentos instalados nas extremidades de acionamento e do ventilador do motor. As especificações desses rolamentos são apresentadas na Tabela 9. A taxa de amostragem aplicada para coleta dos dados foi de 12.000 amostras por segundo para o rolamento do ventilador e 12.000 e 48.000 amostras por segundo para o rolamento do acionamento.

Tabela 9 – Especificações dos rolamentos - medidas em polegadas (CWRU, 2008).

Rolamento	Localização	Diâmetro Interno	Diâmetro Externo	Espessura	Diâmetro da Esfera	Diâmetro Primitivo
6205-2RS JEM SKF	Extremidade de Acionamento	0,9843	2,0472	0,5906	0,3126	1,537
6203-2RS JEM SKF	Extremidade do Ventilador	0,6693	1,5748	0,4724	0,2656	1,122

Com relação ao estado desses rolamentos, além de sua condição normal, ou seja, sem defeito, foram considerados três tipos de falhas: pista interna, pista externa e elemento de rolamento. Para cada tipo, foram introduzidos até cinco variações de falha, por meio de seu diâmetro, representando a severidade desta falha. A Tabela 10 apresenta uma relação completa de todas as condições tratadas nos experimentos. A relação completa de todos os arquivos resultantes dos experimentos, com base em todas as configurações realizadas, é apresentada no APÊNDICE A deste documento.

Tabela 10 – Especificações das falhas – em polegadas (CWRU, 2008).

Rolamento	Tipo de Falha	Diâmetro	Profundidade	Fabricante do Rolamento
Acionamento	Pista Interna	0,007	0,011	SKF
Acionamento	Pista Interna	0,014	0,011	SKF
Acionamento	Pista Interna	0,021	0,011	SKF
Acionamento	Pista Interna	0,028	0,050	NTN
Acionamento	Pista Externa	0,007	0,011	SKF
Acionamento	Pista Externa	0,014	0,011	SKF
Acionamento	Pista Externa	0,021	0,011	SKF
Acionamento	Pista Externa	0,028	0,050	NTN
Acionamento	Esfera	0,007	0,011	SKF
Acionamento	Esfera	0,014	0,011	SKF
Acionamento	Esfera	0,021	0,011	SKF
Acionamento	Esfera	0,028	0,150	NTN
Ventilador	Pista Interna	0,007	0,011	SKF
Ventilador	Pista Interna	0,014	0,011	SKF
Ventilador	Pista Interna	0,021	0,011	SKF
Ventilador	Pista Externa	0,007	0,011	SKF
Ventilador	Pista Externa	0,014	0,011	SKF
Ventilador	Pista Externa	0,021	0,011	SKF
Ventilador	Esfera	0,007	0,011	SKF
Ventilador	Esfera	0,014	0,011	SKF
Ventilador	Esfera	0,021	0,011	SKF

6.1.3 DATA-RANDALL

Esta base de dados é proposta por Randall (2011) e disponibilizada na web no site da editora *John Wiley & Sons, Inc.* Os dados se referem a sinais extraídos a partir de rolamento sem defeito, defeito na pista interna, defeito na pista externa e defeito no elemento de rolamento. Os dados disponibilizados pelo autor do referido rolamentos são: diâmetro d da esfera igual 7,12 mm, diâmetro primitivo D igual a 38,5 mm, número de esferas igual a 12 e ângulo de contato igual a 0° . Os dados foram coletados com uma frequência de amostragem de 48.000 amostras por segundo, sendo coletadas 100.000 amostras para cada condição de rolamento. Para todos os casos a velocidade do eixo foi 360 rpm.

6.1.4 DATA-FEG2

Este conjunto de amostras consiste em dados referentes a partículas de desgaste provenientes nos experimentos desenvolvidos em Gonçalves, Almeida e Mathias (2009). A base de dados contém informações referentes a quarenta partículas de desgaste, divididas em quatro grupos de dez partículas, cada um representando um tipo de desgaste específico: por abrasão (CW, do inglês *Cutting Wear*), por deslizamento severo (SW, do inglês *Severe Sliding Wear*), por fricção (RW, do inglês *Rubbing Wear*) e desgaste provocado pela fadiga (FW, do inglês *Fatigue Wear*). Para cada partícula são armazenadas as seguintes características morfológicas: área, perímetro, largura, altura, diâmetro principal, diâmetro secundário, circularidade, diâmetro de Feret, alongamento e razão de aspecto. O APÊNDICE B apresenta os valores dessas características para cada partícula.

6.2 Definição dos parâmetros de entrada

Conforme apresentado no Capítulo 3, existem diversas abordagens para extração de características tanto para sinais de vibração quanto para partículas de desgaste.

Neste trabalho, para a análise dos sinais de vibração são utilizadas dezesseis características estatísticas no domínio do tempo com base em diversos trabalhos propostos na literatura (MENDEL, 1991; TAX; YPMA; DUIN, 1999; SAMANTHA, AL-BALUSHI, 2003; TAKEYASU; KANEDA, 2004; NIU; ZHU; DING, 2005). Neste caso, as características utilizadas são: média, variância, curtose, assimetria, quinto ao nono momentos, valor rms, valor de pico, valor de pico-a-pico, fator de forma, fator de crista, fator impulso, fator de folga. Essas características foram calculadas para o sinal original, e para a diferença ou integral e a soma ou derivada do sinal que, respectivamente, têm por objetivo tentar destacar componentes de alta e de baixa frequência do sinal.

Com relação às partículas de desgaste, a análise se baseia em suas características morfológicas conforme os estudos de Xu e Luxmore (1997), Xu et al (1998), Laghari (2003), Laghari, Menon e Khuwaja (2004), Menon e Laghari (2005). As características

morfológicas utilizadas são: área, perímetro, largura, altura, diâmetro principal, diâmetro secundário, circularidade, alongamento, razão de aspecto e diâmetro de Feret.

Quando se deseja propor um recurso de *software* para análise baseada na aplicação de RNA, um dos fatores a se considerar está relacionado ao seu desempenho, e, neste sentido, podem ser citados dois importantes aspectos: confiabilidade na resposta dada e tempo de processamento da informação.

A confiabilidade na resposta está relacionada com a capacidade da RNA em efetuar a classificação com a menor taxa de erro possível e, no que diz respeito à configuração de uma RNA, isso depende de diversos fatores, tais como: quantidade de neurônios nas camadas de entrada e oculta, configuração ideal dos parâmetros a serem utilizados na camada de entrada, tempo de treinamento da RNA, dentre outros.

Por outro lado, o tempo de processamento depende diretamente da arquitetura da RNA, ou seja, a quantidade de neurônios em cada camada e o tempo necessário para seu aprendizado.

Deste modo, uma arquitetura ideal de RNA é aquela que proporcione resultados com uma menor taxa de erro possível em um tempo mais reduzido possível. Sendo assim, um primeiro ponto a ser considerado é a verificação da melhor combinação de dados de entrada para a análise de uma determinada massa de dados. Nessa etapa, busca-se a melhor combinação de parâmetros que resulte em maior incidência de classificações corretas.

Portanto, a fim de se definir o número adequado de neurônios para a camada de entrada e quais características a serem utilizadas para cada neurônio, foram consideradas as arquiteturas de RNA apresentadas nas Figuras 58 a 60.




Figura 58 – Arquitetura de RNA para classificação básica - módulo Vibrações.

Na Figura 58, as variáveis $x_{i,j}$, representam os neurônios da camada de entrada, sendo i o índice indicando uma dada característica no domínio do tempo e j indicando o tipo do sinal utilizado para o cálculo da característica, ou seja, original, integral do sinal ou derivada do sinal; as variáveis B representam o bias; as variáveis z_k representam os neurônios da camada oculta; e a variável y representa o neurônio da camada de saída da RNA.




Figura 59 – Arquitetura de RNA para classificação completa - módulo Vibrações.

A Figura 59 apresenta as mesmas variáveis da Figura 58, descritas anteriormente, exceto pelas variáveis da camada de saída. Cada y_m está relacionado a um tipo de defeito o qual a RNA se propõe a identificar.




Figura 60 – Arquitetura de RNA para classificação no módulo Partículas.

Na Figura 60, as variáveis x_i , representam os neurônios da camada de entrada, sendo i o índice indicando cada um dos 10 atributos morfológicos utilizados para análise da partícula; as variáveis z_j representam os neurônios da camada oculta; e as variáveis y_k representam os neurônios da camada de saída, cada um representando um tipo de partícula diferente.

Para os dados de vibração são aplicadas duas RNAs distintas: uma para classificação básica (Figura 56), ou seja, determinar a presença ou não de falha, e outra para, no caso de ser apontada a presença de uma falha (Figura 57), identificar o tipo de falha detectada. Para ambas RNAs a arquitetura proposta permite a aplicação de até dezesseis características, cada qual correspondendo a um conjunto de três neurônios, representando o resultado do cálculo da respectiva característica considerando os dados originais, a sua derivada e a sua integral. Para os dados DATA-FEG1 o total de características é duplicado pelo fato de se utilizar dois canais para aquisição dos dados.

Já para a análise de partículas é aplicada somente uma arquitetura de RNA (Figura 58), sendo essa adaptada para a aplicação de até dez neurônios para a camada de entrada.

O número de nós da camada de saída de cada RNA está associado ao número de

categorias que a rede irá tratar. Deste modo:

- para os dados DATA-FEG1 a camada de saída apresenta um nó para a classificação básica, representando ausência ou presença de falha e quatro nós para identificação do tipo de falha: defeito suave na pista interna, defeito acentuado na pista interna, representando defeito suave na pista externa e defeito acentuado na pista externa;
- para os dados DATA-CWRU a camada de saída apresenta: um nó para a classificação básica, representando ausência ou presença de falha; seis nós para a identificação do tipo de falha – defeito suave na pista interna, defeito acentuado na pista interna, defeito suave na pista externa, defeito acentuado na pista externa, defeito suave na esfera, defeito acentuado na esfera.
- para os dados DATA-RANDALL a camada de saída apresenta: um nó para a classificação básica, representando ausência ou presença de falha; três nós para identificação do tipo de falha – pista interna, pista externa e esfera.
- para os dados DATA-FEG2 a camada de saída apresenta quatro nós na camada de saída, representando desgaste por abrasão, deslizamento severo, fadiga e fricção.

Para cada configuração avaliada, foram realizadas 200 execuções, sendo ao final calculada a média aritmética expressando a porcentagem de acerto na classificação. Para cada execução a RNA foi treinada por um período de 8000 iterações para a classificação completa e 5000 iterações para a classificação básica na análise de vibrações e 5000 iterações na análise de partículas.

6.2.1 Resultados para base de dados DATA-FEG1

Neste conjunto de testes é analisada a capacidade da RNA em identificar a ausência ou presença de uma falha considerando 5 diferentes estados para um rolamento: sem defeito, defeitos suave e acentuado na pista interna e defeitos suave e acentuado na pista externa. Neste caso, para a saída da rede são estabelecidos dois valores distintos, -1 e 1, identificando, respectivamente, ausência ou presença de defeito no rolamento. Detectada a presença de falha, o próximo passo é avaliar a

habilidade da RNA de identificar o tipo de defeito, no caso, um dos 6 defeitos disponibilizados na base de dados.

Para cada estado, as respectivas amostras foram divididas em 50 segmentos, identificados por $S_1...S_{50}$, com 2048 pontos cada, sendo esses divididos em dois grupos de 25 segmentos, um para treinamento e outro para teste da RNA, com cada grupo totalizando 125 segmentos. Para cada segmento foram calculadas suas características, identificadas por $f_{i,j}$, com i variando de 1 até 16, representando cada uma das características no domínio do tempo propostas neste trabalho, e j variando de 1 até 3, representando, respectivamente, as amostras dos sinais originais e suas derivadas e integrais, totalizando, deste modo, 48 características. A Figura 61 apresenta o processo de criação dos arquivos de treinamento e de teste da RNA, para análise dos dados coletados à velocidade de 1.200 rpm.




Figura 61 – Processo de criação dos arquivos para treinamento e teste a partir de DATA-FEG1.

As RNAs ilustradas nas Figuras 56 e 57 são utilizadas para realização dos testes detalhados nas Tabelas 11 e 12, respectivamente. Para cada uma das três velocidades – 1.200, 2.100 e 3.000 rpm, a quantidade de características utilizada na camada de entrada de cada RNA foi fixada em uma unidade e, posteriormente, incrementada em uma unidade até não mais se obter um aumento na taxa de acerto entre a transição de uma configuração para outra.

Tabela 11 – Testes realizados para classificação básica - DATA-FEG1

Identificação do Teste	Neurônios na Camada de Entrada	Arquivos de Dados Utilizados
TESTE_FE01	3	R0_V20, R1_V20, R2_V20, R3_V20, R4_V20
TESTE_FE02	6	R0_V20, R1_V20, R2_V20, R3_V20, R4_V20
TESTE_FE03	9	R0_V20, R1_V20, R2_V20, R3_V20, R4_V20
TESTE_FE04	3	R0_V35, R1_V35, R2_V35, R3_V35, R4_V35
TESTE_FE05	6	R0_V35, R1_V35, R2_V35, R3_V35, R4_V35
TESTE_FE06	9	R0_V35, R1_V35, R2_V35, R3_V35, R4_V35
TESTE_FE07	12	R0_V35, R1_V35, R2_V35, R3_V35, R4_V35
TESTE_FE08	15	R0_V35, R1_V35, R2_V35, R3_V35, R4_V35
TESTE_FE09	18	R0_V35, R1_V35, R2_V35, R3_V35, R4_V35
TESTE_FE10	3	R0_V50, R1_V50, R2_V50, R3_V50, R4_V50

Tabela 12 – Testes realizados para classificação completa - DATA-FEG1.

Identificação do Teste	Neurônios na Camada de Entrada	Arquivos de Dados Utilizados
TESTE_FE11	3	R1_V20, R2_V20, R3_V20, R4_V20
TESTE_FE12	6	R1_V20, R2_V20, R3_V20, R4_V20
TESTE_FE13	9	R1_V20, R2_V20, R3_V20, R4_V20
TESTE_FE14	3	R1_V35, R2_V35, R3_V35, R4_V35
TESTE_FE15	6	R1_V35, R2_V35, R3_V35, R4_V35
TESTE_FE16	9	R1_V35, R2_V35, R3_V35, R4_V35
TESTE_FE17	12	R1_V35, R2_V35, R3_V35, R4_V35
TESTE_FE18	3	R1_V50, R2_V50, R3_V50, R4_V50
TESTE_FE19	6	R1_V50, R2_V50, R3_V50, R4_V50
TESTE_FE20	9	R1_V50, R2_V50, R3_V50, R4_V50
TESTE_FE21	12	R1_V50, R2_V50, R3_V50, R4_V50
TESTE_FE22	15	R1_V50, R2_V50, R3_V50, R4_V50

As Tabelas 13, 14 e 15 apresentam o resultado para uma, duas e três características, respectivamente, aplicadas a RNA para classificação básica, considerando a velocidade de 1.200 rpm. Percebe-se que com três características foi possível se alcançar a meta de pelo menos 99% na taxa de acerto, tendo como maior valor a combinação das características assimetria, 7º momento e valor pico-a-pico.

Tabela 13 – Resultados obtidos para TESTE_FE01.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor de pico	93,0
fator de impulso	90,9
valor pico-pico	89,7
fator de crista	89,1

Tabela 14 – Resultados obtidos para TESTE_FE02.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
média	variância	98,6
média	valor pico-a-pico	98,3
média	rms	98,2

Tabela 15 – Resultados obtidos para TESTE_FE03.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
assimetria	7º momento	valor pico-a-pico	99,9
média	assimetria	7º momento	98,9
média	assimetria	5º momento	98,4
média	assimetria	9º momento	98,4
assimetria	9º momento	rms	98,2
5º momento	rms	valor de pico	98,1

Quando aplicada a velocidade de 2.100 rpm a RNA proposta para a classificação básica obtém, no máximo, o valor de 95,8% de taxa de acerto, tendo como entrada as características variância, assimetria, 9º momento, valor de pico, valor pico-a-pico e fator de crista. A evolução dos resultados obtidos, considerando de uma a seis características na camada de entrada, é apresentada na Tabelas 16 a 21.

Tabela 16 – Resultados obtidos para TESTE_FE04.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor de pico	91,2
assimetria	91,0
valor pico-a-pico	89,6
fator de impulso	85,9

Tabela 17 – Resultados obtidos para TESTE_FE05.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
Rms	valor pico-a-pico	90,6
assimetria	8º momento	89,9
assimetria	curtose	88,9
Assimetria	fator de impulso	88,3

Tabela 18 – Resultados obtidos para TESTE_FE06.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
Média	assimetria	7º momento	92,1
assimetria	curtose	7º momento	92,1
assimetria	curtose	valor pico-a-pico	92,1
assimetria	8º momento	valor de pico	92,0

Tabela 19 – Resultados obtidos para TESTE_FE07.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Características $f_{4,1}; f_{4,2}; f_{4,3}$	Acerto (%)
assimetria	6º momento	9º momento	valor de pico	93,7
assimetria	6º momento	7º momento	rms	93,6
assimetria	7º momento	valor de pico	fator de forma	93,3
assimetria	9º momento	valor pico-a-pico	fator de forma	93,3
assimetria	7º momento	rms	fator de folga	93,0

Tabela 20 – Resultados obtidos para TESTE_FE08.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Características $f_{4,1}; f_{4,2}; f_{4,3}$	Características $f_{5,1}; f_{5,2}; f_{5,3}$	Acerto (%)
média	assimetria	8º momento	9º momento	valor pico-a-pico	94,4
assimetria	curtose	5º momento	7º momento	valor pico-a-pico	94,3
assimetria	8º momento	9º momento	valor de pico	valor pico-a-pico	94,1

Tabela 21 – Resultados obtidos para TESTE_FE09.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Características $f_{4,1}; f_{4,2}; f_{4,3}$	Características $f_{5,1}; f_{5,2}; f_{5,3}$	Características $f_{6,1}; f_{6,2}; f_{6,3}$	Acerto (%)
variância	assimetria	9º momento	valor de pico	valor pico-a-pico	fator de crista	95,8
média	assimetria	Curtose	5º momento	9º momento	valor pico-a-pico	95,5
média	assimetria	7º momento	rms	valor de pico	valor pico-a-pico	95,3
média	assimetria	6º momento	9º momento	valor de pico	valor pico-a-pico	95,0

Por outro lado, a RNA utilizada para a classificação básica obtém um bom resultado na classificação quando aplicada a velocidade de 3000 rpm. A Tabela 22 confirmam esta evidência apresentando valores de 100% de acerto no processo de classificação utilizando apenas uma característica.

Tabela 22 – Resultados obtidos para TESTE_FE10.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
rms	100,0
valor pico-a-pico	99,9
valor de pico	94,4

As Tabelas 23 a 25 apresentam os resultados referentes à RNA para classificação completa, quando aplicada a velocidade de 1.200 rpm. Para estes testes verifica-se que com 3 características foi possível alcançar a taxa de 99% de acerto na classificação, tendo como melhor configuração a utilização das características média, variância e valor de pico-a-pico.

Tabela 23 – Resultados obtidos para TESTE_FE11.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor pico-pico	91,3
variância	87,8
rms	86,9

Tabela 24 – Resultados obtidos para TESTE_FE12.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
variância	assimetria	97,7
média	rms	97,2
assimetria	rms	97,0
média	valor pico-pico	96,6
média	variância	96,1

Tabela 25 – Resultados obtidos para TESTE_FE13.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
média	variância	8º momento	99,3
média	variância	valor pico-a-pico	99,2
média	5º momento	Rms	99,2
média	9º momento	Rms	99,1

As Tabelas 26 a 29 apresentam os resultados referentes à RNA para classificação completa, quando aplicada a velocidade de 2.100 rpm. Para estes foram necessárias 4 características para se obter a taxa de 99% de acerto na classificação, sendo a melhor melhor configuração contendo as características média, assimetria, rms e valor de pico-a-pico.

Tabela 26 – Resultados obtidos para TESTE_FE14.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
variância	95,7
rms	94,7
valor pico-pico	87,5

Tabela 27 – Resultados obtidos para TESTE_FE15.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
variância	assimetria	97,7
variância	valor de pico	97,1
média	variância	96,9
Rms	valor pico-pico	96,9
variância	5º momento	96,8
Rms	valor de pico	96,7

Tabela 28 – Resultados obtidos para TESTE_FE16.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
média	rms	valor pico-a-pico	98,4
média	variância	valor de pico	98,2
média	5º momento	rms	98,2
variância	valor de pico	fator de folga	98,2
assimetria	9º momento	Rms	98,1
média	rms	valor de pico	98,1

Tabela 29 – Resultados obtidos para TESTE_FE17.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Características $f_{4,1}; f_{4,2}; f_{4,3}$	Acerto (%)
média	assimetria	rms	valor pico-a-pico	99,4
média	variância	assimetria	valor pico-a-pico	99,2
assimetria	7º momento	rms	fator de impulso	99,1

Por fim, as Tabelas 30 a 33 descrevem os resultados obtidos com a RNA para classificação completa, quando aplicada a velocidade de 3.000 rpm. Neste caso, o valor máximo obtido foi de 98% de acerto na classificação, tendo como melhor configuração a combinação das características assimetria, 7º momento, rms e valor de pico.

Tabela 30 – Resultados obtidos para TESTE_FE18.

Características: $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor de pico	88,7
rms	85,4
variância	82,5
valor pico-a-pico	77,7

Tabela 31 – Resultados obtidos para TESTE_FE19.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
valor de pico	ft. impulso	93,2
variância	Rms	92,8
8º momento	Rms	92,8
valor de pico	fator de crista	92,1

Tabela 32 – Resultados obtidos para TESTE_FE20.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
6º momento	Rms	valor de pico	96,3
variância	assimetria	valor de pico	95,5
assimetria	Rms	valor de pico	95,4
5º momento	Rms	valor de pico	95,3

Tabela 33 – Resultados obtidos para TESTE_FE21.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Características $f_{4,1}; f_{4,2}; f_{4,3}$	Acerto (%)
assimetria	7º momento	rms	valor de pico	98.4
assimetria	8º momento	rms	valor de pico	97.6
variância	assimetria	curtose	valor de pico	96.2
variância	5º momento	6º momento	valor de pico	96.2

6.2.2 Resultados para base de dados DATA-CWRU

Para estes testes o objetivo é verificar a capacidade da RNA em identificar a ausência ou presença de uma falha considerando 7 diferentes estados para um rolamento: sem defeito, defeitos suave e acentuado na pista interna, defeitos suave e acentuado na pista externa, defeitos suave e acentuado na esfera. Os valores de saída

da RNA são os mesmos utilizados para os dados DATA-FEG1, ou seja, -1 e 1, identificando, respectivamente, ausência ou presença de defeito no rolamento. Detectada a presença de falha, o próximo passo é avaliar a habilidade da RNA de identificar o tipo de defeito, no caso, um dos 6 defeitos disponibilizados na base de dados.

Para cada estado, as respectivas amostras foram divididas em 200 segmentos, identificados por $S_1...S_{200}$, com 2048 pontos cada, sendo esses divididos em dois grupos de 100 segmentos, um para treinamento e outro para teste da RNA, com cada grupo totalizando 700 segmentos. O processo para cálculo das características é o mesmo daquele executado para a base de dados DATA-FEG1. A Figura 62 apresenta um exemplo do processo de criação dos arquivos de treinamento e de teste da RNA, para análise dos dados.




Figura 62 – Processo de criação dos arquivos para treinamento e teste a partir de DATA-CWRU.

As RNAs ilustradas nas Figuras 56 e 57 são utilizadas para realização dos testes detalhados nas Tabelas 34 e 35, respectivamente. Para cada uma das quatro velocidades – 1.797, 1.772, 1.750 e 1.730 rpm, o critério para incremento na quantidade de características utilizada na camada de entrada de cada RNA foi idêntico aos testes com DATA-FEG1.

Tabela 34 – Testes realizados utilizando para classificação básica para dados DATA-CWRU.

Identificação do Teste	Neurônios na Camada de Entrada	Arquivos de Dados Utilizados
TESTE_CW01	3	Normal_0, OR007_0, OR021_0, IR007_0, IR021_0, B007_0, B021_0
TESTE_CW02	3	Normal_1, OR007_1, OR021_1, IR007_1, IR021_1, B007_1, B021_1
TESTE_CW03	3	Normal_2, OR007_2, OR021_2, IR007_2, IR021_2, B007_2, B021_2
TESTE_CW04	3	Normal_3, OR007_3, OR021_3, IR007_3, IR021_3, B007_3, B021_3

Tabela 35 – Testes realizados utilizando para classificação completa para dados DATA-CWRU.

Identificação do Teste	Neurônios na Camada de Entrada	Arquivos de Dados Utilizados
TESTE_CW05	3	OR007_0, OR021_0, IR007_0, IR021_0, B007_0, B021_0
TESTE_CW06	6	OR007_0, OR021_0, IR007_0, IR021_0, B007_0, B021_0
TESTE_CW07	9	OR007_0, OR021_0, IR007_0, IR021_0, B007_0, B021_0
TESTE_CW08	3	OR007_1, OR021_1, IR007_1, IR021_1, B007_1, B021_1
TESTE_CW09	6	OR007_1, OR021_1, IR007_1, IR021_1, B007_1, B021_1
TESTE_CW10	9	OR007_1, OR021_1, IR007_1, IR021_1, B007_1, B021_1
TESTE_CW11	3	OR007_2, OR021_2, IR007_2, IR021_2, B007_2, B021_2
TESTE_CW12	6	OR007_2, OR021_2, IR007_2, IR021_2, B007_2, B021_2
TESTE_CW13	9	OR007_2, OR021_2, IR007_2, IR021_2, B007_2, B021_2
TESTE_CW14	3	OR007_3, OR021_3, IR007_3, IR021_3, B007_3, B021_3
TESTE_CW15	6	OR007_3, OR021_3, IR007_3, IR021_3, B007_3, B021_3
TESTE_CW16	9	OR007_3, OR021_3, IR007_3, IR021_3, B007_3, B021_3

As Tabelas 36 a 51 apresentam as configurações que obtiveram os melhores resultados considerando-se até três nós na camada de entrada. Estes resultados se referem à base de dados DATA-CWRU.

Considerando a classificação básica, a RNA foi capaz de realizar a classificação com 100% de acerto para todas as velocidades aplicadas. Os resultados podem ser observados nas Tabelas 36 a 39.

Tabela 36 – Resultados obtidos para TESTE_CW01.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor pico-a-pico	100,0
valor de pico	99,3
assimetria	99,2
rms	98,7

Tabela 37 – Resultados obtidos para TESTE_CW02.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor de pico-a-pico	100,0
rms	99,7
variância	99,5

Tabela 38 – Resultados obtidos para TESTE_CW03.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor pico-a-pico	100,0
variância	98,9
rms	98,9
fator de forma	98,9
fator de folga	98,9

Tabela 39 – Resultados obtidos para TESTE_CW04.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor pico-a-pico	100,0
variância	99,9
rms	99,7
valor de pico	99,5
média	99,4

Quando aplicada a velocidade de 1.797 rpm e considerando a classificação completa, a RNA consegue, no máximo, efetuar uma classificação correta em uma taxa de 95,9%, utilizando três características, rms, fator de crista e fator de folga. Os resultados são apresentados na Tabelas 40 a 42.

Tabela 40 – Resultados obtidos para TESTE_CW05.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor pico-a-pico	82,4
valor de pico	81,6
rms	80,6

Tabela 41 – Resultados obtidos para TESTE_CW06.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
rms	valor de pico	93,9
rms	fator de forma	92,8
variância	curtose	91,9
rms	fator de folga	91,5

Tabela 42 – Resultados obtidos para TESTE_CW07.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
rms	fator de crista	fator de folga	95,9
variância	6º momento	rms	95,4
valor de pico	fator de forma	fator de crista	95,3
curtose	rms	fator de impulso	94,8

Para a velocidade de 1.772 rpm e considerando a classificação completa, a RNA consegue classificar corretamente um determinado defeito a uma taxa máxima de 95,7%, também, para este caso, utilizando três características na camada de entrada, rms, valor de pico e fator de crista. Os resultados são apresentados na Tabelas 43 a 45.

Tabela 43 – Resultados obtidos para TESTE_CW09.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
rms	74,2
valor pico-a-pico	71,2
fator de forma	65,2
fator de impulso	60,8

Tabela 44 – Resultados obtidos para TESTE_CW09.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
curtose	rms	93,9
rms	valor pico-a-pico	88,9
rms	fator de folga	87,8

Tabela 45 – Resultados obtidos para TESTE_CW10.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
rms	valor de pico	fator de crista	95,7
curtose	6º momento	rms	95,4
6º momento	rms	fator de folga	95,3
rms	fator de forma	fator de crista	95,1

As Tabelas 46 a 48 ilustram os resultados da RNA para os dados coletados a uma velocidade de 1.750 rpm. Nessa situação, obtém-se um índice máximo de 99,6% na classificação correta do tipo de defeito, tendo como entrada, as características média curtose e valor pico-a-pico.

Tabela 46 – Resultados obtidos para TESTE_CW11

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor pico-a-pico	86,7
valor de pico	81,9
rms	81,0

Tabela 47 – Resultados obtidos para TESTE_CW12

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
média	valor pico-a-pico	95,8
média	valor de pico	93,1

Tabela 48 – Resultados obtidos para TESTE_CW13

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
média	curtose	valor pico-a-pico	99,6
média	valor de pico	fator de folga	99,1
média	curtose	valor de pico	98,8
média	valor de pico	fator de forma	98,6

Por fim, no caso dos dados coletados a velocidade de 1.730 rpm, a RNA alcança

um valor de 99,4% para a classificação correta do tipo de defeito detectado. Os resultados são apresentados na Tabelas 49 a 51.

Tabela 49 – Resultados obtidos para TESTE_CW14.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
rms	65,9
valor pico-a-pico	63,7
valor de pico	62,4

Tabela 50 – Resultados obtidos para TESTE_CW15.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
curtose	rms	94,4
rms	fator de impulso	92,5
rms	fator de forma	91,6

Tabela 51 – Resultados obtidos para TESTE_CW16.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
curtose	rms	fator de forma	99,4
8º momento	rms	fator de forma	98,9
6º momento	rms	fator de forma	98,5
8º momento	rms	fator de folga	98,2

6.2.3 Resultados para base de dados DATA-RANDALL

Para os testes com essa base de dados analisa-se a capacidade da RNA em identificar a ausência ou presença de uma falha considerando 4 diferentes estados para um rolamento: sem defeito, defeito na pista interna, defeito na pista externa e defeito na esfera. Assim como nos testes anteriores, para a saída da rede são estabelecidos dois valores distintos, -1 e 1, identificando, respectivamente, ausência ou presença de defeito no rolamento. Detectada a presença de falha, o próximo passo é avaliar a habilidade da RNA de identificar o tipo de defeito, no caso, um dos 3 defeitos disponibilizados na base de dados.

As respectivas amostras de cada estado foram divididas em 90 segmentos, identificados por $S_1...S_{90}$, com 1024 pontos cada, sendo esses divididos em dois grupos de 45 segmentos, um para treinamento e outro para teste da RNA, com cada grupo totalizando 180 segmentos. Para cada segmento foram calculadas suas características, identificadas por $f_{i,j}$, com i variando de 1 até 16, representando cada uma das

características no domínio do tempo propostas neste trabalho, e j variando de 1 até 3, representando, respectivamente, as amostras dos sinais originais e suas derivadas e integrais, totalizando, deste modo, 48 características. A Figura 62 apresenta o processo de criação dos arquivos de treinamento e de teste da RNA, para análise dos dados coletados à velocidade de 360 rpm.




Figura 63 – Processo de criação dos arquivos para treinamento e teste a partir de DATA-RANDALL.

As RNAs ilustradas nas Figuras 58 e 59 são utilizadas para realização dos testes detalhados nas Tabelas 52 e 53, respectivamente. A quantidade de características utilizada na camada entrada de cada RNA foi fixada em uma unidade e, posteriormente, incrementada em uma unidade até não mais se obter um aumento na taxa de acerto entre a transição de uma configuração para outra.

Tabela 52 – Testes realizados para classificação básica – DATA-RANDALL.

Identificação do Teste	Neurônios na Camada de Entrada	Arquivos de Dados Utilizados
TESTE_RA01	3	GoodBear, Fault1, Fault2, Fault3
TESTE_RA02	6	GoodBear, Fault1, Fault2, Fault3
TESTE_RA03	9	GoodBear, Fault1, Fault2, Fault3

Tabela 53 – Testes realizados para classificação completa – DATA-RANDALL.

Identificação do Teste	Neurônios na Camada de Entrada	Arquivos de Dados Utilizados
TESTE_RA04	3	GoodBear, Fault1, Fault2, Fault3
TESTE_RA05	6	GoodBear, Fault1, Fault2, Fault3
TESTE_RA06	9	GoodBear, Fault1, Fault2, Fault3
TESTE_RA07	12	GoodBear, Fault1, Fault2, Fault3

As Tabelas 54, 55 e 56 apresentam o resultado para uma, duas e três características, respectivamente, aplicadas a RNA para classificação básica. Com três características foi possível se alcançar a meta de pelo menos 98,9% na taxa de acerto, tendo como maior valor a combinação das características 8º momento, valor pico-a-

pico e fator de folga.

Tabela 54 – Resultados obtidos para TESTE_RA01.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor de pico	94,1
valor pico-pico	92,7
rms	89,5

Tabela 55 – Resultados obtidos para TESTE_RA02.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
valor de pico	fator de impulso	96,9
valor pico-a-pico	fator de impulso	96,4
valor pico-a-pico	fator de folga	96,4
variância	fator de folga	96,4
rms	valor de pico	94,7

Tabela 56 – Resultados obtidos para TESTE_RA03.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
8º momento	valor pico-a-pico	fator de folga	98,9
valor pico-a-pico	fator de forma	fator de folga	98,5
6º momento	rms	valor pico-a-pico	98,5
curtose	8º momento	valor pico-a-pico	97,7
curtose	rms	valor pico-a-pico	97,7
rms	valor de pico	fator de impulso	97,6

As Tabelas 57, 58 e 59 apresentam os resultados referentes à RNA para classificação completa. Para estes testes verifica-se que com 3 características foi possível alcançar a taxa de 96,2% de acerto na classificação, tendo como melhor configuração a utilização das características variância e valor de pico e fator de impulso.

Tabela 57 – Resultados obtidos para TESTE_RA04.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Acerto (%)
valor pico-a-pico	88,9
valor de pico	84,4
variância	77,5
rms	73,4

Tabela 58 – Resultados obtidos para TESTE_RA05.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Acerto (%)
variância	valor de pico	90,8
média	valor de pico	88,6
valor de pico	fator de crista	88,6
média	valor pico-a-pico	88,5

Tabela 59 – Resultados obtidos para TESTE_RA06.

Características $f_{1,1}; f_{1,2}; f_{1,3}$	Características $f_{2,1}; f_{2,2}; f_{2,3}$	Características $f_{3,1}; f_{3,2}; f_{3,3}$	Acerto (%)
variância	valor de pico	fator de impulso	96,2
variância	rms	valor de pico	95,9
variância	valor de pico	fator de forma	95,2
variância	rms	valor pico-a-pico	94,1
rms	valor de pico	valor pico-a-pico	94,1

6.2.4 Resultados para base de dados DATA-FEG2

Estes testes consistem na avaliação do módulo Partículas do protótipo NEURALNET-CBM. Para isto, são utilizados os dados provenientes nos experimentos desenvolvidos em Gonçalves, Almeida e Mathias (2009). Essa base de dados consiste de um arquivo contendo as características extraídas de 40 partículas, sendo 10 partículas para cada tipo de desgaste analisado: abrasão, corte, deslizamento severo e fadiga.

Para a classificação é utilizada a RNA ilustrada na Figura 58. Neste caso, cada neurônio de saída da rede é mapeado a um tipo específico de desgaste considerado. Desta maneira, conforme um determinado neurônio torna-se ativo, a RNA classifica a partícula como o tipo de desgaste correspondente.

Nesta etapa, os testes visam encontrar a configuração com a quantidade mínima de características com melhor desempenho no que diz respeito à taxa de acerto na classificação. Por conseguinte, são apresentadas as Tabelas 60 a 62, as quais demonstram que a melhor combinação é a utilização de 3 características, resultando em um valor de 96,2% de acerto na classificação das partículas, tendo como entrada as seguintes características: área, largura do retângulo e eixo secundário.

Tabela 60 – Resultados para DATA-FEG2 utilizando RNA com um neurônio na camada de entrada.

Característica 1	Acerto (%)
eixo secundário	73.7
largura	67.5
área	66.3
circularidade	64.1

Tabela 61 – Resultados para DATA-FEG2 utilizando RNA com dois neurônios na camada de entrada.

Característica 1	Característica 2	Acerto (%)
eixo secundário	circularidade	89,5
largura	eixo secundário	88,0
eixo secundário	<i>aspect ratio</i>	85,0
área	eixo secundário	80,5

Tabela 62 – Resultados para DATA-FEG2 utilizando RNA com três neurônios na camada de entrada.

Característica 1	Característica 2	Característica 3	Acerto (%)
área	largura	eixo secundário	96,2
área	eixo secundário	circularidade	94,0
eixo secundário	circularidade	<i>aspect ratio</i>	92,7

6.3 Configuração da RNA

Finalizada a etapa de treinamento da RNA tem-se a configuração ideal a ser utilizada pelo classificador. Entretanto, torna-se necessário a criação de um arquivo contendo as seguintes informações desta configuração: número de neurônios nas camadas de entrada, oculta e de saída, lista das características a serem utilizadas na camada de entrada, lista das falhas ou tipos de desgaste treinados e os pesos das conexões. A estrutura do arquivo de configuração é ilustrada na Figura 63.

```

Total de neurônios na camada de entrada
Índice da característica 1
...
Índice da característica N
Total de neurônios na camada oculta
Total de neurônios falhas treinadas
Lista das falhas/desgastes treinados
Lista de pesos

```

Figura 64 – Estrutura do arquivo de configuração da RNA para o classificador.

Para a identificação das características definidas como entrada da RNA, são armazenados índices conforme a descrição dada nas Tabelas 63 e 64.

Tabela 63 – Identificação das características para módulo Vibrações.

Índice	Característica
0	média
1	variância
2	assimetria
3	curtose
4	5º Momento
5	6º Momento
6	7º Momento
7	8º Momento
8	9º Momento
9	rms
10	valor de pico
11	valor pico-a-pico
12	fator de forma
13	fator de crista
14	fator de impulso
15	fator de folga

Tabela 64 – Identificação das características para módulo Partículas.

índice	Característica
0	área
1	perímetro
2	largura
3	altura
4	eixo primário
5	eixo secundário
6	circularidade
7	alongamento
8	<i>aspect ratio</i>
9	diâmetro de Feret

Com o arquivo de configuração criado é possível disponibilizar a RNA para um módulo classificador responsável, exclusivamente, em analisar os dados provenientes de dado sistema de aquisição. A fim de demonstrar o sistema classificador a ser utilizado, o protótipo NEURALNET-CBM apresenta um modelo básico de classificador. Por exemplo, para o módulo Vibrações a classificação é dividida em duas fases distintas: detecção de presença ou não de falha no rolamento e, se houver, identificação do tipo de falha, de acordo com aquelas conhecidas pela RNA. A Figura 64 apresenta uma situação em que ocorre uma falha e a Figura 65 ilustra a falha identificada pelo classificador como sendo de pista interna em um estágio avançado.




Figura 65 – Classificador indicando presença de falha no rolamento.




Figura 66 – Classificador indicando defeito acentuado na pista interna.

Portanto, no possível desenvolvimento de um sistema a ser implantado em um ambiente real, as janelas apresentadas nas Figuras 65 e 66 seriam uma das ferramentas para monitoramento do equipamento.

7 CONSIDERAÇÕES FINAIS

Essa tese abordou a aplicação de técnicas de IA no projeto de sistemas classificadores no apoio ao monitoramento de condição de máquinas. Mais especificamente, foi apresentada a aplicação de agentes classificadores baseados em Redes Neurais Artificiais devido ao grande retrospecto desta técnica na solução de problemas de previsão nas mais diversas áreas de conhecimento (SCOTT, SHAVLIK, RAY, 1992; VENAYAGAMOORTHY, MOOSASAR, SANDRASEGARAN, 1998; RAMÍREZ; WEIGANG; FERREIRA, 1999; DE CASTRO, VON ZUBEN, 1999; GUNGO, RODRIGUES, THOMÉ, 2002; ENNS, SI, 2003; LAGHARI, 2003; RAFIEE ET AL, 2007).

O protótipo desenvolvido, denominado NEURALNET-CBM, atualmente dividido em dois módulos – Vibrações e Partículas, propõe a utilização de uma RNA do tipo MLP utilizando como entrada características estatísticas dos sinais de vibração coletados e morfológicas das partículas de desgaste. Os testes e os resultados demonstraram alguns aspectos positivos da RNA implementada, dentre os quais podem ser destacados:

- Possibilidade de se tratar dados provenientes de vários sistemas de aquisição de dados, importando-os para um formato padrão que, posteriormente, pode ser utilizado para diversos fins, como por exemplo, exibição do sinal e das características, análise dos dados.
- Identificação correta dos dados superior a 95%, conforme apresentado nas Tabelas 65 e 66. Esse fato, desperta a possibilidade no desenvolvimento de um sistema de apoio ao monitoramento de máquinas a ser utilizado. Neste caso, a proposta é um sistema composto por dois programas distintos: um primeiro, com as mesmas características do NEURALNET-CBM, responsável em treinar a RNA para atender às especificações de treinamento para uma dada máquina, tendo como objetivo gerar um arquivo de configuração para o agente classificador; um segundo, de menor porte, contendo somente o agente classificador, a ser instalado em um hardware próximo à máquina, a fim de auxiliar o monitoramento do equipamento no

qual a RNA foi treinada.

- Necessidade, na maioria dos testes, de uma pequena quantidade de características para obtenção de resultados acima de 95% resultando em um processamento ainda mais rápido e viabilizando sua implementação *online*.

Tabela 65 – Resumo dos resultados para módulo Vibrações.

Base de Dados		Classificação Básica		Classificação Completa	
Identificação	Velocidade (rpm)	Acerto (%)	Número de Características	Acerto (%)	Número de Características
DATA-FEG1	1.200	99,9	3	99,3	3
	2.100	95,8	6	99,4	4
	3.000	100,0	1	98,4	4
DATA-CWRU	1.797	100,0	1	95,9	3
	1.772	100,0	1	95,7	3
	1.750	100,0	1	99,6	3
	1.730	100,0	1	99,4	3
DATA-RANDALL	360	98,9	3	95,4	3

Tabela 66 – Resumo dos resultados para módulo Partículas.

Base de Dados	Acerto (%)	Número de Características
DATA-FEG2	96,4	3

Entretanto, para fins de aprimoramento dos estudos aqui realizados alguns pontos devem ser relevados para o desenvolvimento de um sistema mais completo. Para isso, pode-se citar:

- Os dados para o módulo de Partículas são provenientes de um sistema de processamento de imagens, ou seja, as características utilizadas não são geradas pelo NEURALNET-CBM. Isso pode ocasionar a geração de um conjunto de características morfológicas de qualidade limitada e, conseqüentemente, uma menor taxa de acerto no processo de identificação de partículas. Dessa forma, seria interessante a inclusão de um módulo de processamento de imagens que calculasse os atributos morfológicos a serem utilizados pelo classificador, evitando, assim, possíveis
- A análise atual para o módulo de Vibrações trata-se somente de características no domínio do tempo. Diversas pesquisas destacam abordagens baseadas na análise no domínio da frequência, como por exemplo, transformada rápida de

Fourier (SCHOEN, HABETLER, 1995, LIU ET AL, 2004). Como trabalho futuro, seria interessante uma pesquisa mais aprofundada para esse tipo de análise a fim de incorporar funcionalidades adicionais que possam viabilizar análises que, porventura, o modelo atual seja incapaz de tratar.

- Para o módulo Partículas, propõe-se outros tipos de análises, além da morfológica, como, por exemplo, a análise por composição que permite a identificação da partícula como sendo não-metálica ou metálica, nesse caso, subdividindo-a em metais ferrosos e não-ferroso. Essa classificação indica a fonte geradora da partícula (LAGHARI, 2003).
- Como classificador, adotou-se a abordagem baseada em RNA, proporcionando um classificador determinístico o qual identifica uma dada falha ou partícula. Outra abordagem que pode ser utilizada é aquela baseada em inferência Bayesiana, que, adicionalmente, oferece a informação probabilística com relação à possibilidade de falha.

Por fim, este trabalho levanta a hipótese no desenvolvimento de um sistema a ser utilizado conforme o sistema de aquisição de dados. Entretanto, quando se trata de um sistema de manutenção, um importante fator para sua viabilização é custo no seu desenvolvimento. Neste sentido, o protótipo NEURALNET-CBM tem a limitação de ser desenvolvido em uma versão acadêmica no *software* Borland Builder C++, necessitando da compra da licença completa para sua utilização e, até mesmo, para seu aprimoramento como um sistema, gerando, para isso, um custo adicional. Quando se trata de empresas de pequeno porte, esse custo adicional pode se tornar inviável.

Como sugestões para redução expressiva de custo, no caso de surgir um interesse na conversão do NEURALNET-CBM em um sistema, tem-se: desenvolvimento em linguagem Java ou C ANSI, possibilitando sua instalação em máquinas com qualquer sistema operacional, inclusive Linux, dispensando a compra de qualquer licença adicional para sua utilização.

Por outro lado, para grandes empresas esse custo pode ser relevado, devido a um possível benefício envolvido. Dessa forma, o desenvolvimento com o atual pacote de *software* justificar-se-ia. Um recurso de *software* muito útil para desenvolvimento de aplicações envolvendo processamento de sinais é o LabVIEW. Trata-se de um

ambiente gráfico desenvolvido pela empresa *National Instruments* que possui um interessante conjunto de ferramentas embutido para processamento de sinais, tendo como características, no processo de desenvolvimento: a dispensa de alocação de memória e declaração de variáveis; não precisa compilar; controle de instrumentos ou de aquisição de dados altamente integrado; excelentes ferramentas para exibição de sinais digitais (CLARK, 2005).

Em suma, dentro da proposta dessa tese de aplicar uma RNA genérica para fins de utilização no monitoramento de vibrações e análise de partículas de desgaste o resultado obtido, por meio da implementação do protótipo NEURALNET-CBM, demonstrou sua efetividade na classificação de diferentes bases de dados, alcançando, inclusive, uma taxa de acerto superior a 95%. Isso motiva a um aprimoramento para construção de um *software* mais completo a ser implantado, no futuro, em um ambiente real de manutenção preditiva.

REFERÊNCIAS

ABDALLAH, R. R. **Uma experiência de aplicação do sistema APPCC (Análise de Perigos em Pontos Críticos de Controle) em uma indústria de laticínios**, 1997, 142f. Dissertação (Mestrado em Engenharia de Produção) Departamento de Engenharia de Produção e Sistemas, Universidade Federal de Santa Catarina, Florianópolis, 1997.

ABRAMAN, A situação da manutenção no Brasil, **Associação Brasileira de Manutenção**, Documento Nacional, Rio de Janeiro: ABRAMAN, 2007.

AI, X.; MOYER, C. A. Rolling element bearing. In: BRUSHAN, B. **Modern Tribology handbook – vol. 2**. New York: CRC Press, p. 7.69-7.104, 2001.

AL-GARNI, A. Z.; JAMAL, A.; AHMAD, A. M.; AL-GARNI, A. M.; TOZAN, M. Neural network-based failure rate prediction for De Havilland Dash-8 tires, **Engineering Applications of Artificial Intelligence**, v. 19, p. 681-691, 2006.

AL-RAHEEM K. F.; ABDUL-KAREM, W. Rolling bearing fault diagnostics using artificial neural networks based on Laplace wavelet analysis, **International Journal of Engineering, Science and Technology**, v. 2, n. 6, p. 278-290, 2010.

ALBIDEWI, I. A. Wear particles surface identification using neural network, **International Journal of Computer Science and Network Security**, v.8, n.1, 2008.

ANDINA, D.; VEGA-CORONA, A.; SEIJAS, J. I; TORRES-GARCÍA, J. Neural networks historical review. **Computational Intelligence for Engineering and Manufacturing**, ANDINA, D., PHAM, D. T. eds., Dordrecht: Springer, 2007, 213 p.

ALMEIDA, F. R. V. A. **Análises estatísticas e reconhecimento de padrão aplicados em diagnósticos de defeitos em rolamentos através da análise de vibração**, 2007, 137f. Tese (Doutorado em Engenharia Mecânica) Instituto de Engenharia de Itajubá, Universidade Federal de Itajubá, Itajubá, 2007.

ASTM F1877-05. **ASTM 1877-05 Standard practice for characterization of particles**, American Society for Testing and Materials, 2006.

AUSTERLITZ, H. **Data Acquisition Techniques Using PCs**, 2. ed., San Diego: Academic Press, 2003, 416 p.

BADAOUI, M. E.; ANTONI, J.; GUILLET, F.; DANIÈRE, J. Use of the moving cepstrum integral to detect and localise tooth spalls in gears, **Mechanical Systems and Signal Processing**, 2001, v. 15, n. 5, p. 873-885, 2001.

BANNISTER, R. H. A review of rolling element bearing monitoring techniques. **Conference on Condition Monitoring of Machinery and Plant**, p. 11-24, 1985.

BARROS, A.; BÉRENGUER, C.; GRALL, A. Optimization of replacement times using imperfect monitoring information, **IEEE Transactions on Reliability**, v. 52, n. 4, p. 523-533, 2003.

BARTO, A. G.; SUTTON, R. S.; ANDERSON, C. W. Neuron like adaptive elements that can solve difficult learning control problems, **IEE Transactions on Systems, Man and Cybernetics - SMC-13**, p. 834-846, 1983.

BLOCH, H. P.; GEITNER, F. K. **Machinery component maintenance repair**, 3. ed., v. 3, Burlington: Elsevier, 2005, 641 p.

BONALDI, E. L.; OLIVEIRA, L. E. L.; SILVA, J. G. B. Análise e Identificação de Falhas em Motores de Indução Trifásicos através da Técnica de Análise da Assinatura Elétrica, **Anais do 23º Congresso Brasileiro de Manutenção**, Santos, 2008.

BHUSHAN, B. **Modern Tribology Handbook - Volume One**. 1. ed., Boca Raton: CRC Press, 2001, 1760 p.

CAMPBELL, J. D.; JARDINI, A. K. S. **Maintenance Excellence – Optimizing Equipment Life-Cycle Decisions**. New York: Marcel Dekker, Inc., 2001, 495 p.

CHEN, P. **Bearing condition monitoring and fault diagnosis**. Master of Science Thesis, Department of Mechanical and Manufacturing Engineering, University of Calgary, 2000.

CHEN, P.; TANIGUCHI, M.; TOYOTA, T.; HE, Z. Fault diagnosis method for

machinery in unsteady operating condition by instantaneous power spectrum and genetic programming, **Mechanical Systems and Signal Processing**, v. 19, p. 175-194, 2005.

CHENG, H. **Implementation strategies and tools for condition based maintenance at nuclear power plants**. Technical Report - IAEA-TECDOC-1551, International Atomic Energy Agency, 2007, 178 p.

CHENG, J.; YU, D.; YU, Y. A fault diagnosis approach for roller bearings based on EMD method and AR model, **Mechanical Systems and Signal Processing**, v. 20, n. 2, 2006.

CLARK, C. L. **LabVIEW - Digital Signal Processing and digital communications**, New York: McGraw-Hill, 2005, 205 p.

COWAN, R. S.; WINER, W. Rolling technologies for machinery diagnosis and prognosis. In: BRUSHAN, B. **Modern Tribology handbook – vol. 2**. New York: CRC Press, p. 7.69-7.104, 2001.

CRWU, Bearing Data Center - Seeded Fault Test Data. Disponível em: <http://www.eecs.case.edu/laboratory/bearing/download.htm>. Acesso em: 17/07/2008.

COURRECH, J.; ESHLEMAN, R. L. **Harris' shock and vibration handbook**, HARRIS, C. M. e PERSOL, A. G eds., 5 ed., New York: McGraw-Hill, 2002.

DATTA, A.; PATEL S.; MAVROIDIS C.; ANTONIADIS I.; KRISHNASAMY J.; HOSEK M. Fault diagnostics of industrial robots using support vector machines and discrete wavelet transforms, **Proceedings of ASME International Mechanical Engineering Congress and Exposition - IMECE2006**, Chicago, Illinois, USA, 2006.

DE CASTRO, L. N.; VON ZUBEN, F. J. An improving pruning technique with restart for the Kohonen Self-Organizing feature map, **Proceedings of International Joint Conference on Neural Networks**, p. 1916-1919, 1999.

DELAWARE. **Tribology**. Portal da Materials Tribology Laboratory da Universidade de Delaware. Disponível em: <<http://research.me.udel.edu/~dlburris/more.html>>. Acesso em: 22 de janeiro de 2011.

DELOUX, E.; CASTANIER, B.; BÉRENGUER, C. Predictive maintenance policy for a gradually deteriorating system subject to stress, **Reliability Engineering & System Safety**, v. 94, n. 2, p. 418-431, 2009.

DHILON, B. S. **Engineering maintenance: a modern approach**, Boca Raton: CRC Press, 2002, 244 p.

DHILLON, B. S. **Maintainability, maintenance, and reliability for engineers**, Boca Raton: CRC Press, 2006, 240 p.

DUTTON, A. G.; BLANCH, M. J.; VIONIS, P.; LEKOU D.; VAN DELFT, D. R. V.; JOOSSE, P. A.; ANASTASSOPOULOS, A.; KOUROUSSIS, D.; KOSSIVAS, T.; PHILIPPIDIS, T. P.; ASSIMAKOPOULOU, T. T.; FERNANDO; G.; DOYLE, C.; PROUST, A. Acoustic emission condition monitoring of wind turbine rotor blades: laboratory certification testing to large scale in-service deployment, **Proceedings of the 2001 European Wind Energy Conference**, 2001, Copenhagen, Denmark.

ENNS, R.; SI, J. Helicopter trimming and tracking control using direct neural dynamic programming, **IEEE Transactions on Neural Networks**, v. 14, n. 4, p. 929-939, 2003.

FAI, T. C. An Expert Fault Diagnosis System for Auto Wire Bond Machine, **Jurnal Teknologi**, v. 47A, p. 55-73, 2007.

FERNANDES, M. A. Como aumentar a disponibilidade das máquinas e reduzir custos de manutenção, **Máquinas e metais**, p. 316-329, 2003.

FOGEL, L. J.; OWENS, A. J.; WALSH, M. J. **Artificial Intelligence through simulated evolution**. New York: Wiley Publishing, 1966.

FRASER, A. M. **Hidden Markov models and dynamical systems**, Society for Industrial and Applied Mathematics: Philadelphia, 2008, 132 p.

FUGATE, M. L.; SOHN, H.; FARRAR, C.R. Vibration-based damage detection using statistical process control, **Mechanical Systems and Signal Processing**, v. 15, p.707-721, 2001.

FUJIMOTO, R. Y. **Diagnóstico automático de defeitos em rolamentos baseado em Lógica Fuzzy**, 2005, 158f. Dissertação (Mestrado em Engenharia Mecânica) Departamento de Engenharia de Mecânica, Universidade de São Paulo, São Paulo, 2005.

GEN, M.; CHENG, R. **Genetic algorithms and engineering design**, New York: John Wiley & Sons, 1997, 432 p.

GILABERT, E.; ARNAIZ, A. Intelligent automation systems for predictive maintenance: A case study. **Robotics and Computer Integrated Manufacturing**, v. 22, p. 543-549, 2006.

GÓES, A. G. A.; ALVARENGA, M. A. B.; MELO, P. F. F. NAROAS: a neural network-based advanced operator support system for the assessment of systems reliability. **Reliability Engineering & System Safety**, v. 87, n. 2, p. 149-161, 2005.

GOODE, K. B.; ROYLANCE, B. J.; MOORE, J. The development of a Predictive Model for Condition-Based Maintenance in a Steel Works Hot Strip Mill. **In: Proceedings of the JOAP International Condition Monitoring Conference**, Mobile, Alabama, p. 203-218, 1998.

GOODE, K. B.; ROYLANCE, B. J.; MOORE, J. Development of Model to Predict Condition Monitoring Interval Times, **Ironmaking and Steelmaking**, v. 27, p. 63-68, 2000.

GOODE, K. B.; MOORE, J.; ROYLANCE, B. J. Plant Machinery Working Life Prediction Method Utilizing Reliability and Condition-Monitoring Data, **Proceedings of the Institution of Mechanical Engineers Part E-Journal of Process Mechanical Engineering**, v. 214, p. 109-122, 2000.

GODDU, G.; LI, B.; CHOW, M. Y.; HUNG, J. C. Motor bearing fault diagnosis by a fundamental frequency amplitude based fuzzy decision system, **Proceedings of IECon '98**, Aachen, Germany, 1998.

GOH, K. M.; TJAHJONO, B.; BAINES, T.; SUBRAMANIAM, S. A Review of Research in Manufacturing Prognostics, **IEEE International Conference on Industrial Informatics**, Singapura, 2006.

GONÇALVES, V. D. **Desenvolvimento de um sistema de análise de imagem para quantificação do tamanho e distribuição de partículas de desgaste**. 2010. 135f. Tese (Doutorado em Engenharia Mecânica) – Faculdade de Engenharia de Guaratinguetá, Universidade Estadual Paulista - UNESP, 2010.

GONÇALVES, V. D.; ALMEIDA, L. F.; MATHIAS, M. H. Wear Particle Classifier Based on an Artificial Neural Network. In: **2nd European Conference on Tribology, ECOTRIB 2009**, PISA, v. 01. p. 263-268, 2009.

GUINGO, B. C.; RODRIGUES, R. J.; THOMÉ, A. C. G. Automatic identification for automotives vehicles plates. **3rd WSEAS - Conference on Neural Networks and Applications NNA'02**, Fuzzy Sets and Fuzzy Systems FSFS'02, Evolutionary Computation EC'02, Interlaken – Switzerland, 2002.

HAYES, M. H. **Statistical digital signal processing and modeling**. New York: John Wiley & Sons, Inc, 1996, 608 p.

HAYKIN, S. **Neural Networks: a comprehensive foundation**. New Jersey: Prentice Hall, 1999, 842 p.

HAMEED, Z.; HONG, Y. S.; CHO, Y. M.; AHN, S. H.; SONG, C. K. Condition monitoring and fault detection of wind turbines and related algorithms: A review, **Renewable and Sustainable Energy Reviews**, v. 13, p. 1-39, 2009.

HARIHARAN, V.; SRINIVASAN, P. S. S. New approach of classification of rolling element bearing fault using artificial neural network. **Journal of Mechanical Engineering**, v. 40, n. 2, p. 119-130, 2009.

HE, Q.; KONGA, F.; YAN, R. Subspace-based gearbox condition monitoring by kernel principal component analysis, **Mechanical Systems and Signal Processing**, v. 21, p. 1755–1772, 2007.

HEBB, D. O. **The organization of behavior**. New York: John Wiley and Sons, 1949.

HECHT-NIELSEN, R. Counterpropagation networks, **Applied Optics**, v. 26, p. 4979-4984, 1987.

HIGGINS, L. R.; MOBLEY, R. K. **Maintenance engineering handbook**, 6 ed., Nova Iorque: McGraw-Hill, 2002, 1297 p.

HOLLAND, J. **Adaptation in natural and artificial systems**, Ann Arbor: Univ. Michigan, 1975, 211 p.

HOWARD, I. **A review of rolling element bearing vibration - detection, diagnosis and prognosis**, Defense Science and Technology Organization, Australia, 1994.

HU, J.; ZHANG, L.; LIANG, W.; WANG, Z. Incipient mechanical fault detection based on multifractal and MTS methods, **Petroleum Science**, China University of Petroleum, v. 6, n. 2, p. 208-216, 2009.

IAEA, **Implementation strategies and tools for condition based maintenance at nuclear power plants**. IAEA-TECDOC-1551, Nuclear Power Engineering Section, International Atomic Energy Agency, Vienna, Austria, 2007.

JACK, L. B.; NANDI, A. K. Genetic algorithms for feature selection in machine condition monitoring with vibration signals, **IEE Proceedings in Vision, Image and Signal Processing**, v. 147, n. 3, p. 205-212, 2000.

JARDINE, A. K. S.; LIN, D.; BANJEVIC, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance, **Mechanical Systems and Signal Processing**, v. 20, p. 1483-1500, 2006.

KELLY, S. G. **Fundamental of mechanical vibrations**. Singapore: McGraw-Hill Science, 2000, 672 p.

KOBBACY, K. A. H; MURTHY, D. N. P. **Complex System: maintenance handbook**. London: Springer Verlag, 2008, 657 p.

KOHONEN, T. **Self-organizing and associative memory**, Berlim: Springer-Verlag, 1984.

KONSTANTIN-HANSEN, H. **Envelope analysis for diagnostics of local faults in rolling element bearings**, Application Note, Brüel&Kjaer, 2011. Disponível em: <<http://www.bksv.com/doc/bo0501.pdf>> Acesso em: 17 de janeiro de 2011.

KOZA, J. R. **Genetic programming: on the programming of computers by means of natural selection**. Cambridge: The MIT Press, 1992, 835 p.

KULLBACK, S.; LEIBLER, A. On information and sufficiency, **Annals of Mathematical Statistics**, v. 22, n. 1, p. 79-86, 1951.

KUMAR, M. S.; PRABHU, B. S. Rotating machinery predictive maintenance expert system, **International Journal of Rotating Machinery**, v. 6, p. 363-373, 2000.

KUO, S. M.; LEE, B. H. **Real time digital processing**. West Sussex: John Wiley and Sons, Ltd., 2001, 488 p.

LAGHARI, M. S. Recognition of texture types of wear particles, **Neural Computing and Applications**, v. 12, n. 1, p. 18-25, 2003.

LAGHARI, M. S.; MENON, Q. A.; KHUWAJA, G. A. Knowledge based wear particle analysis, **Transactions on Engineering, Computing and Technology**, v. 3, p. 112-116, 2004.

LEE, J.; ABUJAMRA, R.; JARDINE, A.K.S.; LIN, D.; BANJEVIC, D. An integrated platform for diagnostics, prognostics and maintenance optimization, In: **The IMS '2004 International Conference on Advances in Maintenance and in Modeling, Simulation and Intelligent Monitoring of Degradations**, Arles, France, 2004.

LEHMANN, E. L.; ROMANO, J. P. **Testing statistical hypotheses**. 3 ed., New York: Springer Verlag, 2005, 784 p.

LI, B.; CHOW, M. Y.; TIPSUWAN, Y.; HUNG, J. C. Neural-Network-Based motor rolling bearing fault diagnosis, **IEEE Transactions on Industrial Electronics**, v. 47, n. 5, 1060-1069, 2000.

LI, Z.; HE, Y.; CHU, F; HAN, J.; HAO, W. 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**, v. 291, p. 60-71, 2006.

LI, J. C.; LEE, H. Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics, **Mechanical Systems and Signal Processing**, v. 19, p.4, p. 836-846, 2005.

LI, Z; WU, Z.; HE, Y.; FULEI, C. Hidden Markov model-based fault diagnostics method in speed-up and speed-down process for rotating machinery, **Mechanical Systems and Signal Processing**, v. 19, p. 329-339, 2005.

LI, C. J.; WU, S. M. On-line detection of localized defects in bearings by pattern recognition analysis. Transactions of the ASME, **Journal of Engineering for Industry**, v. 111, p. 331-336, 1989.

LIANG, G. F.; LIN, J. T.; HWANG, S. L.; HUANG, F. H.; YENN. T. C.; HSU, C. C. Evaluation and Prediction of On-Line Maintenance Workload in Nuclear Power Plants. **Human Factors and Ergonomics in Manufacturing**, v. 19, n. 1, p. 64-77, 2009.

LIU, S. C.; LIU, S. Y. An Efficient Expert System for Machine Fault Diagnosis, **International Journal of Advanced Manufacturing Technology**, v. 21, p. 691-698, 2003.

LIU, Z.; YIN, X.; ZHANG, Z.; CHEN, D.; CHEN, W. Online rotor mixed fault diagnosis way based on spectrum analysis of instantaneous power in squirrel cage induction motors, **IEEE Transactions on Energy Conversion**, v. 19, 485–490, 2004.

LOU, X.; LOPARO, K.A. Bearing fault diagnosis based on wavelet transform and fuzzy inference, **Mechanical Systems and Signal Processing**, v. 18, p. 1077-1095, 2004.

LUBROSOFT, **Wear particle atlas**, version 2.0, Lubrosoft Pty Ltd, 1997.

LUGER, G. F. **Inteligência Artificial**: estruturas e estratégias para a resolução de problemas complexos. 4. ed., Porto Alegre: Editora Bookman, 2004, 774 p.

MA, J.; LI, C. J. Detection of localized defects in rolling element bearings via composite hypothesis test, **Mechanical Systems and Signal Processing**, v. 9, p. 63-75, 1995.

MAHALANOBIS, P. C. On the generalized distance in statistics, **Proceedings of the National Institute of Science of India**, v. 2, p. 49-55, 1936.

MAILLART, L. M.; POLLOCK, S. M. Cost-optimal condition-monitoring for predictive maintenance of 2-phase systems, **IEEE Transactions on Reliability**, v. 51, n. 3, p. 322-330, 2002.

MAN, K.F.; TANG, K.S. Genetic algorithms for control and signal processing, **International Conference on Industrial Electronics, Control and Instrumentation, IECON 97**, 1997.

MARÇAL, R. F. M.; SUSIN, A. A. Detectando falhas incipientes em máquinas rotativas, **Revista Gestão Industrial**, v. 1, n. 2, p. 228-236, 2005.

MARCORIN, W. R.; LIMA, C. R. C. Análise dos custos de manutenção e de não-manutenção de equipamentos produtivos. **Revista Ciência e Tecnologia**, v. 11, n. 22, p. 35-45, 2003.

MATHER, D. **CMMS: A Timesaving Implementation Process**. Boca Raton: CRC Press, 2003, 141 p.

MCCORMICK, A. C.; NANDI, A. K. Classification of rotating machine condition using artificial neural networks, **Mechanical Engineering Science**, v. 211, n. 6, p. 439-450, 1997.

MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 7, p.115-133, 1943.

MCFADDEN, P. D. Condition monitoring of rolling element bearing by vibration analysis. **Proceedings of Institution of Mechanical Engineers**, p. 49-54, 1990.

MCFADDEN, P. D.; SMITH, J. D. Model for the vibration produced by a single point in a rolling element bearing. **Journal of Sound and Vibration**, v. 96, n. 1, p. 69-82, 1984.

MECHEFSKE, C. K.; MATHEW, J. Fault detection and diagnosis in low speed rolling element bearing. Part II: The use of nearest neighbour classification, **Mechanical Systems and Signal Processing**, v. 6, p. 309-316, 1992.

MENDEL, J. M. Tutorial on higher-order statistics (Spectra) in Signal Processing and System Theory: Theoretical Results and Some Applications. **Proceedings of the IEEE**, v. 19, n. 3, 1991.

MENDEL, E.; MARIANO, L. Z.; DRAGO, I.; LOUREIRO, S.; RAUBER, T. W.; VAREJÃO, F. M.; BATISTA, R. J. Automatic bearing fault pattern recognition using vibration signal analysis. **Proceedings of the IEEE International Symposium on Industrial Electronics (ISIE)**, Cambridge, UK, 2008.

MENON, Q. A.; LAGHARI, M. S. Self organizing analysis platform for wear particle, **Transactions on Engineering, Computing and Technology**, v. 6, p. 122-125, 2005.

MENON, Q. A.; LAGHARI, M. S. Building relationship network for machine analysis from Wear Debris measurements, **International Journal of Computational Intelligence**, v. 3, n. 2, p. 99-103, 2007.

MHF. MHF manutenção preditiva: termografia. Portal da MHF. Disponível em: <<http://www.mhfpreditiva.com.br/conteudo/termografia/termografia.html>> Acesso em: 20 de janeiro de 2011.

MINSK, M. L.; PAPERT, S. A. **Perceptrons**, Cambridge: MIT Press, 1969.

MOBLEY, R. K. **An introduction to predictive maintenance**, 2 ed., Boston: Elsevier Science, 2002, 454 p.

MOBLEY, K. M. Vibration: its analysis and correction. In: MOBLEY, K. M.; HIGGINS, L. R.; WIKOFF, D. J. **Maintenance Engineering Handbook**. New York: McGraw-Hill Professional, p. 7.69-7.104, 2008a.

MOBLEY, K. M. Predictive maintenance. In: MOBLEY, K. M.; HIGGINS, L. R.; WIKOFF, D. J. **Maintenance Engineering Handbook**. New York: McGraw-Hill Professional, p. 2.19-2.34, 2008b.

MOBLEY, R. K. **Vibrations fundamentals**, Boston: Butterworth-Heinemann, 1999, 295 p.

MORGAN, I.; LIU, H.; TURNBULL, G.; BROWN, D. Predictive Unsupervised Organisation in Marine Engine Fault Detection, **IEEE World Congress on Computational Intelligence**, IEEE International Joint Conference on Neural Networks, IJCNN 2008, Hong Kong, p. 249-256, 2008.

MORROW, L. C. **Maintenance Engineering Handbook**. New York: McGraw-Hill, 1957.

MOUBRAY, F. **Reliability Centered Maintenance**. 4. ed., Oxford: Butterworth-Heinemann, 1997, 448 p.

NANDI, A. K. **Blind estimation using high-orders statistics**. Boston: Kluwer Academic Publishers, 1999.

NANDI, S.; TOLİYAT, H. A. Condition Monitoring and Fault Diagnosis of Electrical Machines – A Review. In: **Proceedings 34th Annual Meeting of the IEEE Industry Applications**, 1999, p. 197-204.

NBR5462. **NBR 5462: confiabilidade e manutenibilidade**. Associação Brasileira de Normas Técnicas - ABNT, 1994.

NEALE, M. J. **The Tribology handbook**. 2. ed., London: Newnes-Butterworths, 1995, 640 p.

NGUYEN, D.; WIDROW, B. Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights. **Proceedings of the International Joint Conference on Neural Networks**, v. 3, p. 21-26, 1990.

NIKIAS, C. L.; MENDEL, J. M. Signal processing with higher order spectra. **IEEE Signal Processing**, v. 10, n. 4, p. 10-37, 1993.

NILSSON, N. J. **Learning machines: foundations of trainable pattern-classifying systems**, New York: McGraw-Hill, 1965.

NIU, X.; ZHU, L.; DING, H. New statistical moments for the detection of defects in rolling element bearings, **International Journal of Advanced Manufacturing Technology**, v. 26, p. 1268–1274, 2005.

NYBERG, M. *A general framework for fault diagnosis based on statistical hypothesis testing*, in: **Twelfth International Workshop on Principles of Diagnosis (DX 2001)**, Via Lattea, Italian Alps, p. 135–142, 2001.

OAKLAND, J. S. **Statistical process control**. 5. ed., Oxford: Butterworth-Heinemann, 2003.

OECD. Organisation for Economic Co-operation and Development. Página Oficial. Disponível em: <<http://www.oecd.org>>. Acesso em: 31 de outubro de 2010.

OLIVEIRA JUNIOR, H. A. **Inteligência computacional aplicada à administração, economia e engenharia em Matlab**, São Paulo: Thomson, 2007.

PAN, M. C.; VAN BRUSSEL, P. H. Machine condition monitoring using signal classification techniques, **Journal of Vibration and Control**, v. 9, p. 1103-1120, 2003.

PAPOULIS, A. **Probability, random variables and stochastic processes**. New York: McGrawHill Inc., 1991.

PELIZZARI, E.; MARTINS, C. O. D.; MENEZES, A. F.; REGULY, A. Aplicações da termografia como ferramenta de manutenção preditiva em conectores elétricos. In: **17º CBECIMat - Congresso Brasileiro de Engenharia e Ciência dos Materiais**, Foz do Iguaçu, p. 6315-6325, 2006.

PENG, Z. An Integrated Intelligence System for Wear Debris Analysis, **Wear**, v. 252,

p. 730-743, 2002.

PHAN, D. T.; PHAN, P. T. N. Computational Intelligence for manufacturing. **Computational Intelligence in Manufacturing Handbook**, Jun Wang and Andrew Kusiak eds., CRC Press, 2001.

PINTO, A. K.; XAVIER, J. N. **Manutenção: função estratégica**. Rio de Janeiro: Qualitymark, 2001, 266 p.

PORTARI, M. V. **Diagnóstico de defeitos em equipamentos utilizando métodos estatísticos de reconhecimento de padrões**. 1997. 101 f. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Estadual de Campinas, Campinas, 1997.

PURUSHOTHAMA, V.; NARAYANANA, S.; PRASAD, S. A. N. Multi-fault diagnosis of rolling bearing elements using wavelet analysis and hidden Markov model based fault recognition, **NDT&E International**, v. 38, p. 654-664, 2005, 370 p.

RAFIEE, J.; ARVANIA, F.; HARIFIB, A.; SADEGHI, M. H. Intelligent condition monitoring of a gearbox using artificial neural network, **Mechanical Systems and Signal Processing**, v. 21, p. 1746-1754, 2007.

RAMÍREZ, M. C. V.; WEIGANG, L.; FERREIRA, N. J. Aplicação de Redes Neurais Artificiais e Transformada de Ondeletas para Estimativas de Precipitação usando imagens do satélite GOES-8: Resultados Preliminares, **Proceedings of the IV Brazilian Conference on Neural Networks**, p. 252-256, 1999.

RANDALL, R. B. **Vibration-based condition monitoring**, West Sussex: John Wiley & Sons Ltd, 2011, 289 p.

RAYNOR, W. J. **The international dictionary of artificial intelligence**, New York: The Glenlake Publishing Company, 1999, 318 p.

RECHENBERG, I. **Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution**. Stuttgart: Frommann-Holzboog, 1973.

REIS, D.; PATI, N. Applications of artificial intelligence to condition-based

maintenance. **Revista de Administração de Empresas**, v. 40, n. 2, p. 102-107, 2000.

RICH, E.; KNIGHT, K. **Inteligência Artificial**. 2. ed., São Paulo: Makron Books, 1994, 722 p.

ROSENBLATT, F. The Perceptron: a Probabilistic Model for Information Storage and Organization in the Brain. **Psychological Review**, v. 65, n. 6, p. 386-408, 1958.

ROYLANCE, B. J.; ALBIDEWI, I. A.; LUXMORE, A. R.; PRICE, A. L. The Development of a Computer-Aided Systematic Particle Analysis Procedure – CASPA, **Journal of the Society of Tribologists and Lubrication Engineers**, v. 48, n. 12, p. 940-946, 1992.

RUD, O. P. **Data Mining Cookbook: Modeling Data for Marketing, Risk, and Customer Relationship Management**. New York: John Wiley & Sons, Inc., 2001, 367 p.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. **In Parallel Distributed Processing: Explorations in the Microstructure of Cognition**, v. 1, Cambridge: MIT Press, 1986a.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, p. 533-536, 1986b.

RUSSELL, S.; NORVIG, P. **Inteligência Artificial**. Rio de Janeiro: Editora Campus, 2004, 1056 p.

SÁ, J. P. M. de. **Pattern Recognition Concepts, Methods and Applications**. New York: Springer Verlag, 2001, 318 p.

SAMANTA, B.; AL-BALUSHI, K. R. Artificial Neural Network Based Fault Diagnostics of Rolling Element Bearings Using Time-Domain Features, **Mechanical Systems and Signal Processing**, v. 17, n. 2, p. 317-328, 2003.

SAMANTA, B. Artificial neural networks and genetic algorithms for gear fault

detection, **Mechanical Systems and Signal Processing**, v. 18, p. 1273-1282, 2004.

SANTOS, A. V.; DIMURO, G. P.; BARBOZA, L. V.; COSTA, A. C. R.; REISER, R. H. S. Probabilidades Intervalares em Modelos Ocultos de Markov, **Tendências em Matemática Aplicada Computacional**, v. 7, n. 2, p. 361-370, 2006.

SCHEFFER, C; GIRDHAR, P. *Practical machinery vibration analysis and predictive maintenance*, Boston: Elsevier, 2004, 255 p.

SCHOEN, R. R.; HABETLER, T. G. Effects of time-varying loads on rotor fault detection in induction machines, **IEEE Transactions on Industry Applications**, v. 31, p. 900–906, 1995.

SCOTT, G. M.; SHAVLIK, J. W; RAY, W. H. Refining PID controllers using neural networks, **Neural Computation**, v. 4, p. 746-757, 1992.

SEASONICS. Página Oficial da Empresa. Disponível em: <<http://www.seasonics.co.uk>> Acesso: 06 de novembro de 2010.

SHIROISHI, J.; LI, Y.; LIANG, S.; KURFESS, T.; DANYLUK, S. Bearing condition diagnostics via vibration and acoustic emission measurements. **Mechanical Systems and Signal Processing**, v. 11, n. 5, p. 693-705, 1997.

SMITH, S. W. **The Scientist and Engineer's Guide to Digital Signal Processing**. 2. ed., San Diego: California Technical Publishing, 1999.

SPENCER, F. W. **Visual Inspection Research Project Report on Benchmark Inspections**. FAA Aging Aircraft NDI Validation Center Sandia National Laboratories, U.S. Department of Transportation, Federal Aviation Administration, Office of Aviation Research, 1996.

SOMMERVILLE, I. **Software Engineering**, 8 ed., New York: Addison Wesley, 2006, 864 p.

SREEJITH, B.; VERMA, A. K.; SRIVIDYA, A. Fault diagnosis of rolling element bearing using time-domain features and neural networks. **IEEE Region 10**

Colloquium and the Third ICIIS, Kharagpur, India, 2008.

STACHOWIAK, G. W.; BATCHELOR, A. W. **Engineering Tribology**. 2. ed., Boston: Butterworth Heinemann, 2001, 750 p.

STASZEWSKI, W. J.; WORDEN, K.; TOMLINSON, G. R. *Time–frequency analysis in gearbox Fault detection using the Wigner–Ville Distribution and pattern recognition*. **Mechanical Systems and Signal Processing**, v. 11, n. 5, p. 673-692, 1997.

TAKEYASU, K.; HIGUCHI, Y. Analysis of the behavior of kurtosis by simplified model and its application to machine diagnosis, **Proceedings of the Fifth Asia Pacific Industrial Engineering and Management Systems Conference**, 2004.

TAKEYASU, K.; KANEDA, S. Simplified machine diagnosis techniques by impact vibration deterioration factor of autocorrelation function type. **Proceedings of the Fifth Asia Pacific Industrial Engineering and Management Systems Conference**, 2004.

TAX, D., YPMA, A., & DUIN, R. Support vector data description applied to machine vibration analysis. In: BOASSEN, M; KAANDORP, J.; TONINO, J. (eds.), **Proceedings of the Fifth Annual Conference of the ASCI**, p. 398-405, 1999.

TAYLOR, J. I. **The Vibration Analysis Handbook**. Florida: Vibration Consultants, 1994.

TIAN, Z.; WONG, L.; SAFAEI, N. A Neural Network Approach for Remaining Useful Life Prediction Utilizing Both Failure and Suspension Histories, **Mechanical Systems and Signal Processing**, 2010.

UNAL, A. Feature Article, Intelligent Diagnostics of Ball Bearings. **The shock and vibration digest**, p. 9-12, 1994.

VAPNIK, V. **The Nature of Statistical Learning Theory**. New York: Springer Verlag, 1995.

VENAYAGAMOORTHY, G. K.; MOOSASAR, V.; SANDRASEGARAN, K. Voice recognition using neural networks, **Proceedings of IEEE South African Symposium on Communications and Signal Processing** - COMSIG 98, p. 29-32, 1998.

WANG, X. **Simulation Models for Rolling Bearing Vibration Generation and Faults Detection Via Neural Networks**. Thesis (Doctor of Philosophy in Engineering Science) Department of Engineering Science, Oxford University, Oxford, 1996.

WANG, W. Modelling Condition Monitoring Intervals: a hybrid of simulation and analytical approaches, **Journal of the Operational Research Society**, v. 54, p. 273-282, 2003.

WANG, G.; LUO, Z.; QIN, X.; LENG, Y.; WANG, T. Fault identification and classification of rolling element bearing based on time-varying autoregressive spectrum. **Mechanical Systems and Signal Processing**, v. 22, n. 4, p. 934-947, 2008.

WEBB, A. **Statistical Pattern Recognition**. 2. ed., West Sussex: John Wiley & Sons, Inc., 2002, 495 p.

WIDROW, B.; HOFF, M. E. Adaptive switching circuits, **IRE WESCON Convention Record**, p. 96-104, 1960.

XU, K.; LUXMOORE, A. R. An Integrated System for Automatic Wear Particle Analysis, **Wear**, v. 208, p. 184-193, 1997.

XU, K.; LUXMOORE, A. R.; DERAVID, F. Comparison of Shape Features for the Classification of Wear Particles. **Engineering Application Artificial Intelligence**, v. 10, n. 5, p. 485-493, 1997.

XU, K. LUXMOORE, A. R.; JONES, L. M.; F., DERAVID Integration of neural networks and expert systems for microscopic wear particle analysis, **Knowledge-Based Systems**, v. 11, p. 213-227, 1998.

XU, R.; WUNSCH, D. C. **Clustering**. Hoboken: John Wiley & Sons, Inc., 2009.

XUE, F.; BONISSONE, P.; VARMA, A.; YAN, W.; EKLUND, N.; GOEBEL, K. An

Instance-Based Method for Remaining Useful Life Estimation for Aircraft Engines, **Journal of Failure Analysis and Prevention**, v. 8, p. 199-206, 2008.

YUAN, S.; CHU, F. Fault diagnosis based on support vector machines with parameter optimisation by artificial immunisation algorithm, **Mechanical Systems and Signal Processing**, v. 21, p. 1318-1330, 2007.

ZENG, Y.; JIANG, WEI; ZHU, C.; LIU, J.; TENG, W.; ZHANG, Y. Prediction of Equipment Maintenance Using Optimized Support Vector Machine. **Lecture Notes in Computer Science**, Computational Intelligence, v. 4.114, p.570-579, 2006.

ZHANG, X. L.; CHEN, X. F.; HE, Z. J. Fault diagnosis based on support vector machines with parameters optimization by ant colony algorithm. Proceedings of the Institution of Mechanical Engineers - Part C, Journal of Mechanical Engineering Science, v. 223, p. 1-13, 2009.

ZHANG, L.; JACK, L. B.; NANDI, A. K. Fault detection using genetic programming, **Mechanical Systems and Signal Processing**, v. 19, p. 271–289, 2005.

ZI, E.; DI MAIO, F. A data-driven fuzzy approach for predicting the remaining useful life in dynamic failure scenarios of a nuclear system, **Reliability Engineering and System Safety**, v. 95, p. 49–57, 2010.

APÊNDICE A – RELAÇÃO COMPLETA DO EXPERIMENTO DATA-CWRU

A seguir são apresentadas as Tabelas 67 à 70 referentes às configurações para os arquivos gerados no processo de aquisição de dados considerando rolamento se defeito, defeitos referentes ao rolamento localizado na extremidade do acionamento com taxa de aquisição igual a 12.000 rpm, defeitos referentes ao rolamento localizado rolamento na extremidade do acionamento com taxa de aquisição igual a 48.000 rpm, defeitos referentes ao rolamento localizado rolamento na extremidade do ventilador.

Tabela 67 – Rolamento sem defeito

Nome do arquivo	Velocidade do motor (rpm)	Carga do Motor (HP)
Normal_0	1.797	0
Normal_1	1.772	1
Normal_2	1.750	2
Normal_3	1.730	3

Tabela 68 – Rolamento localizado na extremidade do acionamento (taxa de aquisição=12.000 rpm)

Diâmetro da Falha (polegadas)	Velocidade do motor (rpm)	Carga do Motor (HP)	Nome do Arquivo				
			Pista Interna	Esfera	Pista Externa (centralizado)	Pista Externa (ortogonal)	Pista Externa (oposto)
0,007	1.797	0	IR007_0	B007_0	OR007@6_0	OR007@3_0	OR007@12_0
	1.772	1	IR007_1	B007_1	OR007@6_1	OR007@3_1	OR007@12_1
	1.750	2	IR007_2	B007_2	OR007@6_2	OR007@3_2	OR007@12_2
	1.730	3	IR007_3	B007_3	OR007@6_3	OR007@3_3	OR007@12_3
0,014	1.797	0	IR014_0	B014_0	OR014@6_0	---	---
	1.772	1	IR014_1	B014_1	OR014@6_1	---	---
	1.750	2	IR014_2	B014_2	OR014@6_2	---	---
	1.730	3	IR014_3	B014_3	OR014@6_3	---	---
0,021	1.797	0	IR021_0	B021_0	OR021@6_0	OR021@3_0	OR021@12_0
	1.772	1	IR021_1	B021_1	OR021@6_1	OR021@3_1	OR021@12_1
	1.750	2	IR021_2	B021_2	OR021@6_2	OR021@3_2	OR021@12_2
	1.730	3	IR021_3	B021_3	OR021@6_3	OR021@3_3	OR021@12_3
0,028	1.797	0	IR028_0	B028_0	OR028@6_0	---	---
	1.772	1	IR028_1	B028_1	OR028@6_1	---	---
	1.750	2	IR028_2	B028_2	OR028@6_2	---	---
	1.730	3	IR028_3	B028_3	OR028@6_3	---	---

Tabela 69 – Rolamento localizado na extremidade do acionamento (taxa de aquisição=48.000 rpm)

Diâmetro da Falha (polegadas)	Velocidade do motor (rpm)	Carga do Motor (HP)	Nome do Arquivo				
			Pista Interna	Esfera	Pista Externa (centralizado)	Pista Externa (ortogonal)	Pista Externa (oposto)
0,007	1.797	0	IR007_0	B007_0	OR007@6_0	OR007@3_0	OR007@12_0
	1.772	1	IR007_1	B007_1	OR007@6_1	OR007@3_1	OR007@12_1
	1.750	2	IR007_2	B007_2	OR007@6_2	OR007@3_2	OR007@12_2
	1.730	3	IR007_3	B007_3	OR007@6_3	OR007@3_3	OR007@12_3
0,014	1.797	0	IR014_0	B014_0	OR014@6_0	---	---
	1.772	1	IR014_1	B014_1	OR014@6_1	---	---
	1.750	2	IR014_2	B014_2	OR014@6_2	---	---
	1.730	3	IR014_3	B014_3	OR014@6_3	---	---
0,021	1.797	0	IR021_0	B021_0	OR021@6_0	OR021@3_0	OR021@12_0
	1.772	1	IR021_1	B021_1	OR021@6_1	OR021@3_1	OR021@12_1
	1.750	2	IR021_2	B021_2	OR021@6_2	OR021@3_2	OR021@12_2
	1.730	3	IR021_3	B021_3	OR021@6_3	OR021@3_3	OR021@12_3

Tabela 70 – Rolamento localizado na extremidade do ventilador

Diâmetro da Falha (polegadas)	Velocidade do motor (rpm)	Carga do Motor (HP)	Nome do Arquivo				
			Pista Interna	Esfera	Pista Externa (centralizado)	Pista Externa (ortogonal)	Pista Externa (oposto)
0,007	1.797	0	IR007_0	B007_0	OR007@6_0	OR007@3_0	OR007@12_0
	1.772	1	IR007_1	B007_1	OR007@6_1	OR007@3_1	OR007@12_1
	1.750	2	IR007_2	B007_2	OR007@6_2	OR007@3_2	OR007@12_2
	1.730	3	IR007_3	B007_3	OR007@6_3	OR007@3_3	OR007@12_3
0,014	1.797	0	IR014_0	B014_0	OR014@6_0	---	---
	1.772	1	IR014_1	B014_1	---	---	---
	1.750	2	IR014_2	B014_2	---	---	---
	1.730	3	IR014_3	B014_3	---	---	---
0,021	1.797	0	IR021_0	B021_0	OR021@6_0	---	---
	1.772	1	IR021_1	B021_1	---	OR021@3_1	---
	1.750	2	IR021_2	B021_2	---	OR021@3_2	---
	1.730	3	IR021_3	B021_3	---	OR021@3_3	---

APÊNDICE B – CARACTERÍSTICAS MORFOLÓGICAS DA BASE DE DADOS DATA-FEG2

Tabela 71 – Características morfológicas das partículas contidas na base de dados DATA-FEG2

Tipo da Part.	Área	Perímetro	Largura	Altura	Eixo Primário	Diâmetro Secundário	Circul.	Diâmetro de Feret	Along.	Razão de Aspecto
SW	16.411,37	555,57	180,36	126,38	178,91	116,80	0,67	184,72	4,761069	1,427125
SW	14.430,56	586,63	180,36	122,70	181,86	101,03	0,53	184,72	3,499814	1,469927
SW	17.799,02	614,74	180,36	153,37	175,45	129,17	0,59	184,72	6,582109	1,175980
SW	14.413,62	553,75	166,87	126,38	161,36	113,74	0,59	174,24	5,776984	1,320383
SW	17.742,94	569,65	180,36	132,51	179,62	125,77	0,69	184,72	5,671123	1,361105
SW	12.210,39	505,66	165,64	116,56	173,44	89,64	0,60	173,41	3,139379	1,421071
SW	8.824,58	677,42	131,35	155,67	152,02	73,91	0,24	167,3	2,892459	0,843772
SW	8.325,54	617,95	131,35	147,02	145,57	72,82	0,27	166,94	3,001924	0,893416
SW	14.943,55	595,64	180,36	126,38	179,53	105,98	0,53	184,72	3,881849	1,427125
SW	16.546,86	653,62	194,47	126,38	204,64	102,95	0,49	212,1	3,024781	1,538772
RW	1.802,90	235,38	40,82	70,99	60,19	38,14	0,41	71,62	4,459410	0,575011
RW	1.769,33	234,28	40,63	70,65	59,62	37,79	0,41	71,28	4,462208	0,575088
RW	1.780,37	248,22	41,57	72,29	61,27	37,00	0,36	72,93	4,049032	0,575045
RW	1.726,67	256,74	41,57	72,29	61,12	35,97	0,33	72,93	3,860437	0,575045
RW	1.544,29	265,16	40,59	70,59	59,78	32,89	0,28	71,21	3,446263	0,575011
RW	1.763,67	263,26	48,24	70,59	56,46	39,77	0,32	71,21	5,765728	0,683383
RW	2.109,69	273,13	58,24	70,59	55,86	48,09	0,36	71,21	13,378380	0,825046
RW	2.243,60	266,78	58,24	70,59	59,30	48,17	0,40	71,21	9,655885	0,825046
RW	2.405,88	269,42	58,24	70,59	61,30	49,97	0,42	71,21	9,820830	0,825046
RW	2.573,36	258,83	58,24	75,88	65,91	49,71	0,48	76,39	7,137037	0,767528
CW	1.436,57	385,25	108,28	83,43	60,56	30,20	0,12	113,57	2,989460	1,297854
CW	1.408,21	469,78	120,12	98,82	55,24	32,46	0,08	123,7	3,849868	1,215543
CW	1.333,99	431,45	108,28	100,59	55,08	30,84	0,09	120,36	3,544554	1,076449
CW	766,43	347,65	91,12	84,02	46,57	20,95	0,08	105,93	2,635441	1,084504
CW	1.533,91	491,82	120,71	108,28	56,21	34,74	0,08	128,62	4,236143	1,114795
CW	1.093,10	376,65	90,53	100,00	56,43	24,66	0,10	122,71	2,552408	0,905300
CW	981,41	401,65	117,75	50,89	56,79	22,00	0,08	118,24	2,264731	2,313814
CW	965,65	406,38	97,63	99,41	51,01	24,10	0,07	118,49	2,791156	0,982094
CW	1.325,58	554,81	129,59	95,27	60,74	27,79	0,05	150,86	2,686798	1,360239
CW	1.206,54	531,65	118,34	100,00	48,24	31,85	0,05	124,52	4,886516	1,183400
FW	13.855,89	594,90	162,57	140,35	154,43	114,24	0,49	172,38	6,684996	1,158318
FW	14.397,23	1.085,33	164,71	142,35	157,01	116,75	0,15	175,98	6,799801	1,157078
FW	14.055,26	544,52	171,93	129,24	160,56	111,46	0,60	179,13	5,540122	1,330316
FW	14.616,46	590,90	170,76	140,35	156,50	118,91	0,53	173,98	7,326683	1,216673
FW	14.797,72	586,42	162,57	139,77	152,82	123,29	0,54	172,38	9,350152	1,163125
FW	12.907,90	580,60	160,23	131,58	145,66	112,83	0,48	162,67	7,873591	1,217738
FW	11.928,46	590,94	160,23	140,35	135,48	112,10	0,43	166,76	10,589390	1,141646
FW	12.203,76	608,24	168,42	140,35	137,65	112,88	0,41	172,66	10,114250	1,200000
FW	15.225,20	632,71	162,57	142,11	153,13	126,60	0,48	172,38	10,543910	1,143973
FW	12.284,78	520,36	142,94	133,53	134,55	116,25	0,57	152,95	13,710000	1,070000