



**UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECATRÔNICA**

JOSÉ ROBERTO DA SILVA PACHECO

**RECONHECIMENTO DE PADRÕES DE VIBRAÇÃO EM MÁQUINAS
ROTATIVAS UTILIZANDO REDE NEURAL ARTIFICIAL.**

Salvador
2007

JOSÉ ROBERTO DA SILVA PACHECO

**RECONHECIMENTO DE PADRÕES DE VIBRAÇÃO EM MÁQUINAS
ROTATIVAS UTILIZANDO REDE NEURAL ARTIFICIAL**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Mecatrônica, Escola Politécnica, Universidade Federal da Bahia, como requisito parcial para obtenção do grau de Mestre em Engenharia Mecatrônica.

Orientador: Prof. Dr. Leizer
Schnitman

Salvador
2007

FICHA CATALOGRAFICA
Elaboração: Biblioteca Central da UNEB
Bibliotecária: Maria Conceição da Gama Santos
CRB/5- 310

Pacheco, José Roberto da Silva

Reconhecimento de padrões de vibração em máquinas rotativas utilizando rede neural artificial / José Roberto da Silva Pacheco. – Salvador: s.n., 2007.

101f.

Dissertação (Mestrado) – Universidade Federal da Bahia, Escola Politécnica, 2007.

Orientador: Prof. Dr. Leizer Schnitman.

Inclui referências e apêndice.

1. Redes neurais (computação) 2.Reconhecimento de padrões. 3. Vibração. I. Schnitman, Leizer. II. Universidade Federal da Bahia. Escola Politécnica.

CDD: 006. 3

TERMO DE APROVAÇÃO

JOSÉ ROBERTO DA SILVA PACHECO

RECONHECIMENTO DE PADRÕES DE VIBRAÇÃO EM MÁQUINAS ROTATIVAS UTILIZANDO REDE NEURAL ARTIFICIAL

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre em Mecatrônica, Universidade Federal da Bahia – UFBA, pela seguinte banca examinadora:

Leizer Schnitman – Orientador _____
Doutor em Engenharia Eletrônica e Computação, Instituto Tecnológico de Aeronáutica (ITA)
Universidade Federal da Bahia (UFBA)

Augusto César Pinto Loureiro da Costa _____
Doutor em Engenharia Elétrica, Universidade Federal de Santa Catarina (UFSC)
Universidade Federal da Bahia (UFBA)

Angelo Amâncio Duarte _____
Doutor em Informática, Universidad Autonoma de Barcelona
Universidade Católica do Salvador

*A toda minha família, em especial
aos meus pais, José e Maria
Angélica, aos irmãos Cristina e
Rogério, a minha esposa, Rita e a
minha filha Marina.*

AGRADECIMENTOS

Aos meus pais, pela educação de qualidade que me proporcionaram e orientação durante toda a minha vida.

À minha esposa e filha, pelo amor e carinho ao longo de todos esses anos e pela compreensão nos momentos em que não pude dar toda a atenção que elas merecem.

Ao meu orientador, Prof. Dr. Leizer Schnitman, pela orientação paciente e competente durante todo o processo de definição, elaboração e finalização deste trabalho.

Ao meu colega e amigo Emerson Sanches, cujo incentivo, apoio nas horas difíceis e ajuda técnica foram fundamentais para a realização desta pesquisa.

Aos colegas do mestrado, em especial Hugo Campero, pelo companheirismo e ajuda durante a fase dos créditos.

Aos professores do mestrado, em especial aos Profs. Herman Lepikson e Armando Ribeiro.

Aos funcionários do PPGM, especialmente Lúcia Lago, pela atenção cordial que sempre dão aos alunos.

Ao Eng^o Urbano Campello, pelo apoio e incentivo a participar do processo seletivo e aulas do Mestrado.

À empresa Tecvib, particularmente aos Eng^{os}. Charles Matos e Marcelo Euclides Souza, pelo apoio e fornecimento dos dados para esta pesquisa.

RESUMO

Esta dissertação tem como objetivo principal o desenvolvimento de uma metodologia de reconhecimento de padrões de vibração em máquinas rotativas utilizando redes neurais artificiais. A proposta é reproduzir o diagnóstico dado por especialistas em vibração ao analisar um espectro de frequência gerado a partir de dados de vibração coletado por sensores instalados em diversos pontos de uma máquina rotativa. Juntamente com a metodologia foi desenvolvido um algoritmo em programa Matlab, software amplamente utilizado e conhecido nos meios acadêmicos. De modo diferente do que é encontrado em sistemas industriais comercializados por empresas especializadas, o código do programa é aberto e com isto pode ser compreendido, aperfeiçoado ou ampliado por outros pesquisadores, especialistas em vibração ou engenheiros de manutenção. Pode também ser ajustado a condições próprias de cada instalação ou características de operação de grupo de máquinas a ser analisado. Os dados de vibração foram obtidos de uma empresa especializada que atua no Pólo Petroquímico de Camaçari. Com o uso desta metodologia, o pesquisador ou profissional da área de manutenção pode, a partir de dados gerados por coletores de dados de vibração, aplicar o método para desenvolver, por exemplo, um programa de manutenção preditiva para um grupo de máquinas. Devido ao foco do trabalho ser de caráter aplicativo, é evitado o uso de demonstrações matemáticas, focando em utilização de ferramentas já dominadas como a Análise de Fourier e algoritmos para redes neurais, amplamente disponíveis na literatura. Uma das contribuições deste trabalho é mostrar que um sistema de reconhecimento de padrões de vibração pode ser desenvolvido facilmente a partir das ferramentas citadas, com baixo custo e sem necessidade de um modelo matemático específico para a máquina a ser analisada. Uma outra contribuição é mostrar mais um estudo de caso de aplicações de redes neurais em manutenção preditiva de máquinas. Os fundamentos para o desenvolvimento de um software aberto para monitoração e diagnóstico de vibração foram definidos. Restringe-se o âmbito da pesquisa a problemas de vibração causados por desbalanceamento do rotor ou desalinhamento do eixo em máquinas rotativas, problemas que são considerados bastante comuns em um ambiente industrial.

Palavras-chave: Vibração; Máquinas rotativas; Redes neurais artificiais; Séries de Fourier; Espectro em frequência; Reconhecimento de padrões.

ABSTRACT

The main goal of this dissertation is the development of a neural network pattern recognizing methodology for the vibration of rotating machines. It proposes to reproduce the diagnosis of rotating machines vibration problems commonly performed by vibration specialists using spectrum analysis. Such system has been developed as an algorithm in Matlab which is a widely used software program in academic environments. Matlab is an open source code application which enables researchers or maintenance technicians to understand it or adjust it to specific conditions of a machine in an industrial plant. The vibration data used is supplied by a vibration company that works mainly in the Petrochemical complex in Camaçari, Bahia. By using this methodology, it is possible that a researcher or a technician can develop a vibration maintenance program for a machine group. As this work is intended to be a useful tool in the work environment, it avoids abstract mathematical demonstrations and focuses on using well-known computational tools such as Fourier Analysis and Artificial Neural Network algorithms. One of the contributions here is the demonstration that it is feasible to develop a vibrational pattern recognizing system by using free and available techniques and tools, without the need of a mathematical model of the specific machine to be monitored. Another contribution is in presentation of a case study of Neural Network application in a machine's predictive maintenance. The basis for an open computational algorithm development for vibrational analysis has already been established. The scope of this research has been constrained to vibrations caused by unbalance and axis misalignment in rotating machines which are one of the most common causes of vibration in the industry.

Key-words: vibration; rotating machines; Artificial Neural Networks ; Fourier series; frequency spectrum; pattern recognition;

LISTA DE FIGURAS

Figura 2. 1 - Função periódica	17
Figura 2. 2 - Representação de um movimento harmônico simples.....	18
Figura 2. 3 - Representação de um movimento composto.....	20
Figura 2. 4 – Representações no domínio tempo e freqüência.....	23
Figura 2. 5 - Sinal amostrado no domínio do tempo	28
Figura 2. 6 - Sinal periódico composto	33
Figura 2. 7 - Sinal transformado pela FFT	34
Figura 2. 8 - Sinal após escalonamento.....	35
Figura 3. 1 - Neurônio Artificial.....	39
Figura 3. 2 - Função de ativação logsig	40
Figura 3. 3 - Função de ativação tansig	41
Figura 3. 4 - Rede neural de uma camada.....	42
Figura 3. 5 - Rede neural multicamada	44
Figura 3. 6 - Sistema de diagnóstico e rede neural artificial	47
Figura 3. 7 - Classificação do conjunto de treinamento.....	49
Figura 3. 8 - Classificação do conjunto de teste	50
Figura 4. 1 - Passos para o reconhecimento de voz.....	55
Figura 5. 1 - Registro de vibração em uma máquina rotativa	57
Figura 5. 2 - Espectro em freqüência	58
Figura 5. 3 - Espectro em freqüência típico de desbalanço.....	65
Figura 5. 4 - Espectro em freqüência típico de desalinhamento.....	65
Figura 6. 1 - Espectro e sinal de vibração	68
Figura 6. 2 - Sensor de vibração	69
Figura 6. 3 - Coletor de dados	69
Figura 6. 4 - Exemplo de registro utilizado.....	70
Figura 6. 5 - Espectro gerado pelo Matlab	72

Figura 6. 6 - Espectro gerado pelo software comercial	72
Figura 6. 7 - Amplitudes até o 3º harmônico	74
Figura 6. 8 - Espectro e sinal processados pelo software RBM	76
Figura 6. 9 - Espectro e sinal no tempo processados pelo MATLAB	76
Figura 6. 10 - Algoritmo p/ geração das matrizes de entrada e saída para o treinamento	79
Figura 6. 11 - Algoritmo p/ extração dos três primeiros harmônicos	81
Figura 7. 1 - Efeito da variação do número de neurônios	85
Figura 7. 2 - Harmônicos 1, 2 e 3 do espectro de D4	87
Figura 8. 1 - Diagrama em blocos do sistema	89

LISTA DE TABELAS

Tabela 2. 1 - Frequência x causas de vibração	27
Tabela 5. 1 – Tabela de classificação segundo a ISO 2372	60
Tabela 5. 2 – Classificação prática	62
Tabela 7. 1 . Resultados do sistema	86
Tabela 7. 2. Comparação resultados esperados x resultados do sistema.	87

SUMÁRIO

1	INTRODUÇÃO	14
2	ASPECTOS TEÓRICOS FUNDAMENTAIS	17
2.1	MOVIMENTO HARMÔNICO SIMPLES	17
2.2	VIBRAÇÕES	19
2.3	ANÁLISE EM FREQUÊNCIA	21
2.4	ANÁLISE DE FOURIER	23
2.5	ANÁLISE DE FOURIER EM VIBRAÇÕES	26
2.6	SINAIS DISCRETOS	28
2.7	TRANSFORMADA RÁPIDA DE FOURIER	30
2.8	ANÁLISE DE ESPECTRO COM FFT E MATLAB	32
2.9	SISTEMAS BASEADOS EM CONHECIMENTO	35
3	REDES NEURAIS	38
3.1	O NEURÔNIO ARTIFICIAL	39
3.2	TIPOS DE ARQUITETURA DE REDES NEURAIS	41
3.3	REDE NEURAL DE UMA CAMADA	42
3.4	REDE NEURAL MULTICAMADA	43
3.5	PROCESSO DE TREINAMENTO	45

3.6	ASPECTOS IMPORTANTES NO TREINAMENTO	48
3.7	APLICAÇÕES DAS REDES NEURAIIS	51
4	RECONHECIMENTO DE PADRÕES	52
4.1	RECONHECIMENTO DE PADRÕES POR REDES NEURAIIS	52
4.2	APLICAÇÕES SIMILARES	53
5	VIBRAÇÕES EM MÁQUINAS ROTATIVAS	56
5.1	CONCEITOS	56
5.2	PADRÕES DE VIBRAÇÃO	63
6	TRATAMENTO DOS DADOS EXPERIMENTAIS	67
6.1	MÉTODO UTILIZADO	67
6.2	TRANSFORMAÇÃO PARA O DOMÍNIO FREQUENCIA	70
6.3	EXTRAÇÃO DAS CARACTERÍSTICAS DE INTERESSE	72
6.4	ENTRADAS E SAÍDAS DA REDE	74
6.5	CLASSIFICAÇÃO E TRATAMENTO DOS DADOS	75
6.6	ARQUITETURA DA REDE E ALGORITMO DE TREINAMENTO	77
6.7	TREINAMENTO DA REDE	78
6.8	TESTE DA REDE	80
6.9	FLUXOGRAMA	82

7	RESULTADOS	84
8	CONCLUSÃO	89
	REFERÊNCIAS	93
	APÊNDICE A - CÓDIGO DO PROGRAMA EM MATLAB	95
	APÊNDICE B - RELAÇÃO DE MÁQUINAS	101

1 INTRODUÇÃO

A detecção de falhas em máquinas em seu estágio inicial antes que elas causem uma parada ou dano grave, é um tema extensivamente pesquisado devido à grande importância que a continuidade operacional das máquinas representa para as indústrias em geral.

Pode-se afirmar que o ideal de qualquer Engenheiro de Manutenção é o de dispor de meios e ferramentas que possam antecipar os problemas antes que eles comecem a interferir na linha de produção.

Para um sistema que se deteriora gradualmente, a mais avançada estratégia de manutenção preventiva se baseia na monitoração de parâmetros que levem a um diagnóstico do nível de deterioração da máquina (GRALL, 2002). Esta estratégia, baseada na condição do equipamento, é muito mais eficaz que aquela baseada somente no tempo decorrido após a última manutenção. Isto evita paradas inesperadas ou substituição desnecessária de peças.

Dentre os parâmetros que indicam que algo não vai bem em uma máquina rotativa e pode ocorrer uma falha grave, encontra-se a vibração. A vibração ocorre como resultado de pequenos distúrbios localizados e que vão sendo amplificados ao longo do tempo. Apesar de esses sintomas serem bem conhecidos e a vibração ser um fenômeno bastante estudado, a interpretação

dos dados para diagnóstico ainda é um tema cercado de muita incerteza, geralmente deixado a cargo de poucos especialistas.

A vibração é uma das grandezas de maior interesse na monitoração do estado das máquinas rotativas. Se uma pequena falha se desenvolve e se mantém sem ser detectada, então esta falha pode se agravar com o tempo, causando uma parada total do equipamento e/ou redução da sua vida útil. Através da medição e análise da vibração em máquinas rotativas, é possível detectar e localizar falhas importantes como desbalanceamento, empeno de eixo, trincas, problemas em rolamentos, entre outros (SANTIAGO, 2004).

Existem equipamentos oferecidos no mercado destinados à monitoração e diagnóstico de vibração, mas estes são fechados, caros e usualmente requerem um especialista para interpretá-los.

Masuli, Parent e Studer (1998) mencionam que as técnicas mais utilizadas para diagnóstico de vibração utilizam a Transformada de Fourier para transformar o sinal de vibração do domínio do tempo para o domínio frequência e então verificar as amplitudes das bandas e as frequências onde elas ocorrem.

A partir do estudo de técnicas utilizadas na indústria para diagnóstico de vibração, este trabalho propõe um algoritmo em Matlab, baseado em Redes Neurais Artificiais, que leia registros de vibração e, em seguida, proceda a classificação do tipo de defeito.

No capítulo 2 são tratados alguns conceitos teóricos considerados fundamentais ao entendimento do problema como o dos movimentos harmônicos, Análise de Fourier, vibrações em máquinas rotativas, discretização de sinais, análise de espectro, a transformada rápida de Fourier e os sistemas baseados em conhecimento. O capítulo 3 aborda especificamente os aspectos básicos associados às redes Neurais Artificiais (RNA). O capítulo 4 trata do problema de reconhecimento de padrões e destaca casos de aplicação similares ao problema de vibração de máquinas rotativas. Detalhes específicos de vibração em máquinas rotativas são tratados no capítulo 5. O capítulo 6 detalha os experimentos realizados e o uso das RNA para o reconhecimento de padrões de vibração em equipamentos rotativos. Os resultados são expressos no capítulo 7 e o capítulo 8 trata as conclusões deste trabalho.

2 ASPECTOS TEÓRICOS FUNDAMENTAIS

2.1 MOVIMENTO HARMÔNICO SIMPLES

A vibração, na sua forma mais simples, pode ser considerada uma oscilação ou um movimento repetitivo de um corpo em torno de um ponto de equilíbrio. Este tipo de movimento é chamado de movimento periódico que se caracteriza por uma repetição de todas as suas características após um certo intervalo de tempo chamado de *período* (HARTOG,1972). Como exemplo, a Fig.2.1 mostra a curva do deslocamento observado no suporte de um mancal de uma turbina.




Figura 2.1 - Função periódica

O *movimento harmônico* é o tipo mais simples de movimento periódico. Nele, a relação entre a variável observada x (deslocamento) e o tempo t pode ser expressa por:

$$x = X_0 \text{ sen } \omega t.$$

Equação 2.1




Figura 2. 2 - Representação de um movimento harmônico simples

Na figura 2.2, T é o Período e X_0 a amplitude máxima. O inverso do Período, $f = 1/T$, é a frequência do movimento, expressa em *ciclos/segundo*, ou *Hertz*. Na equação 2.1 aparece também a grandeza ω que é denominada frequência angular medida em *radianos/segundo*.

A *velocidade* do movimento descrito acima é igual à taxa de variação do deslocamento, ou em outras palavras, a medida da rapidez do deslocamento. Matematicamente esta taxa é expressa por:

$$v = \frac{dx}{dt} = \omega X_0 \cos(\omega t) \quad \text{Equação 2.2}$$

onde v = velocidade instantânea.

A forma da função velocidade é também senoidal, mas *defasada* de 90° em relação ao deslocamento quando as duas funções são expressas em termos de vetores girantes. Isto significa que quando o deslocamento está com sua amplitude máxima, a velocidade está com valor 0.

A *aceleração* do movimento é definida como a taxa de variação da velocidade, ou a medida da rapidez da mudança de

velocidade em qualquer instante. É expressa matematicamente por:

$$a = \frac{dv}{dt} = \frac{d^2x}{dt^2} = -\omega^2 X \cos(\omega t) \quad \text{Equação 2.3}$$

onde a = aceleração instantânea.

Como no caso da velocidade, a forma e o período são os mesmos do deslocamento, mas com uma defasagem de 180° , ou seja, quando o deslocamento está no máximo positivo, a aceleração está no máximo negativo.

Estas equações mostram que a velocidade é proporcional ao produto do deslocamento pela frequência angular e que a aceleração é proporcional ao deslocamento vezes o quadrado da frequência angular.

Este resultado é relacionado com a escolha do parâmetro de vibração a ser utilizado na monitoração e diagnóstico, como será visto no item 5.1.

2.2 VIBRAÇÕES

A vibração é o movimento resultante de uma força oscilante e, para um sistema linear, a frequência da vibração é a mesma da força que a provoca. Quando existem várias forças atuando ao mesmo tempo, então a vibração resultante será a soma de vibrações cada uma com a mesma frequência da força causadora.

A forma de onda resultante não será mais uma senóide como a do movimento harmônico simples, mas uma forma mais complexa como, por exemplo, a imagem da figura a seguir.




Figura 2.3 - Representação de um movimento composto

A figura 2.3 representa a forma de onda de duas forças oscilantes cada uma com uma frequência diferente (proporcional às massas dos corpos e das constantes das respectivas molas).

Ainda assim, a forma de onda não é considerada complexa e é relativamente fácil de se determinar as frequências e amplitudes das duas componentes da onda. Casos reais, porém, associam maior complexidade.

Em uma máquina rotativa típica, é muito difícil obter informações a respeito das componentes e causas da vibração por uma simples inspeção da forma de onda expressa no tempo.

2.3 ANÁLISE EM FREQUÊNCIA

Para contornar as limitações e dificuldades da análise da forma de onda do sinal de vibração no domínio do tempo, a prática comum é utilizar a análise em frequência, também chamada de análise espectral. O gráfico no domínio tempo é chamado de forma de onda e o gráfico no domínio frequência é chamado de espectro. O tempo e a frequência guardam entre si a seguinte relação:

$$tempo = \frac{1}{frequencia} \quad \text{Equação 2.4}$$

Pode-se visualizar a equivalência entre as duas representações com o seguinte exemplo:

Supondo que se queira realizar uma medida durante 24 h a intervalos de 10 minutos, pode se expressar esta informação, por exemplo, destas duas maneiras:

a) Intervalos = [6:10 , 06:30, 06:50, 07:10, 07:30,04:50, 05:10, 05:30, 05:50, 06:10]

b) Intervalos = "a cada 20 minutos, iniciando às 06:10"

No primeiro caso a informação é equivalente à representação no domínio do tempo e na segunda no domínio frequência.

Nota-se que a informação é a mesma em ambos os exemplos, mas, neste caso, é muito mais compacta no domínio frequência.

Um outro exemplo pode ser encontrado na Engenharia Elétrica com o conceito de *Fasor* (HAYT; KEMMERLY, 1975): uma corrente ou tensão senoidal com uma frequência determinada pode ser caracterizada por apenas dois parâmetros, uma amplitude e um ângulo de fase. Assim, por exemplo, uma corrente senoidal tem amplitude máxima I_m , frequência ω e ângulo de fase ϕ . No domínio tempo, esta corrente, cujo valor varia no tempo, é representada por:

$$i = I_m \cos(\omega t + \phi) \quad \text{Equação 2.5}$$

No domínio da frequência esta mesma corrente é representada simplesmente por:

$$\mathbf{I} = I_m \angle \phi \quad \text{Equação 2.6}$$

Observa-se que a representação não inclui explicitamente a frequência, pois esta informação está implícita. Quando se fala que a tensão de distribuição de uma rede elétrica é 220 V, 60 Hz, este conceito está sendo implicitamente utilizado.

Em análise de vibração, a representação no domínio frequência simplifica bastante o trabalho, conforme será visto no capítulo 5.

Resgatando a figura 2.3 do item 2.2, a qual simula a vibração causada por dois corpos com massas diferentes, a forma de onda resultante no domínio tempo pode ser agora representada pelo espectro de frequência mostrado na figura 2.4.

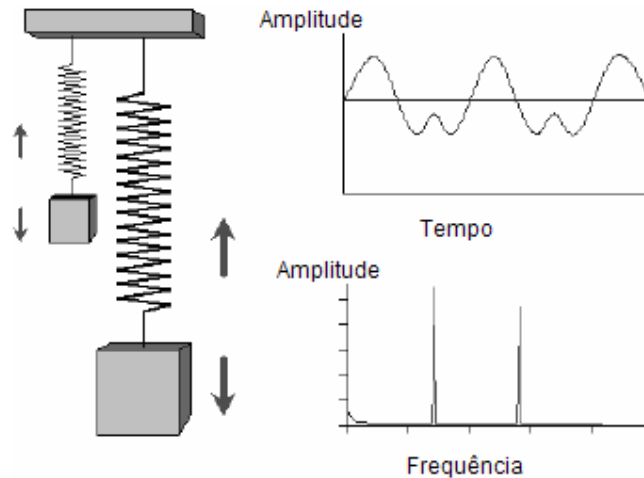


Figura 2. 4 – Representações no domínio tempo e frequência

Observa-se que o sinal no domínio frequência (espectro) é uma representação bem mais simples, mostrando amplitudes bem determinadas em duas frequências diferentes. Sem se conhecer a origem das forças que originaram a forma de onda complexa, pode-se dizer que o sinal resultante é composto duas forças oscilantes cada uma com uma frequência e amplitude características. Tal abordagem fornece a identificação das causas individuais do fenômeno da vibração.

Uma outra vantagem da análise em frequência é permitir o uso de ferramentas computacionais que utilizam a análise de Fourier, como a Transforma Rápida de Fourier, ou FFT, como será visto no item 2.7.

2.4 ANÁLISE DE FOURIER

Joseph Fourier (1768- 1830) submeteu um artigo em 1807 para a Academia de Ciências de Paris. Este artigo fazia uma

descrição matemática de problemas envolvendo a condução de calor, mas foi rejeitado por ter sido considerado com falta de rigor matemático. Contudo, o artigo continha idéias que permitiram o desenvolvimento de uma importante área da matemática que foi denominada em sua homenagem como Análise de Fourier.

Fourier demonstrou que:

- 1) É possível reduzir uma onda complexa periódica em uma soma de uma série de ondas senoidais
- 2) As ondas senoidais necessárias para reconstituir a onda original são ondas com frequências que são múltiplos inteiros da frequência fundamental.

A análise de Fourier permite representar um sinal periódico qualquer no domínio do tempo em componentes representados pela frequência e amplitude, no domínio frequência.

Dada uma função contínua periódica qualquer, ou seja,

$$f(t) = f(t+T) \quad \text{Equação 2.6}$$

onde T é o período, o teorema de Fourier estabelece que $f(t)$ pode ser representada por uma série infinita denominada de *série de Fourier* expressa por: (HAYT; KEMMERLLY, 2005)

$$f(t) = a_0 + a_1 \cos \omega_0 t + a_2 \cos 2\omega_0 t + \dots + b_1 \text{sen} \omega_0 t + b_2 \text{sen} 2\omega_0 t + \dots$$

$$= a_0 + \sum_{n=1}^{\infty} (a_n \cos n\omega_0 t + b_n \text{senn}\omega_0 t) \quad \text{Equação 2.7}$$

A freqüência angular fundamental ω_0 é relacionada com o período T através de

$$\omega_0 = \frac{2\pi}{T} \quad \text{Equação 2.7}$$

Demonstra-se que os componentes a_0 , a_n e b_n podem ser calculados como

$$a_0 = \frac{1}{T} \int_0^T f(t) dt \quad \text{Equação 2.8}$$

$$a_n = \frac{2}{T} \int_0^T f(t) \cos n\omega_0 t dt \quad \text{Equação 2.9}$$

$$b_n = \frac{2}{T} \int_0^T f(t) \text{senn}\omega_0 t dt \quad \text{Equação 2.10}$$

Em um espectro de freqüência, o valor de a_0 é a amplitude da componente contínua e a_n e b_n são as amplitudes das componentes harmônicas para os termos cosenoidais e senoidais, respectivamente, com $n = \{1, 2, \dots, \infty\}$. O processo de determinar as constantes a_0 , a_n e b_n é denominado de *Análise de Fourier*.

Neste trabalho está sendo usada a ferramenta Fast Fourier Transform (FFT), implementada e disponível no ambiente do Matlab, para transformar um sinal discretizado do domínio tempo para o domínio freqüência.

2.5 ANÁLISE DE FOURIER EM VIBRAÇÕES

Em análise de vibração, as harmônicas são comumente referidas como sendo 1x a rotação (fundamental), 2x a rotação, 3x a rotação e assim sucessivamente.

Como visto no item 2.4, o método de análise de frequências, baseado na transformada de Fourier, estabelece que qualquer função periódica pode ser decomposta por uma série de ondas senoidais puras com frequências distintas e múltiplas harmônicas da frequência fundamental. Estas componentes constituem o espectro de frequência da vibração. Observando a amplitude das harmônicas e relacionando com a amplitude da frequência fundamental, pode-se chegar a um diagnóstico do estado de funcionamento ou alteração em curso na máquina [MARÇAL, 2000].

Cada força excitadora existente em diferentes pontos da máquina gerará uma harmônica da vibração determinando um certo deslocamento, uma certa velocidade e uma determinada aceleração; a soma de todas as harmônicas para cada variável resultará um sinal resultante complexo, presente nos mancais ou estrutura da máquina.

Os métodos usuais de análise de vibração fazem uso da análise de Fourier para a determinação das causas e severidade do problema. Pode-se, por exemplo, transformar o sinal do domínio tempo para o domínio frequência (análise espectral) para facilitar a análise do fenômeno. Existem tabelas que

relacionam as frequências com as causas da vibração como a tabela 2.1.

Tabela 2. 1 - Frequência x causas de vibração [fonte: apostila Análise de Vibração, USP]

CAUSA	VIBRAÇÃO		OBSERVAÇÕES
	FREQÜÊNCIA	DIREÇÃO	
Turbilhão de óleo	De 0,42 a 0,48 X FR FR = Frequência de rotação	Radial	Unicamente sobre mancais lisos hidrodinâmicos com grande velocidade.
Desbalanceamento	1 x FR Radial	Radial	Intensidade proporcional à velocidade de rotação.
Defeito de fixação	1, 2, 3, 4 x FR	Radial	
Defeito de alinhamento	2 x FR	Axial e radial	Vibração axial em geral mais importante, se o defeito de alinhamento contém um desvio angular.
Excitação elétrica	1, 2, 3, 4 x 60Hz	Axial e radial	Desaparece ao se interromper a energia elétrica.
Velocidade crítica de rotação	Frequência crítica do motor	Radial	Aparece em regime transitório e desaparece em seguida.
Correia em mau estado	1, 2, 3, 4 x FR	Radial	
Engrenagens defeituosas	Frequência de engrenamento = F F = n° de dentes x FR árvore	Radial + axial	Banda lateral em torno da frequência de engrenamento.
Pinhão ("falsa volta")	F ± FR pinhão	Radial + axial	Bandas laterais em torno da frequência de engrenamento devido às "falsas voltas".
Excitação hidrodinâmica	Frequência de passagem das pás	Radial e axial	
Deterioração do rolamento	Altas frequências	Radial e axial	Ondas de choque causadas por escamações.

A transformação de uma função no domínio tempo para o domínio frequência em sinais amostrados pode ser realizada pela Transformada Discreta de Fourier ou DFT (Discret Fourier Transform) após a amostragem de um sinal contínuo. A FFT é um algoritmo para implementar a DFT com maior velocidade de processamento.

2.6 SINAIS DISCRETOS

Um sinal discreto é uma seqüência de números reais ou complexos [HAYES, 1999]. Dessa forma, o sinal discreto é uma função de uma variável inteira, n , representada por $x(n)$ sendo n pertencendo ao conjunto Z dos números inteiros. Embora a variável independente n não é necessariamente do domínio do tempo, $x(n)$ é normalmente referido como uma função do tempo. Esta função pode ser representada na forma de um gráfico como o da figura 2.5.




Figura 2.5 - Sinal amostrado no domínio do tempo

Em alguns problemas e aplicações, como é o caso desta pesquisa, é conveniente transformar a variável $x(n)$ como um vetor. Assim os valores seqüenciais que variam de $x(0)$ a $x(N-1)$, sendo N um número inteiro arbitrário qualquer, tornam-se elementos de um vetor coluna como a seguir:

$$\mathbf{x} = [x(0), x(1), \dots, x(N-1)]^T$$

Sinais discretos no tempo são geralmente obtidos de amostragem de um sinal contínuo do tempo através de um

conversor A/D. Por exemplo, um sinal contínuo $x_a(t)$ que é amostrado a uma taxa $f_s = 1/T_s$ sendo f_s uma freqüência em amostras/unidade de tempo e T_s o intervalo entre amostras em unidade de tempo. A relação entre $x(n)$ e $x_a(t)$ é dada por:

$$x(n) = x_a(nT_s)$$

Em processamento digital de sinais, usa-se a *Transformada Discreta de Fourier (DFT)* ou a *Transformada Rápida de Fourier (FFT)* para transformar os sinais discretos do domínio tempo para o domínio freqüência.

A transformada discreta de Fourier calcula uma seqüência discreta $X(k)$ de tamanho N cujos coeficientes são relacionados com $x(n)$ por:

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi kn/N} \quad \text{Equação 2.11}$$

$X(k)$ é a amplitude do k^{th} harmônico, onde k varia de 0 a $N-1$ e k/N representa uma fração da freqüência de amostragem. Em geral $X(k)$ é um número complexo, ou seja, possui módulo e ângulo de fase.

O gráfico de $|X(k)|$ versus a freqüência é denominado de espectro do módulo, enquanto o gráfico do argumento de $X(k)$ é o espectro de fase.

Os sinais que foram utilizados nesta pesquisa e que foram processados pela função FFT do algoritmo são sinais discretos no tempo e que foram obtidos com diferentes freqüências de amostragem.

2.7 TRANSFORMADA RÁPIDA DE FOURIER

A transformada rápida de Fourier, conhecida como FFT (Fast Fourier Transform) é um algoritmo eficiente para implementar a DFT em computadores digitais e é amplamente utilizada em análise de vibração em máquinas rotativas.

Por muitos anos, filtros analógicos foram usados para análise de som e vibração em máquinas rotativas [GOLDMAN, 1999]. Bancos de filtros eram colocados lado a lado e a saída de cada um deles era lida ou apenas um filtro sintonizável era utilizado no range de frequência de interesse. Havia dois grandes problemas: a) os filtros analógicos requeriam longo tempo de estabilização antes que as amplitudes pudessem ser lidas com precisão, e b) a varredura através do range de frequência era tão demorada que a máquina podia estar sob diferentes condições de carga antes que a medição pudesse iniciar.

Em 1965, Cooley e Tukey, da Universidade de Columbia, desenvolveram um algoritmo que tornou o cálculo do espectro de frequência de um sinal mais rápido e eficiente em computadores digitais [GOLDMAN, 1999]. O algoritmo, designado Fast Fourier Transform, originou os analisadores de espectro, capazes de cálculos rápidos da transformada de Fourier de um sinal, simulando o os resultados que seriam obtidos por centenas de filtros analógicos colocados lado a lado. Com isto as análises

de espectro de sinais a exemplo dos sinais de som e vibração puderam ser realizadas mais facilmente.

Como será visto no capítulo 5, para se determinar a fonte da vibração, é desejável observar várias faixas de frequência, simulando-se vários filtros com banda estreita. Isto porque, sendo possível determinar as frequências onde ocorrem os picos de amplitude do sinal de vibração, é possível determinar a causa da vibração. O algoritmo FFT simula estes vários filtros.

Para utilização eficiente do algoritmo FFT o sinal deve consistir de um número de amostras igual a uma potência de dois. Por exemplo, 512, 1024, 2048, 4096, e assim por diante [BODRE, 2003].

Como o algoritmo FFT é implementado em dispositivos micro processados, o sinal deve ser previamente digitalizado a uma determinada frequência de amostragem antes de ser processado. Uma taxa de amostragem cuja frequência seja próxima à do sinal que esteja sendo amostrado causa o efeito denominado de "*aliasing*". Para evitar este problema, o teorema de Nyquist recomenda utilizar uma frequência de amostragem de no mínimo 2 vezes a frequência da faixa do sinal que está sendo amostrado [GOLDMAN, 1999].

2.8 ANÁLISE DE ESPECTRO COM FFT e MATLAB

O Matlab possui a função FFT para calcular a transformada discreta de Fourier.

As sintaxes para utilização desta função são [MATLAB FUNCTION REFERENCE]:

```
X = fft(x)
X = fft (x,n)
```

Quando o tamanho do vetor x é uma potência de 2, um algoritmo mais rápido, denominado de *high-speed radix-2 FFT*, é utilizado.

Além disso, recomenda-se que n seja no mínimo igual ao número de amostras do sinal no domínio tempo [UNIVERSITY OF RHODE ISLAND, 2004].

Para ilustrar a utilização da função FFT do Matlab, é importante rever alguns conceitos já apresentados até agora e observar algumas de suas características.

Considere um sinal periódico no domínio tempo, formado por três senóides, cada uma com amplitudes e frequências diferentes. A frequência de amostragem é de 100 Hz. Para gerar e visualizar este sinal pode-se utilizar o seguinte código no Matlab:

```
t=(0:.01:.99); % Gera instantes das amostras
s1= 2*sin(2*pi*10*t);
s2= 4*sin(2*pi*20*t);
s3= 1*cos(2*pi*30*t)
s= s1 + s2 + s3;
plot(t, s)
```

Observa-se que o intervalo entre amostras (período amostral T) é de 0,01 e conseqüentemente a freqüência amostral $f_s = 1/T=100$. O primeiro sinal, s_1 , tem amplitude 2 e freqüência 10 Hz, o segundo amplitude 4 e freqüência 20 Hz e o terceiro é defasado de 90° , tem amplitude 1 e freqüência 30 Hz. Verifica-se que a freqüência amostral atende o critério de Nyquist já que é maior que o dobro da maior freqüência do sinal. O sinal gerado é visto a seguir:




Figura 2. 6 - Sinal periódico composto

Como se vê, é difícil identificar as componentes do sinal observando o sinal no domínio do tempo. Para converter este sinal para o domínio freqüência, usa-se o código:

```
F=fft(s);
```

O vetor F é um vetor complexo da forma $a + jb$, de dimensão $N=100$, simétrico em torno de $N/2$. Portanto tem módulo

(amplitude) e ângulo de fase (argumento) mostrados na figura 2.7:

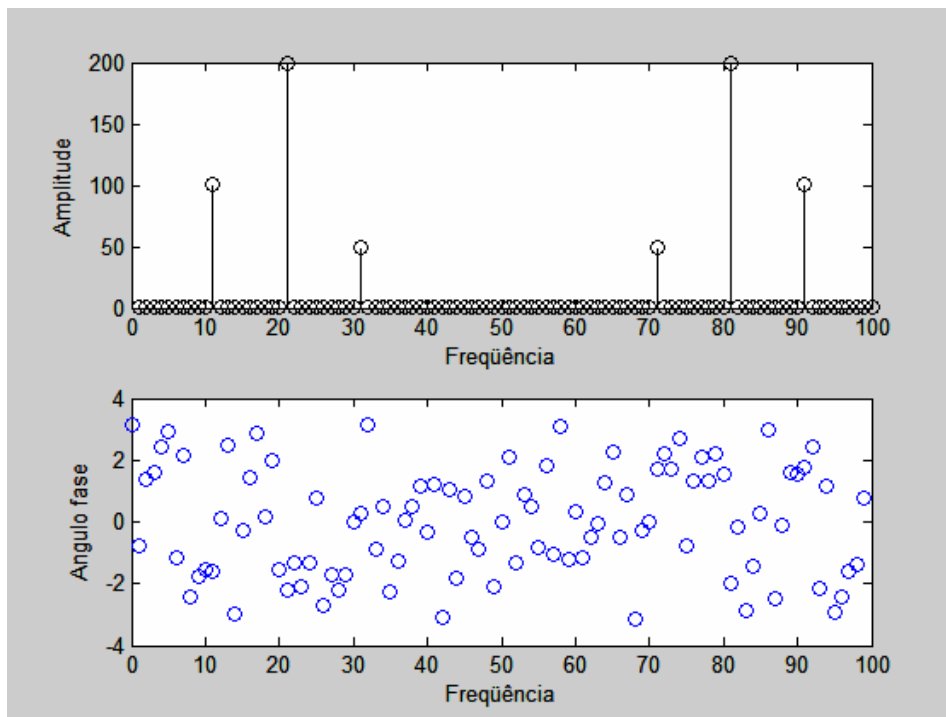


Figura 2. 7 - Sinal transformado pela FFT

Observa-se que a amplitude dos harmônicos está muito diferente do esperado. Isto porque o resultado da FFT é sempre multiplicado pelo número de amostras. Além disso, os valores são simétricos em torno de $N/2$.

Para ajustar estes valores é necessário dividir a amplitude por $N/2$.

Após o tratamento dado acima, obtem-se o resultado esperado:

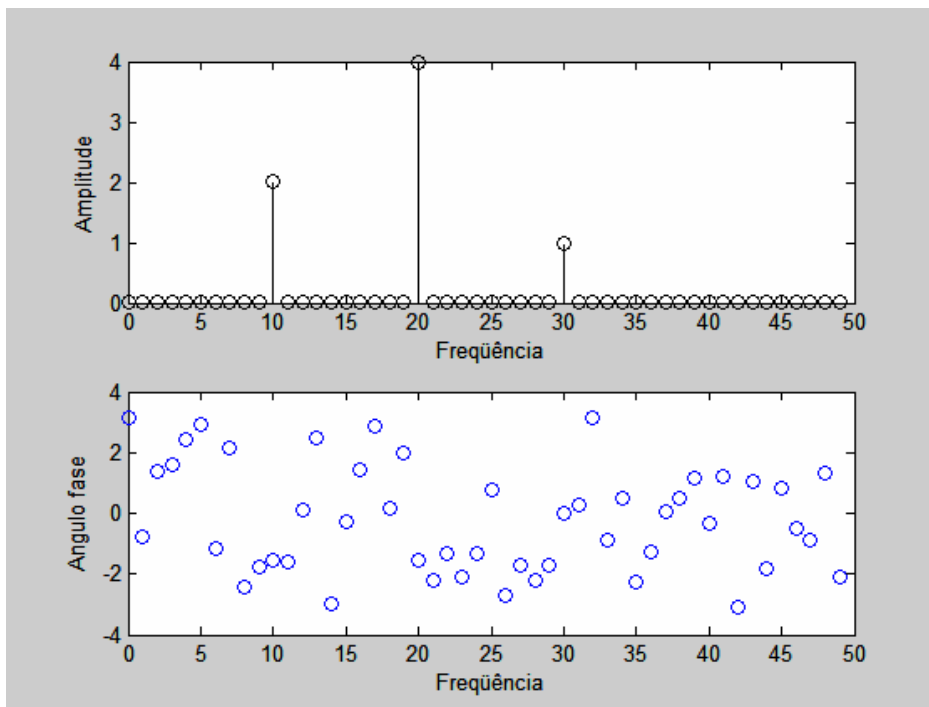


Figura 2. 8 - Sinal após escalonamento

Verifica-se na figura 2.8 que a amplitude na freqüência fundamental, 10 Hz, tem valor 2, no segundo harmônico, 20 Hz, o valor 4, e no terceiro harmônico, 30 Hz, o valor 1, em concordância com as amplitudes dos sinais individuais que geraram o sinal composto.

2.9 SISTEMAS BASEADOS EM CONHECIMENTO

Sistemas Baseados em Conhecimento são programas de computador que usam o conhecimento de especialistas, representado explicitamente, para resolver problemas [REZENDE; PUGLIESI; VAREJÃO; 2003]. Como citado por esses autores, *“devem ser usados quando a formulação genérica do problema a*

ser resolvido computacionalmente é complexa (tipicamente combinatória) e quando existe uma grande quantidade de conhecimento específico para resolvê-lo". Normalmente, uma boa indicação a respeito da aplicabilidade do uso desta metodologia é a existência de um especialista humano capaz de solucionar o problema. Este é o caso do diagnóstico de vibração em máquinas rotativas.

Segundo Newell (1982 *apud* REZENDE, 2003) o desenvolvimento de um Sistema Baseado em Conhecimento deve conter a descrição do sistema sob duas perspectivas distintas: a do conhecimento, processável pelo homem, e a simbólica, processável pelo computador. Com esta distinção, Newell enfatizou a importância de separar a) a análise e a modelagem do método de resolução do problema e b) a atividade de representar este método em um formalismo que seja computacionalmente eficiente.

A representação do conhecimento, que é a parte crítica de um Sistema Baseado em Conhecimento, é definida por Davis, Shrobe, & Szolovits (1983 *apud* REZENDE, 2003) como uma forma sistemática de estruturar e codificar o que se sabe sobre uma determinada aplicação. Contudo, ao contrário de uma codificação qualquer, uma Representação do Conhecimento deve apresentar as seguintes características:

- ser compreensível ao ser humano, pois caso seja necessário avaliar o estado de conhecimento do sistema ou melhorar o seu desempenho, a

representação do conhecimento deve permitir a sua interpretação;

- abstrair-se dos detalhes de como funciona internamente o processador de conhecimento que a interpretará;
- ser robusta, isto é, permitir a sua utilização mesmo que não aborde todas as situações possíveis;
- ser generalizável, de modo que possa ser atribuída a diversas situações.

Como citado por Rezende, Puglise & Varejão (2003), obter e representar todo o conhecimento é extremamente difícil. Em situações específicas, a falta de um tipo de conhecimento pode levar o Sistema Baseado em Conhecimento a gerar uma resposta não razoável. Por conta disso, esses sistemas são muito mais usados como assistentes na resolução de problemas do que propriamente como os responsáveis definitivos pela tomada de decisão.

3 REDES NEURAIS

As RNAs são modelos matemáticos que se assemelham às estruturas neurais biológicas e que podem atingir um desempenho computacional especificado por meio de um processo de treinamento [BRAGA; CARVALHO; LUDEMIR, 2000]. Uma forma alternativa é definir uma rede neural como um processador paralelo distribuído que possui a capacidade de armazenar conhecimento adquirido por treinamento e torná-lo disponível para uso.

Os parâmetros que caracterizam uma rede são os seguintes: número de camadas, número de neurônios por camada, tipos de função de ativação dos neurônios e peso de cada uma das conexões. Uma rede neural pode ter ou não uma retro-alimentação.

Em uma rede neural com várias camadas, do tipo sem retro-alimentação (feed-forward), a saída de uma camada será sempre a entrada da camada seguinte. Portanto, para calcular a saída final de uma rede neural basta calcular seqüencialmente as entradas e saídas por toda a rede neural. Este cálculo que conceitualmente é muito simples pode se tornar tedioso e complexo se a rede possuir várias camadas e muitos neurônios nestas camadas. Uma maneira mais simples e computacionalmente mais eficiente de se fazer isto é expressar a equação da RNA de forma matricial conforme ilustrado adiante.

3.1 O NEURÔNIO ARTIFICIAL

Uma rede neural é um sistema de processamento de sinal ou informação, composto por um grande número de elementos simples de processamento, chamados neurônios artificiais, ou simplesmente nós, que são interconectados por elos diretos chamados de conexões, que colaboram para realizar um processamento paralelo distribuído.

A saída de um neurônio artificial é calculada multiplicando-se cada entrada x_k por um respectivo fator w_k chamado de peso, somando-se os resultados a um valor de polarização (*bias*), e aplicando-se uma função de ativação para o resultado da soma.

$$a = f \left[\sum_{k=1}^n x_k w_k + bias \right] \quad \text{Equação 2.12}$$

A figura a seguir representa um neurônio artificial com n entradas.




Figura 3. 1 - Neurônio Artificial

A função de ativação pode ser de vários tipos, por exemplo, linear, logarítmica sigmoidal, tangente sigmoidal.

A função de ativação linear simplesmente repete a saída, ou seja:

$$y = f(x) = x \quad \text{Equação 2.13}$$

A função de ativação logarítmica sigmoidal (logsig) apresenta saída compreendida entre [0 1] e é calculada como:

$$y = f(x) = \frac{1}{1 + e^{-x}} \quad \text{Equação 2.14}$$

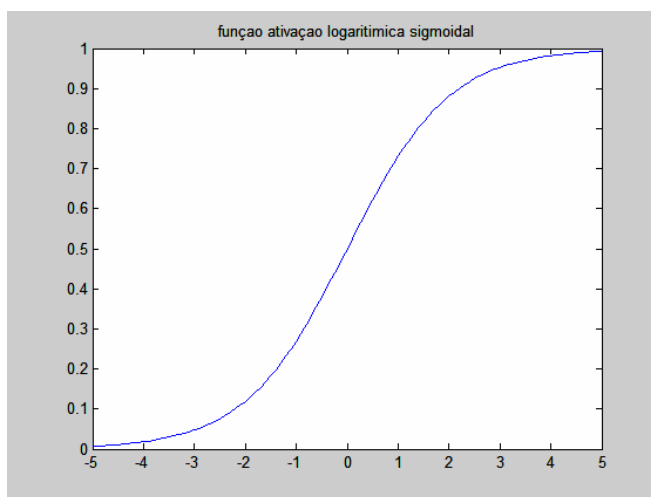


Figura 3. 2 - Função de ativação logsig

A função de ativação tangente sigmoidal (tansig) tem saída compreendida entre [-1 1] e é definida como:

$$y = f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad \text{Equação 2.14}$$

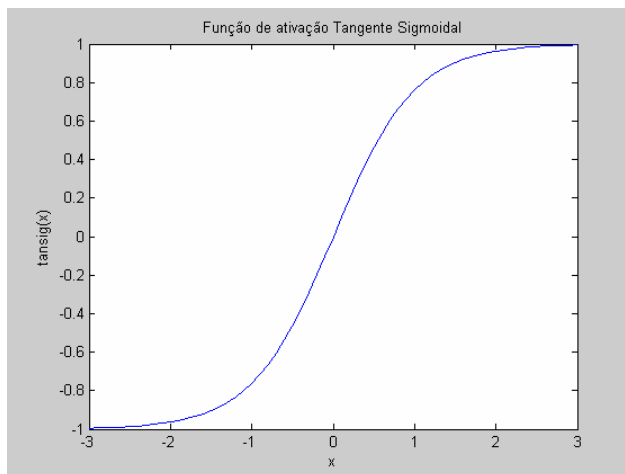


Figura 3. 3 - Função de ativação tansig

3.2 TIPOS DE ARQUITETURA DE REDES NEURAIIS

Há várias arquiteturas de redes neurais. Dentre elas, pode-se citar a *feed-forward network*, *CMAC*, *rede Hopfield*, *rede de Kohonem*, *redes neurais de bases radiais*, *ressonância adaptativas (ART)*. Segundo citado por CHOW [1997], a rede *feed-forward* (sem retro-alimentação) é provavelmente a arquitetura mais popular, cobrindo cerca de 80% das aplicações com redes neurais. Essas redes são organizadas em camadas possuindo conexões unidirecionais entre uma camada e outra.

Outra classe popular de redes é a dos mapas auto-organizáveis (*self-organizing maps*), ou redes de Kohonem, as quais são usadas principalmente para agrupamento de dados (*clustering*) e em mapeamento de características.

O processo de aprendizado pode envolver atualização da arquitetura da rede ou simplesmente a atualização dos pesos das conexões, de forma que a rede possa ser treinada para

efetuar tarefas específicas, por exemplo, de classificação e análise de agrupamentos.

A popularidade de redes neurais cresceu devido ao fato de que o mesmo tipo de rede pode ser aplicado em vários problemas, o que não ocorre com as abordagens baseadas em modelos ou em regras. Outro fator importante na popularidade é o fato de existirem muitos algoritmos eficientes para treinamento das redes neurais.

3.3 REDE NEURAL DE UMA CAMADA

Neurônios são agrupados em camadas para formar uma estrutura de rede. A camada de entrada não faz nenhum processamento, simplesmente transmite os valores das estradas, modificados pelos pesos, para os neurônios das camadas seguintes. A próxima camada pode ser uma camada escondida ou a camada de saída em uma arquitetura de uma camada.




Figura 3. 4 - Rede neural de uma camada

Supondo que temos uma rede neural de uma camada, com três neurônios de entrada e dois neurônios na camada de saída. O vetor de entrada é, por exemplo, $x = [2 \ 4 \ 6]'$, o vetor de pesos que conecta a entrada ao neurônio y_1 é $w_1 = [0,5 \ -0,25 \ 0,33]$ e o vetor de pesos que conecta a entrada ao neurônio y_2 é $w_2 = [0,2 \ -0,75 \ -0,5]$, e o vetor de pesos que conecta o neurônio x_0 que representa a polarização (bias) aos dois neurônios de saída é $w_0 = [0,4 \ -1,2]$. As saídas podem ser calculadas como se segue [HINES, 1997]:

$$y = \tanh(\mathbf{w} * \mathbf{x} + \mathbf{b}) = \tanh\left(\begin{bmatrix} 0.5 & -0.25 & 0.33 \\ 0.2 & -0.75 & -0.5 \end{bmatrix} \begin{bmatrix} 2 \\ 4 \\ 6 \end{bmatrix} + \begin{bmatrix} 0.4 \\ -1.2 \end{bmatrix}\right)$$

onde \tanh é a função de ativação tangente hiperbólica.

Usando o MATLAB:

```
x=[2 4 6]';
w=[0.5 -0.25 0.33; 0.2 -0.75 -0.5];
b=[0.4 -1.2]';
y=tanh (w*x+b)
```

```
y =
    0.9830
   -1.0000
```

3.4 REDE NEURAL MULTICAMADA

Redes neurais com uma ou mais camadas escondidas são denominadas de rede multicamada. Normalmente, cada camada escondida possui o mesmo tipo de função de ativação. A função de ativação dos neurônios da camada de saída é usualmente do tipo sigmoideal ou linear.

Foi demonstrado que uma rede com uma única camada escondida com neurônios não lineares (sigmoidais) pode aproximar qualquer função com qualquer grau de incerteza [CYBENKO, 1989]. O problema é saber quantos neurônios na camada escondida são necessários e não é certo que se consegue achar a matriz de pesos para um dado erro alvo.

A figura 3.5 mostra uma arquitetura de uma rede multicamada.




Figura 3. 5 - Rede neural multicamada

A implementação de uma rede neural multicamadas passa geralmente por três etapas:

- 1) definição do número de entradas e saídas da rede;
- 2) escolha da arquitetura da rede (número de camadas, número de neurônios por camada e respectivos tipos);
- 3) O ajuste dos pesos das conexões ou aprendizagem da rede.

Na escolha da arquitetura da rede deve-se ter cuidado em não escolher uma arquitetura muito simples que possa subestimar a complexidade do problema e, inversamente, uma

arquitetura muito complexa que apresente resultados bons para os exemplos fornecidos na fase de treinamento, mas com mau desempenho para novos exemplos, isto é, sem uma boa capacidade de generalização.

Alguns autores como Chow [1997] citam que o tipo de rede *feed forward* de três camadas (uma camada de entrada, uma escondida e outra de saída) é a mais utilizada por ser simples e tem provado ser capaz de processar funções complicadas com bons resultados. Considerando que a informação de uma RNA é armazenada nos valores dos pesos, em tese, quanto mais pesos, mais informação pode ser armazenada. Por outro lado, problemas também ocorrem quando há o aumento excessivo e desnecessário dos pesos. Para uma rede de três camadas, em geral varia-se o número de nós na camada escondida durante a fase de ajuste da rede, objetivando-se a melhoria do desempenho. No entanto, deve-se ter em mente que o tempo para treinamento deve aumentar com o incremento do número de neurônios.

3.5 PROCESSO DE TREINAMENTO

O ajuste dos pesos das conexões é chamado de aprendizagem da rede, e no caso de uma aprendizagem supervisionada consiste no seguinte procedimento:

- Apresentar à rede um conjunto de pontos (pares conhecidos de entradas e saídas desejadas);

- Minimizar uma função custo, usualmente baseada no erro entre a saída desejada e a saída da rede.

Do ponto de vista de aplicações é mais fácil visualizar uma rede neural artificial como um conjunto de processamento com capacidade de aprendizado para realizar um mapeamento entre as entradas e saídas de um sistema (CHOW, 1997). Esta capacidade pode ser utilizada para reconhecimento de padrões de vibração, por exemplo.

A entrada de uma rede neural pode ser um conjunto de dados do sistema sem nenhum processamento ou conjunto que represente alguma característica importante dos dados originais [DUIN, 2002].

Seja um sistema de diagnóstico de vibração qualquer que, dado uma entrada $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$, apresenta saídas codificadas correspondentes $\mathbf{y} = [y_1, y_2, \dots, y_m]^T$. Uma rede neural é agora ligada em paralelo com o sistema, permitindo-se que ela aprenda o relacionamento entre a entrada e a saída. A saída da rede neural é designada como $\hat{\mathbf{y}}(\mathbf{x}|\mathbf{w})$, que é um vetor estimado pela rede e pertencente ao conjunto de saída Y e função do vetor de entrada \mathbf{x} e parâmetro \mathbf{w} (vetor de pesos).

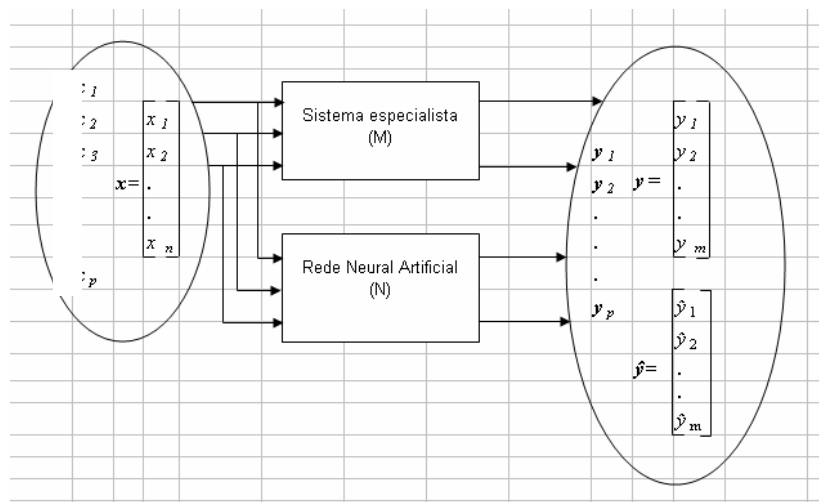


Figura 3. 6 - Sistema de diagnóstico e rede neural artificial

O treinamento da rede pode ser imaginado como um processo que irá aproximar tanto quanto possível (ou especificado) a saída estimada pela rede \hat{y} saída y do sistema que se quer representar. Este processo é feito ajustando-se gradualmente os pesos (w) até que a desempenho geral especificado seja atingido.

Durante o processo de aprendizagem dessa rede, costuma-se inicialmente dividir os dados disponíveis em dois conjuntos: um conjunto para treinamento (80 a 90% dos dados) [CHOW, 1997], o qual permite observar a aprendizagem da rede, e o conjunto de teste (dados restantes inéditos), que permite observar a capacidade de generalização da mesma.

A seguir, escolhe-se um critério para minimizar os erros entre os dados e a saída da rede. Este critério pode ser a soma dos quadrados dos erros, que penaliza os erros grandes e os erros freqüentes, ou pode ser a soma dos valores absolutos dos erros. Uma vez definido o critério, o objetivo da aprendizagem é obter os pesos da rede que minimizem este erro.

É importante que o conjunto de dados fornecidos à rede durante o processo de aprendizagem seja suficientemente rico de forma a cobrir, tanto quanto possível, todo o domínio

esperado da rede. É interessante observar que a necessidade de possuir um número suficiente de exemplos representativos do problema em questão não é uma limitação das redes neurais, mas também uma limitação dos métodos estatísticos.

Na etapa de treinamento várias entradas são apresentadas e propagadas pela rede neural. Uma vez propagadas as entradas, pode-se calcular as saídas. Obtidos os valores previstos pela rede neural, pode-se calcular o erro de previsão. Existem alguns métodos para se fazer a correção dos pesos, entre os quais se encontra o de Levenberg-Marquardt. O algoritmo de Levenberg-Marquardt é uma técnica iterativa para localização de mínimos locais de uma função [LOURAKIS; ARGIROUS, 2005]. Este algoritmo pode ser imaginado como uma combinação do método gradiente descendente e o método Gauss-Newton: quando a solução está longe do mínimo local, o Gauss-Newton é utilizado; quando se está próximo do mínimo local, o algoritmo utiliza o método de gradiente descendente. O algoritmo desenvolvido nesta pesquisa emprega a função de treinamento *trainlm* do Matlab que utiliza o método de Levenberg-Marquardt com retropropagação. A retropropagação significa que o processo de correção dos pesos é iniciado na última camada e prossegue em direção à primeira camada.

Alguns dos principais parâmetros que podem ser ajustados neste algoritmo no MATLAB são a quantidade de épocas (períodos de treinamento), valor alvo do erro, gradiente mínimo, fator de Marquardt, número de épocas mostradas.

3.6 ASPECTOS IMPORTANTES NO TREINAMENTO

Uma rede neural deve ter capacidade de generalização, o que significa ser capaz de prever com uma determinada acurácia a saída correta para um determinado conjunto de dados inéditos. O propósito do processo do treinamento é fazer com

que, na fase de validação, a rede forneça corretamente uma função de saída (em aplicações de regressão) ou classe (em aplicações de classificação) para entradas que não tenham sido apresentadas à RNA na fase de treinamento.

Embora possa ser aumentada a capacidade de armazenamento de informação de uma rede com o aumento do número de neurônios, é necessário cuidado na utilização deste recurso. Conforme citado por Cybenko (1989), o desempenho como função do número de neurônios na camada escondida só é efetiva se os dados usados para treinamento são estatisticamente representativos para o mapeamento. Do contrário, pode ocorrer o que chama de sobre-treinamento, o que provoca deterioração do desempenho da rede.

Este risco ocorre quando a rede “decora” a relação entre o conjunto de entradas e o conjunto de saídas, com isto ela perde a capacidade de generalização. Este problema pode ser visualizado mais claramente com as figuras a seguir.



Figura 3.7 - Classificação do conjunto de treinamento

Na figura 3.7 a rede foi treinada de modo a classificar corretamente todos os dados do conjunto de entrada. Quando apresentada a dados inéditos, ela irá cometer falhas de classificação devido a ter “memorizado” um padrão de classificação, conforme mostrado na figura 3.8. Este problema pode ocorrer devido basicamente a excesso de neurônios na camada escondida ou tempo excessivo de treinamento.




Figura 3. 8 - Classificação do conjunto de teste

Um outro problema, causado com o aumento do tamanho da rede é que ela pode acompanhar eventuais ruídos presentes nos dados.

Como mencionado no item 3.5, uma função de custo pode ser utilizada para avaliar o desempenho de uma RNA em uma determinada aplicação. Normalmente os parâmetros utilizados para esta função são: acurácia (inversamente proporcional a quantidade de erros), tempo de treinamento, robustez e número de neurônios (CHOW, 1997). O objetivo do treinamento é minimizar esta função de custo. Denominando E , o número de erros, T o tempo de treinamento, S a sensibilidade ou robustez, C o número de neurônios, n_h o número de neurônios na camada escondida, n_x o número de padrões de entrada, podem ser construídas as regras heurísticas a seguir (CHOW, 1997):

1. Se E ALTO então AUMENTAR MUITO n_h
2. Se T ALTO então REDUZIR MÉDIO n_x
ou
3. Se T ALTO então REDUZIR MÉDIO n_h
4. Se S ALTO então AUMENTAR MUITO n_x
5. Se C ALTO então REDUZIR MÉDIO n_x
ou
6. Se C ALTO então REDUZIR MÉDIO n_h

3.7 APLICAÇÕES DAS REDES NEURAIIS

As redes neurais são capazes de resolver problemas de aproximação, predição, classificação, categorização e otimização.

Problemas de aproximação de funções, ou regressão, são caracterizados pelo uso da interpolação, ou seja, dados são fornecidos dentro de determinados limites, onde a função é definida e o modelo neural é ajustado para dar uma boa aproximação da função, dentro desses limites.

O problema de predição visa à determinação de estados seguintes de um determinado sistema, baseados nos estados anteriores. Exemplos típicos são a previsão financeira, previsão do tempo e modelagem de sistemas dinâmicos.

Em problemas de classificação, que é o caso desta pesquisa, o objetivo é associar um padrão de entrada a uma classe entre um conjunto de classes conhecidas. Exemplos típicos de problemas de classificação são o reconhecimento de voz, de caracteres e de imagens faciais.

Outros exemplos citados na literatura são: visão computacional, classificação/análise de sinais de radar, reconhecimento por impressões digitais, análise de manuscritos, análise de eletrocardiograma e outros diagnósticos médicos.

4 RECONHECIMENTO DE PADRÕES

Reconhecimento de padrões é uma tarefa que causa pouca dificuldade para os seres humanos, contudo é um grande desafio para a tecnologia moderna.

Como citado por Reis, Albuquerque e Castro [1996]:

“há várias definições para o termo reconhecimento de padrões, porém aquela que mais o caracteriza foi dada por Duda e Hart (1973), como sendo o campo interessado no reconhecimento de regularidades significativas em ambientes ruidosos ou complexos, feito por máquinas, ou a procura por uma estrutura em dados”.

O processo envolve as seguintes etapas principais:

- a) **Extração** de características dos objetos a classificar (ou a descrever);
- b) **Seleção** das características mais representativas;
- c) **Construção** do sistema de classificação.

4.1 RECONHECIMENTO DE PADRÕES POR REDES NEURAI

São diversas as abordagens possíveis em reconhecimento de padrões. Duas delas podem ser consideradas como clássicas que são a estatística e a sintática. Outras duas, da área da Inteligência Artificial, são a que empregam redes neurais e a lógica difusa (*fuzzy logic*).

Como citado por Cera [2005], a eficiência de modelos estatísticos depende de um grande conjunto de suposições ou condições sobre as quais o modelo é construído. Para que o modelo seja empregado com sucesso, é necessário que os usuários possuam um bom conhecimento sobre as propriedades dos dados analisados e das capacidades do modelo. As redes neurais são uma boa alternativa para vários métodos de classificação convencionais, pois apresentam vantagens, como, por exemplo, serem adaptativas em função dos dados recebidos, sem a necessidade de qualquer especificação externa. As redes neurais também são modelos não lineares capazes de modelar com flexibilidade as complexas relações do modelo do mundo real.

Uma rede neural utilizada em sistemas de classificação pode também retornar valores que expressam o “grau de confiança” que a rede tem no resultado expresso pela saída. Isto faz com que a rede neural possa ser integrada com sistemas especialistas para diagnósticos mais confiáveis [HASHEM, 1997].

Neste trabalho, a proposta é utilizar redes neurais artificiais para a tarefa de reconhecimento de padrões associados a sinais de vibração em máquinas rotativas.

4.2 APLICAÇÕES SIMILARES

Uma das aplicações similares ao reconhecimento de padrão de vibração é o reconhecimento de voz. Assim como o sinal de

áudio, o sinal obtido pelos sensores de vibração é um sinal complexo que pode ser decomposto em sinais mais simples de intensidade e frequência características. A frequência é uma das mais importantes características utilizadas neste tipo de aplicação. O sinal de voz no domínio tempo é decomposto nos seus componentes de frequência.

É possível realizar este tipo de reconhecimento utilizando as Redes Neurais Artificiais, seguindo-se quatro passos básicos [HOSON; COLE; FANTY, 1999]. Primeiramente é feita a digitalização do sinal de voz. Em seguida efetua-se a transformação do sinal do domínio do tempo para o domínio da frequência usando-se a transformada de Fourier. Com isto obtêm-se características que representam o domínio espectral contido na fala (regiões de alta energia em frequências particulares). Esse passo é computado em intervalos regulares, onde cada seção é usualmente chamada de quadro. O terceiro passo consiste do uso de uma rede neural para realizar a classificação dos quadros em categorias fonéticas básicas. Por fim, no quarto passo aplica-se um método de busca para associar as saídas da rede neural com padrões de palavras a fim de encontrar a palavra com a qual as saídas da rede mais se assemelham.

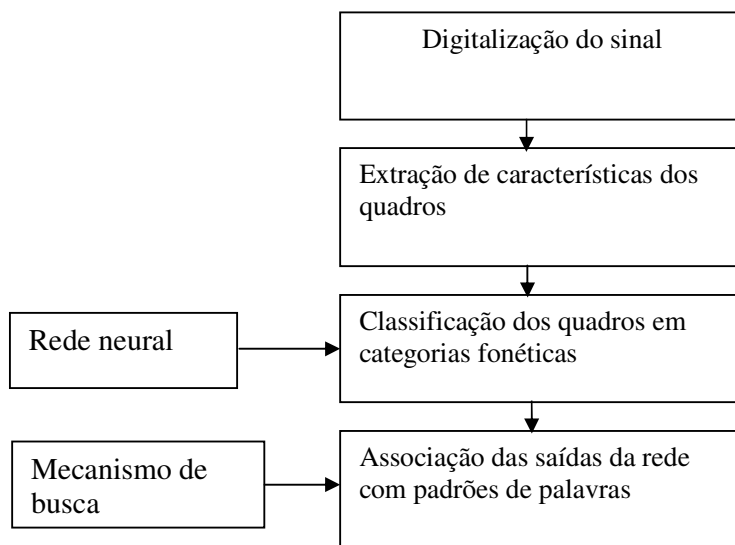


Figura 4.1 - Passos para o reconhecimento de voz

Como citado por Robinson [1998], dois problemas importantes para o reconhecimento de voz são: a) o sinal não é estacionário, ou seja, uma determinada configuração de componentes de frequência e amplitude só existirá por um curto período de tempo; b) é necessária a formulação de um vetor que capture a informação no sinal.

Uma outra aplicação das redes neurais artificiais é em diagnóstico de falhas em motores elétricos de indução. No exemplo descrito por Chow [1997], uma rede neural de três camadas do tipo *feed-forward* é usada para diagnosticar a condição do enrolamento e fricção de motores elétricos de indução monofásicos a partir de dados da corrente elétrica no estator e da velocidade de rotação.

5 VIBRAÇÕES EM MÁQUINAS ROTATIVAS

5.1 CONCEITOS

Condições tais como: instabilidade, desbalanceamento, desalinhamento, mudanças no ajuste, desgaste e até mesmo fadiga em seus componentes, geram vibrações específicas e características.

Considerando a vibração em uma máquina rotativa como a oscilação de uma massa (ou massas) em torno de um ponto de referência, podemos caracterizar esta vibração pelas três variáveis a seguir, conforme Marçal [2000]:

1. Deslocamento: é a distância do afastamento da massa de sua posição natural, medido em micrometros em aplicações em vibração conforme norma ISO 10816-1.

2. Velocidade: é a derivada do deslocamento da massa com relação ao tempo, medida em mm/s.

3. Aceleração: é a derivada da velocidade com relação ao tempo, medida em mm/s^2 .

Pode ser demonstrado que a velocidade da vibração para qualquer frequência é proporcional ao deslocamento vezes a frequência (equação 2.2), e a aceleração é proporcional ao produto da velocidade vezes a frequência, ou o deslocamento vezes a frequência ao quadrado (equação 2.3). Deste fato

resulta que a medida de deslocamento ou velocidade é usada em baixas frequências (desbalanceamento, desalinhamento, etc.) e as de aceleração em altas frequências, como no caso em que o interesse está em problemas com rolamentos.

Em máquinas reais, quando em operação, não são encontrados movimentos harmônico simples como da figura 2.2, mas sim sinais de vibração complexos como a da figura a seguir:

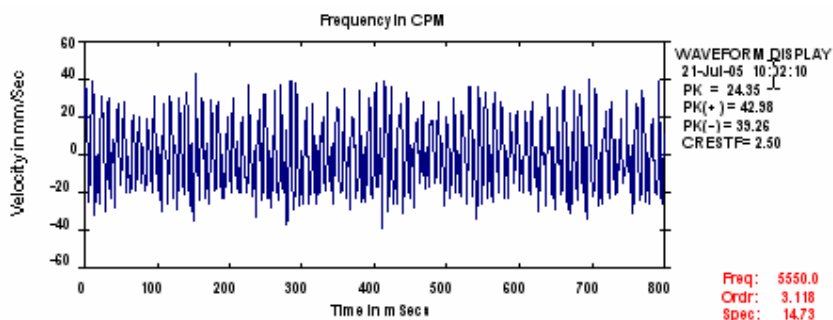


Figura 5. 1 - Registro de vibração em uma máquina rotativa

Conforme mencionado anteriormente, pode-se decompor este sinal complexo em uma série de funções harmônicas simples de frequências múltiplas de uma frequência denominada fundamental, utilizando a transformada de Fourier. A figura a seguir mostra do registro de vibração da figura 5.1 agora apresentado no domínio frequência após a utilização do algoritmo FFT.

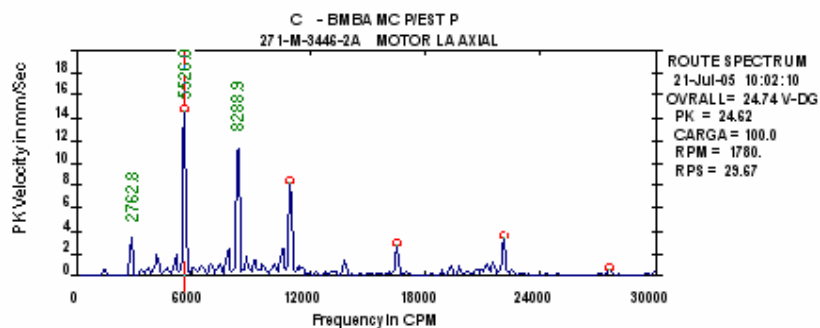


Figura 5. 2 - Espectro em freqüência [fonte Tecvib]

Observa-se que a análise deste registro fica agora mais fácil, reconhecendo-se amplitudes elevadas nas segundas e terceira harmônicas (5.526,8 e 8.288,9 ciclos/minuto).

Uma máquina, caracterizada por suas partes móveis vibrará de acordo com as freqüências características dos seus componentes. Cada tipo de máquina possui uma “ASSINATURA ESPECTRAL ORIGINAL” que pode ser obtida quando o equipamento é novo e considerando que todos os cuidados de instalação foram tomados. No momento em que um ou mais componentes comecem a falhar, a freqüência e amplitude da vibração começarão a mudar.

O sinal da figura 5.1 é resultante de esforços dinâmicos na estrutura da máquina e é a soma de diversos sinais vibratórios cuja freqüência é idêntica àquelas dos esforços que os tenham provocado; a medida global tomada em algum ponto é a soma das respostas vibratórias da estrutura aos diferentes esforços excitadores [WANG, 1995].

Com sensores colocados em pontos particulares, pode-se registrar as vibrações transmitidas pela estrutura à máquina

e, através de análise, identificar a origem dos esforços aos quais ela está submetida [MIRSHAWAKA, 1991]. O monitoramento da vibração provê informações sobre o comportamento macroscópico dentro da máquina [PRICE, 2001].

A premissa fundamental sobre a qual se baseia a análise de vibração como técnica aplicada à manutenção industrial é: cada componente ou cada tipo de deficiência mecânica de uma máquina em operação produz uma vibração de frequência específica que em condições normais de funcionamento, alcança uma amplitude máxima determinada [MARÇAL, 2000]. Considerando que a deterioração do equipamento traduz-se por uma modificação na distribuição da energia vibratória, e que sua consequência mais freqüente é o aumento do nível de vibração, pode-se, a partir da tomada do sinal vibratório em pontos determinados do equipamento, acompanhar a evolução desses sinais e identificar o aparecimento de esforços dinâmicos novos ou o aumento abrupto da amplitude da vibração. Mudanças no comportamento espectral são indicadores do surgimento de possíveis defeitos ou degradação do funcionamento.

Desta forma, medindo e analisando o desvio da amplitude da vibração em frequências específicas em relação ao padrão normal e, baseando-se em conhecimento de especialistas, é possível estabelecer com certa segurança a origem e a gravidade da falha.

Tal abordagem é possível quando se tem registros anteriores de vibração da máquina, o que nem sempre é

disponível. Neste caso o que pode ser feito é comparar os dados da máquina em análise com padrões de referência de equipamentos semelhantes.

Existem limites estabelecidos em normas técnicas que definem faixas de valores de vibração aceitáveis para categorias de máquina. Por exemplo, as normas ISO-2372 e VDI-2056 definem faixas em função do tamanho e tipo de fixação da máquina. Essas normas trabalham com recomendações de valores em unidades de velocidade (ex. V_{rms} (mm/s)) ou de deslocamento (V_{pico} (μm)).

Tabela 5.1 – Tabela de classificação segundo a ISO 2372

NÍVEL	CLASSIFICAÇÃO DOS EQUIPAMENTOS			
	CLASSE I	CLASSE II	CLASSE III	CLASSE IV
	Até 15 KW (20 CV)	15 A 75 KW (20 - 100 CV)	Acima de 75 KW base rígida	Acima de 75 KW base flexível
VALOR RMS DA VELOCIDADE DE VIBRAÇÃO (mm/s).				
A - Bom	até 0,71	até 1,12	até 1,8	até 2,8
B - Satisfatório	0,71 a 1,8	1,12 a 2,8	1,8 a 4,5	2,8 a 7,1
C - Insatisfatório	1,8 a 4,5	2,8 a 7,1	4,5 a 11,2	7,1 a 18,0
D - Inaceitável	Acima de 4,5	acima de 7,1	acima de 11,2	acima de 18,0

A medição de vibração de nível global utiliza instrumentos capazes de medir o valor total de vibração (pico ou rms), em uma extensa faixa de frequência, que depende das normas e padrões aplicáveis. Estes instrumentos medem a vibração total resultante da ação de todas as frequências presentes no sinal de vibração, dentro da faixa considerada. As medições são comparadas com padrões gerais (normas) ou valores de

referências estabelecidos para cada máquina através de estudos de registros de vibração anteriores.

Esta metodologia segue os seguintes passos: a) transformação do sinal de vibração do domínio tempo para o domínio freqüência; b) análise do espectro de freqüência para identificar a causa da vibração; c) medição de amplitudes para avaliar a severidade da vibração e, conseqüentemente o funcionamento normal ou anormal do sistema.

O conhecimento da freqüência permite identificar o componente da máquina ou a natureza da falha que produz a vibração. A medição da amplitude permite avaliar, por comparação com valores limites previamente estabelecidos, se a vibração corresponde a um funcionamento normal ou anormal e o grau de importância da falha detectada.

Diferente do sinal de voz, a vibração em máquinas rotativas geralmente produz registros estacionários por um período de tempo bem mais longo, o que facilita, neste aspecto, o estudo com a transformada de Fourier.

Neste trabalho, com base em conhecimento adquirido com especialistas¹ da área e os exemplos obtidos, utilizou-se a tabela 5.1 para caracterizar os sinais de vibração e auxiliar a classificação dos tipos de defeito para fins de treinamento da rede.

¹ Os especialistas consultados para este trabalho foram: 1) Charles Mattos, Engenheiro Mecânico, Mestre em Ciências Mecânicas pela COPPE/UF RJ e sócio-gerente da TECVIB Engenharia, empresa especializada em análise de vibração em máquinas rotativas. 2) Emerson Carlos Assunção Sanches, Engenheiro Mecânico e Mestre em Mecatrônica pela UFBA, especializado em equipamentos rotativos e análise de vibração, com 29 anos de experiência na área.

Tabela 5.2 - Classificação prática [fonte: Tecvib]

CLASSIFICAÇÃO	AMPLITUDE (mm/s - pico)
Excelente	Até 1,07
Bom	de 1,08 até 2,14
Aceitável	de 2,15 até 5,0
Alerta	de 5,1 até 10,7
Inaceitável	acima de 10,7

Segundo YA'CUBSOHN [1983 *apud* MARÇAL, 2000], pode-se dividir as falhas em duas classes genéricas: as de baixa frequência (ex: desbalanceamento, desalinhamento) e as de alta frequência (ex: rolamentos deteriorados falta de lubrificação, etc.). Já os defeitos causados por problemas de engrenamento estão associados à componentes de média frequência . Por este método, entretanto, não basta medir a frequência de cada um dos componentes da vibração para identificar a falha. Uma vez conhecido o valor absoluto, deve-se relacionar a frequência com a velocidade de giro do eixo. Portanto, nos métodos clássicos, o conhecimento da velocidade de rotação do eixo ou do sistema rotativo, em questão, se torna necessário para o diagnóstico de falhas.

Os sinais de vibração são captados através de sensores denominados transdutores. Os principais transdutores utilizados são: Transdutores de Deslocamento Relativo ou de Proximidade, Transdutores Sísmicos e Acelerômetros Piezo elétricos.

Com o uso de acelerômetros, o usuário tem opção para escolher entre aceleração, velocidade ou deslocamento como parâmetro de medida, bastando para isso realizar a integração desses sinais. Em sistemas de medição com acelerômetros, o medidor de vibração ou pré-amplificador associado já inclui circuitos de integração, tal que os parâmetros de medida, tanto aceleração, velocidade ou deslocamento, possam ser escolhidos simplesmente através de acionamento de uma simples chave.

5.2 PADRÕES DE VIBRAÇÃO

Dentre as diversas fontes de vibração aquelas mais comuns são:

- Desbalanceamento;
- Desalinhamento (Eixos/Correias/Correntes);
- Folgas Generalizadas;
- Dentes de Engrenagens;
- Rolamentos;
- Corrente Elétrica;
- Campo Elétrico Desequilibrado;
- Outros.

Entre essas fontes, o desbalanceamento, o desalinhamento, as folgas e dentes de engrenagem são considerados como causas

de vibração de baixa frequência e os picos de amplitude aparecem em múltiplos da velocidade desenvolvida pelo rotor. Os rolamentos defeituosos provocam vibração considerada de alta frequência.

Os picos que aparecem em frequências independentes da velocidade desenvolvida pelo rotor podem ser causados por vibração proveniente de máquinas vizinhas, vibrações de origem elétrica, ressonância de estruturas e eixos.

Desbalanceamento do rotor e desalinhamento do eixo são duas das principais fontes de vibração em máquinas rotativas [XU; MARANGONI, 1994].

Para este trabalho foram utilizados registros que se caracterizam por padrões de frequência próximos ao da rotação da máquina como os provenientes de problemas de desbalanceamento e desalinhamento.

O desbalanceamento é causado por uma distribuição de massas de um rotor não uniforme em relação a um eixo de inércia. Para o desbalanceamento o espectro de vibração se apresenta com uma amplitude acima da faixa aceitável no primeiro harmônico conforme figura a seguir:




Figura 5. 3 - Espectro em frequência típico de desbalanço

Já o desalinhamento ocorre quando o eixo da máquina acionada não está alinhado, dentro de uma faixa de tolerância especificada, com o eixo da máquina acionadora. O desalinhamento produz esforços que resultam em um espectro de frequência com amplitudes acima do aceitável no segundo e/ou terceiro harmônico.




Figura 5. 4 - Espectro em frequência típico de desalinhamento

O sinal de vibração em uma máquina em condições normais é caracterizado por amplitudes baixas que produzem espectros também de amplitudes baixas.

Como este trabalho está focado em problemas de desalinhamento e desbalanceamento que, como visto nas figuras 5.3 e 5.4, se caracterizam por amplitudes elevadas até o terceiro harmônico, o método desenvolvido utiliza as amplitudes dos três primeiros harmônicos como o vetor de características para a formação do vetor de entrada que é apresentado à rede.

6 TRATAMENTO DOS DADOS EXPERIMENTAIS

6.1 MÉTODO UTILIZADO

A abordagem utilizada é, em muitos aspectos, semelhante ao de reconhecimento de voz usando redes neurais descrito no item 4.2.

O sinal de vibração é coletado, digitalizado e transformado do domínio tempo para o domínio frequência. Em seguida extraem-se características de interesse do espectro de frequência gerado que são utilizadas para o treinamento de uma rede neural.

Os dados no domínio tempo foram obtidos de arquivos de sinais de vibração de diversas máquinas rotativas, lidos por um coletor de dados portátil². Esses arquivos contêm séries temporais de amplitudes de vibração.

O procedimento usual é trabalhar com apenas uma máquina ou um grupo de máquinas semelhantes, operando nas mesmas condições. Isto facilita a utilização das tabelas de classificação como a da figura 5.1 ou mesmo a utilização da assinatura espectral, conforme comentado no item 5.1. No caso deste estudo, devido à diversidade dos tipos de máquina, características e condições operacionais, houve necessidade de construir um sistema de classificação genérico, que se adequasse ao conjunto de registros disponíveis. Por outro

² A relação dessas máquinas encontra-se no Apêndice B.

lado, verifica-se que esta capacidade de generalização é uma das características importantes das redes neurais.

Após a amostragem do sinal em campo, os dados são descarregados em computador com software específico para análise de vibração. Pode se visto na figura 6.1 um desses registros já com tratamento efetuado pelo software, mostrando uma máquina com problema de desalinhamento. O primeiro gráfico é no domínio freqüência e o segundo no domínio tempo.

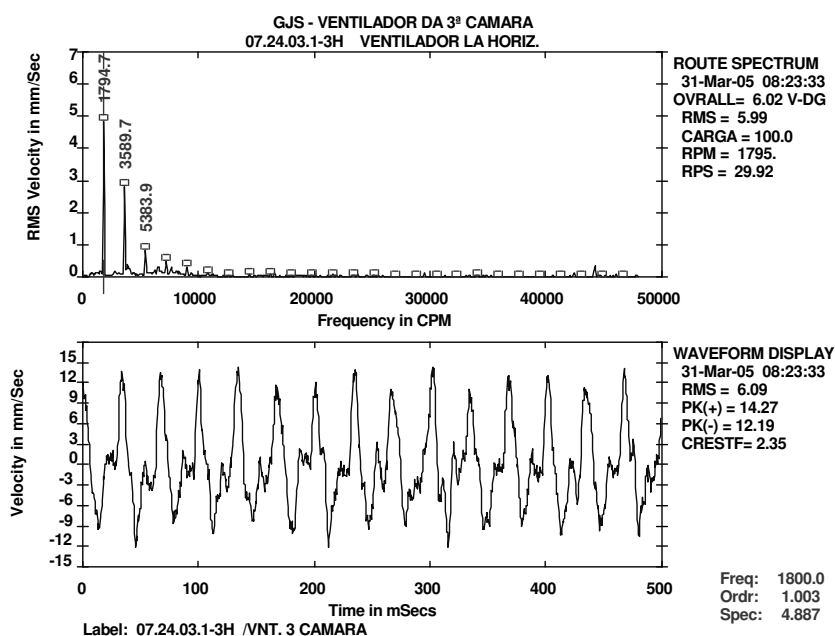


Figura 6. 1 - Espectro e sinal de vibração

O equipamento portátil coleta a amplitude da vibração em um ponto específico da máquina a intervalos regulares de 0,781 milisegundos.

Pode-se verificar que o sinal de vibração no domínio do tempo é um sinal periódico, o que permite a análise de freqüências usando as séries de Fourier.

O sensor utilizado é um acelerômetro de 100 mV/g de sensibilidade, faixa de frequência 0,43 a 13 kHz, resolução de 75 μ g, modelo 603Cx1 da IMI Sensors.



Figura 6. 2 - Sensor de vibração

O coletor de dados portátil é um coletor de dois canais modelo CSI 2120 da Emerson Electric Co..



Figura 6. 3 - Coletor de dados

Os dados obtidos pelo coletor são tratados pelo software RBMware, desenvolvido para trabalhar com dados de vibração, termografia de infravermelho, ultrassom, alinhamento a laser, análise de óleo. Este software armazena os dados em arquivos tipo texto, apresentando os dados das amplitudes versus tempo, gera sinais no domínio tempo ou no domínio frequência, entre outras funções. Neste trabalho foram utilizados os arquivos

textos gerados por este software, conforme a figura 6.4, para serem processados pelo MATLAB.

Waveform Amplitudes

Maquina: (B) BOMBA MC P/TANQUE DE MASSA
Meas. Point: 204-M-3022-5H --> BOMBA LA HORIZ./VEL.
Date/Time: 09-May-05 14:17:24 Amplitude: Velocity in mm/Sec

Time (mS)	Amplitude	Time (mS)	Amplitude	Time (mS)	Amplitude	Time (mS)	Amplitude
0.	7.697	200.0	10.85	400.0	18.35	600.0	3.355
.781	11.05	200.8	8.486	400.8	17.96	600.8	1.579
1.562	11.45	201.6	5.131	401.6	17.37	601.6	-2.763
2.344	8.486	202.3	.197	402.3	17.37	602.3	-5.131
3.125	3.158	203.1	-4.342	403.1	15.79	603.1	-5.526
3.906	-.987	203.9	-9.473	403.9	11.84	603.9	-5.921
4.687	-1.974	204.7	-13.62	404.7	6.908	604.7	-7.500
5.469	-1.974	205.5	-15.99	405.5	2.368	605.5	-8.486
6.250	-3.947	206.2	-17.17	406.2	-1.184	606.2	-6.710
7.031	-6.513	207.0	-17.37	407.0	-3.158	607.0	-5.131
7.812	-4.737	207.8	-16.97	407.8	-4.737	607.8	-6.118
8.594	-.592	208.6	-15.00	408.6	-5.723	608.6	-5.131
9.375	1.974	209.4	-12.24	409.4	-5.723	609.4	-.987
10.16	1.974	210.2	-10.85	410.1	-5.526	610.1	1.579
10.94	1.382	210.9	-8.684	410.9	-4.342	610.9	.395
11.72	4.145	211.7	-3.158	411.7	-3.750	611.7	0.
12.50	8.092	212.5	2.960	412.5	-4.934	612.5	3.158
13.28	10.07	213.3	5.723	413.3	-5.131	613.3	7.894
14.06	9.868	214.1	7.697	414.1	-5.329	614.1	10.07
14.84	9.473	214.8	11.25	414.8	-4.539	614.8	8.289
15.62	9.276	215.6	15.79	415.6	-5.723	615.6	8.684
16.41	4.737	216.4	19.34	416.4	-9.276	616.4	12.24
17.19	-2.368	217.2	19.14	417.2	-8.289	617.2	15.20

Figura 6. 4 - Exemplo de registro utilizado

6.2 TRANSFORMAÇÃO PARA O DOMÍNIO FREQUENCIA

Em primeiro lugar é necessário exportar os dados do registro em arquivo texto para o ambiente do Matlab. Após a captura e tratamento dos dados, a obtenção do espectro em frequência passa a ser uma aplicação direta do algoritmo FFT (*Fast Fourier Transform*) disponível no Matlab.

Uma das características de interesse é frequência fundamental. Embora este dado possa ser obtido *a priori* durante a medição da vibração verificando-se a rotação da máquina, optou-se por descobrir este valor no próprio registro já que a FFT do Matlab não indica diretamente a frequência, mas sim o número da amostra. Conforme explicado no item 2.8, é necessário calcular a frequência de amostragem e multiplicar esta frequência por um fator que a relacione com o número da amostra. Este valor pode diferir um pouco da rotação real da máquina em função do número de amostras ser finito, o que sugere uma pequena imprecisão. Por outro lado, considerando a característica de generalização das redes neurais artificiais, admite-se que tal imprecisão não compromete o resultado.

Em cada registro foram utilizadas 1024 amostras do sinal para que a FFT pudesse ser utilizada convenientemente, conforme observado no item 2.7.

Para ser gerado um espectro de frequência compatível aos dados utilizados, é necessário o ajuste do valor do módulo calculado pela FFT, conforme visto no item 2.8.

Com a finalidade de se comparar o espectro de frequência gerado pelo algoritmo desenvolvido e pelo software RBM, as figuras 6.5 e 6.6 a seguir mostram um exemplo comparativo, caracterizando a coerência necessária para a aplicação proposta.

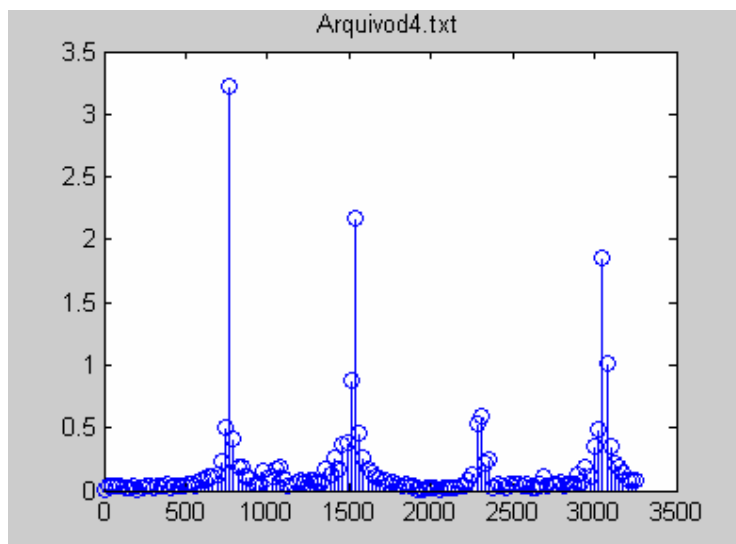


Figura 6. 5 - Espectro gerado pelo Matlab

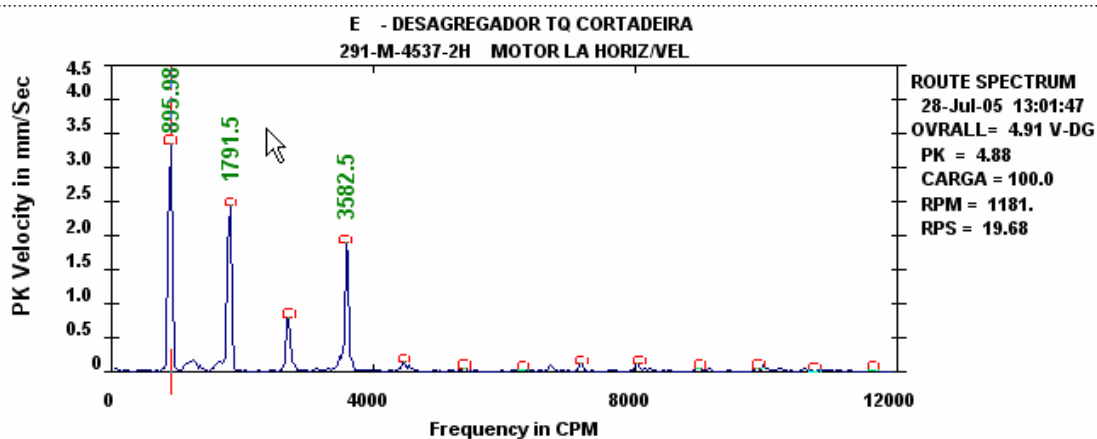


Figura 6. 6 - Espectro gerado pelo software comercial

6.3 EXTRAÇÃO DAS CARACTERÍSTICAS DE INTERESSE

A primeira abordagem utilizada foi semelhante à adotada por Pietrobon (2000) para reconhecimento de voz: o espectro de frequência de cada registro é dividido em faixas, por exemplo, 50 Hz, e calcula-se a amplitude média de cada faixa com o objetivo de analisar a densidade espectral. Em seguida forma-se um vetor com os valores dessas amplitudes médias e que compõe o vetor de entrada para treinamento de uma rede neural.

Observar ainda que, considerando sinais de voz limitados a 4KHz (padrão da telefonia), a dimensão deste vetor de entrada seria de 80 (4000Hz em blocos de 50Hz).

Além de representar dimensões elevadas para o vetor de entrada, o que usualmente associa RNAs de maior complexidade, experimentos realizados para o reconhecimento de padrões de vibração demonstraram que a aplicação deste método resulta em um baixo índice de acerto, não compatível para as necessidades de diagnóstico em um ambiente industrial.

Uma vez caracterizadas algumas restrições associadas a abordagens convencionais, o trabalho foi direcionado a buscar uma aproximação com a prática adotada pelos especialistas para diagnóstico de vibração. Constata-se que de uma forma geral, tais especialistas, para procederem o diagnóstico, identificam as amplitudes que estão acima de valores tabelados, relacionando-as com os harmônicos onde elas ocorrem.

Como o âmbito deste trabalho é limitado a problemas de desbalanceamento e desalinhamento, onde as amplitudes características de defeito ocorrem em baixas frequências, o método proposto utiliza informações de amplitude referentes apenas aos três primeiros harmônicos. Assim sendo, o vetor de entrada para a RNA terá dimensão de apenas 3, o que também reduz a complexidade e favorece o bom desempenho de uma rede neural.

6.4 ENTRADAS E SAÍDAS DA REDE

O vetor de características é a entrada da rede a ser treinada e o vetor de saída é um código para cada tipo de padrão de classificação de vibração.

O vetor de entrada é formado pelas amplitudes dos harmônicos 1, 2 e 3, obtidas do espectro gerado. Como exemplo, para o espectro em frequência ilustrado na figura 6.7, o vetor de entrada é $\mathbf{x} = [3 \ 12 \ 9]$.

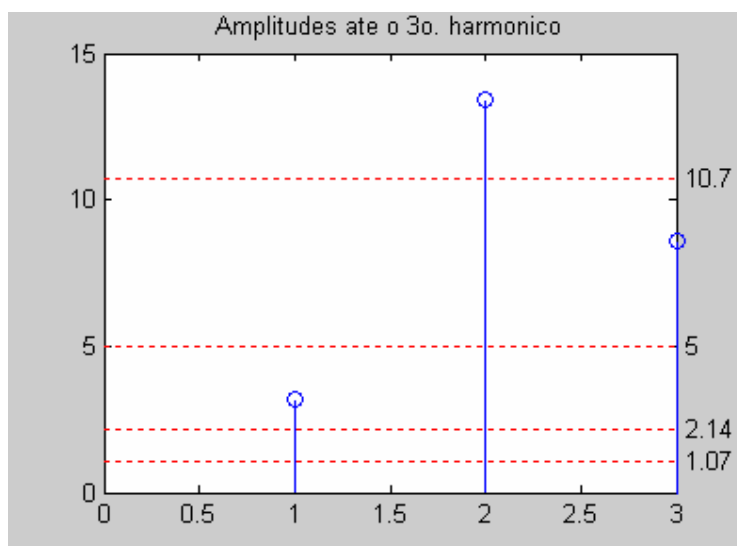


Figura 6. 7 - Amplitudes até o 3º harmônico

São utilizados registros de vibração de máquina em estado normal, com desbalanceamento e com desalinhamento. O código para classificação (vetor de saída) dos registros foi definido como:

- 1) Normal: [1 0 0 0]
- 2) Desalinhamento: [0 1 0 0]

3) Desbalanceamento: [0 0 1 0]

4) Desbalanceamento associado com Desalinhamento [0 0 0 1]

6.5 CLASSIFICAÇÃO E TRATAMENTO DOS DADOS

Os diversos registros de vibração coletados (199 no total) foram classificados de acordo com o tipo de defeito, com ajuda de especialistas em vibração. Assim, é possível associar arquivos específicos aos respectivos diagnósticos. Para efeito de classificação, as categorias definidas foram: Normal, Desbalanceamento, Desalinhamento e Desbalanceamento associado com Desalinhamento.

O algoritmo para extração dos dados e processamento com o Matlab é mostrado no Apêndice A.

Para verificar se os espectros gerados pelo programa desenvolvido estavam de acordo com os espectros gerados pelo software RBM e não ocorreram problemas devido às limitações da FFT mencionadas no item 2.7, foi feita uma comparação com alguns exemplos.

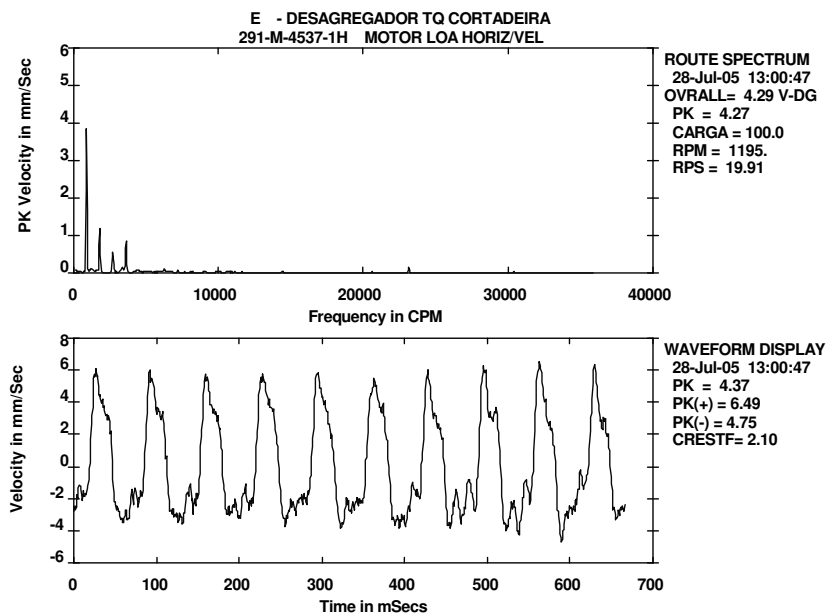


Figura 6. 8 - Espectro e sinal processados pelo software RBM




Figura 6. 9 - Espectro e sinal no tempo processados pelo MATLAB

Verifica-se uma boa concordância entre os dois registros.

Uma vez determinado o espectro do sinal amostrado, é determinada a amplitude da velocidade de vibração em mm/s para o primeiro, segundo e terceiro harmônicos. Tais amplitudes compõem o vetor de entrada que é apresentado à rede.

Com base nos registros adquiridos, tal abordagem oferece 200 pares de entrada/saída conhecidos e que podem ser utilizados para o treinamento/validação da RNA.

6.6 ARQUITETURA DA REDE E ALGORITMO DE TREINAMENTO

Conforme visto no capítulo 3, é necessário configurar a rede com o número de camadas, o número de neurônios por camada e do tipo de função de ativação. Na seqüência, é necessário definir um algoritmo de treinamento. As ferramentas oferecidas pelo Matlab podem ser utilizadas para criação da rede, treinamento e teste.

Neste estudo, utiliza-se a RNA do tipo *feed-forward* com uma única camada escondida, por ser uma estrutura muito popular e eficaz [CHOW, 1997], conforme mencionado no item 3.2. A rede foi configurada com 3 neurônios de entrada, já que o vetor de entrada possui 3 elementos correspondentes aos três primeiros harmônicos, e 4 neurônios com função de ativação linear na camada de saída, já que o código de classificação possui 4 elementos, conforme item 6.4. Variou-se o número de neurônios da camada escondida de modo a se obter melhor desempenho da rede (índice de acerto e rapidez no treinamento), como será visto no capítulo 7. Da mesma forma, foram testadas as funções de ativação logarítmica sigmoidal e tangente sigmoidal na camada intermediária. O algoritmo de treinamento utilizado foi o de Levenberg-Marquardt.

6.7 TREINAMENTO DA REDE

Conforme item 3.5, a prática usual é separar parte dos exemplos disponíveis para treinamento e a parte restante para o teste da rede. Por outro lado, é também usual que, em casos práticos, pouca informação esteja disponível. Assim, neste trabalho, opta-se por gerar exemplos artificiais, com base no conhecimento extraído dos especialistas e nas referências, de tal modo que os 200 registros reais sejam utilizados exclusivamente para o processo de validação da RNA. Isto apresenta duas vantagens: a) não se reduz a quantidade de exemplos disponíveis que são utilizados na fase de teste; b) a quantidade de exemplos gerados pode ser em qualquer número para se obter um bom desempenho da rede. Os vetores que compõem a matriz de entrada são gerados aleatoriamente e classificados por um algoritmo desenvolvido para separar os vetores em classes. O código em Matlab desenvolvido para este algoritmo é destacado a seguir, onde n é o número de exemplos artificiais à serem criados e L é um limite definido pelos especialistas para separação das classes:

```

% geração das matrizes de entrada e saída para treinamento
yn=[1 0 0 0 ]'; % saída para a classe Normal
yd=[0 1 0 0]'; % saída para a classe Desalinhamento
yu=[0 0 1 0]'; % saída para a classe Desbalanceamento
yud=[0 0 0 1]'; % saída para a classe Desbal.com Desalinhamento
X=10*rand(3,n); % geração aleatoria dos vetores de entrada
Y=zeros(4,n); % inicialização da matriz de saída
for i = 1:n
    if      (X(1,i)<=L & X(2,i)<=L & X(3,i)<=L) Y(:,i)=yn; % Normal
    elseif (X(1,i)<=L & X(2,i)<=L & X(3,i)> L) Y(:,i)=yd; % Desalinhamento
    elseif (X(1,i)<=L & X(2,i)> L & X(3,i)<=L) Y(:,i)=yd; % Desalinhamento
    elseif (X(1,i)<=L & X(2,i)> L & X(3,i)> L) Y(:,i)=yd; % Desalinhamento
    elseif (X(1,i)> L & X(2,i)<=L & X(3,i)<=L) Y(:,i)=yu; % Desbalanc_
    else   Y(:,i)=yud; % Desbalanceamento e Desalinhamento
end

```

Figura 6. 10 - Algoritmo p/ geração das matrizes de entrada e saída para o treinamento

Uma outra vantagem adicional deste método é tornar o sistema flexível para se adequar aos limites definidos para classificação da severidade dos problemas de vibração, já que estes podem variar de empresa por empresa ou tipo de aplicação das máquinas. Basta para isto mudar o limite de classificação de classe (L) no algoritmo ou acrescentar diferentes condições de classificação.

Deve-se ressaltar aqui que o conjunto de códigos mostrado na figura 6.10 constitui uma representação do conhecimento

obtido com os especialistas em vibração, traduzida para o MATLAB.

Após a formação dos pares de entrada/saída, a rede é treinada com a função *TRAIN* do Matlab. Este comando é simplesmente:

```
net = train(net,X,Y);
```

onde X é matriz de entrada e Y a matriz de saída com os valores alvo.

Seguindo a recomendação citada no item 3.5, foi adotado o mínimo de 800 exemplos para treinamento, já que o número de registros reais disponíveis era da ordem de 200.

6.8 TESTE DA REDE

Nesta fase são utilizados os registros reais de vibração.

Os 200 registros são identificados em classes de defeito ou normalidade, de acordo com o diagnóstico dos especialistas. Os registros dentro de uma classe recebem um código de acordo com o tipo de defeito e numeração seqüencial para possibilitar a leitura e associação com o tipo de saída desejada.

Com base na tabela 5.2, obtida com especialistas da área, o valor limite para classificação das classes entre Normal e Defeito (Desbalanceamento e Desalinhamento) no algoritmo foi definido como 5,1. Como citado, este valor pode ser ajustado de acordo com as características das máquinas que estão sendo analisadas ou em função da alteração de padrões de aceitação.

Para cada registro é lida a seqüência temporal de amplitudes de vibração para obtenção do respectivo sinal no domínio da freqüência através da função *FFT disponível no Matlab*. Este comando gera uma seqüência discreta de tamanho especificado com os valores calculados pela Transformada Rápida de Fourier. Para extração dos três primeiros harmônicos para a formação dos vetores compõem a matriz de entrada, foi desenvolvido um algoritmo que lê a rotação nominal inserido em cada registro e reconhece a amplitude do harmônico em uma faixa da série gerada pela Transformada Rápida de Fourier. Este algoritmo é mostrado a seguir, onde *F* é a seqüência gerada pela função FFT, *ih* é a posição (índice do vetor) da rotação nominal e *d1* é uma margem de tolerância para procurar a posição dos harmônicos no vetor.

```

%=====EXTRATOR DE PRIMEIROS HARMONICOS=====
Z=[max(F(ih-d1:ih+d1));max(F((ih*2)-d1:(ih*2)+d1));max(F((ih*3)-
d1:(ih*3)+d1))]; % procura amplitude máxima em torno dos harmônicos.

```

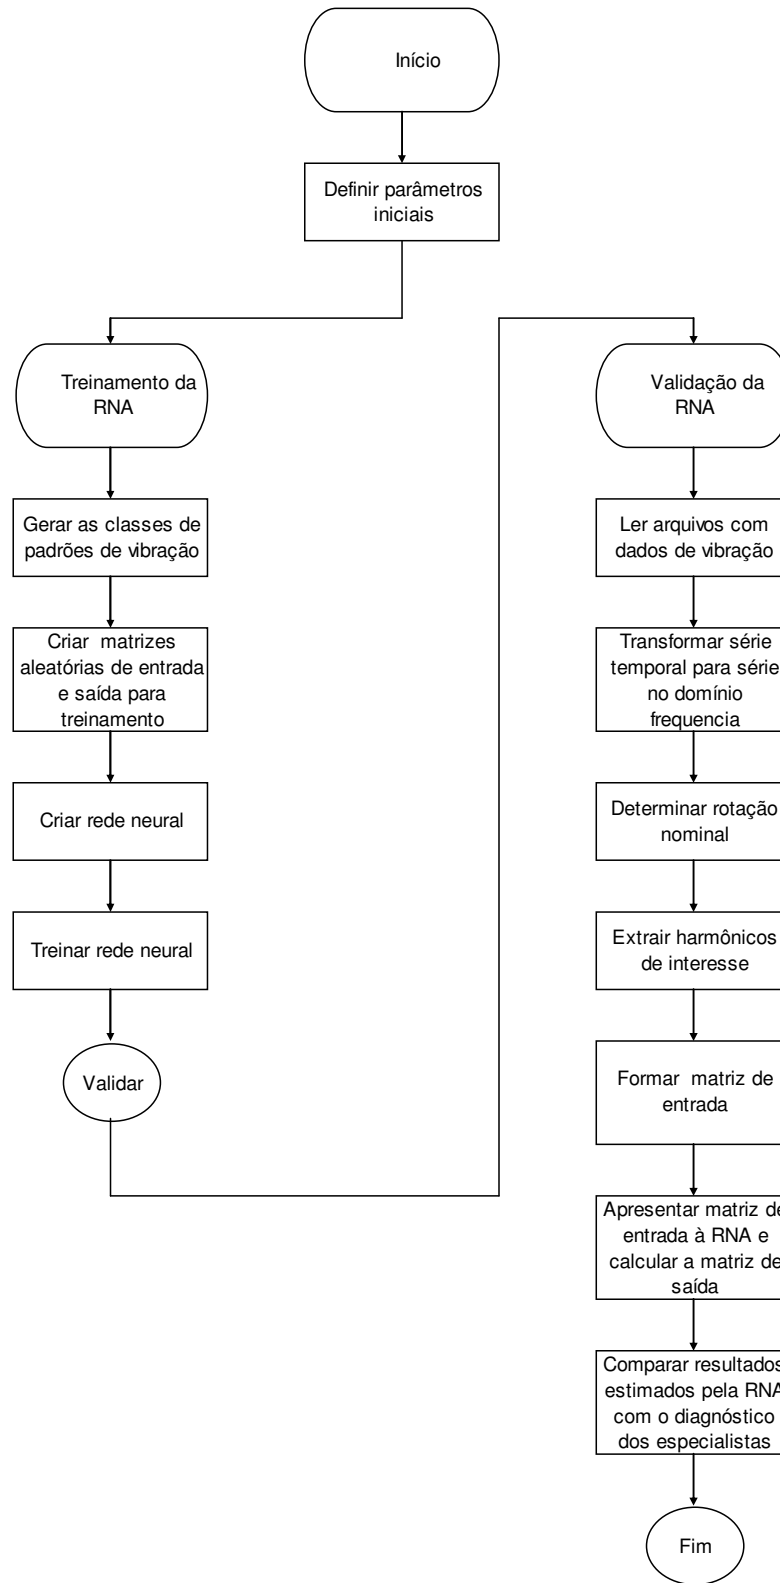
Figura 6. 11 - Algoritmo p/ extração dos três primeiros harmônicos

Como resultado, *Z* é o vetor com os três primeiros harmônicos que será incorporado à matriz de entrada e associa cada registro lido. A matriz de entrada, com dados reais, inéditos para a RNA, é então processada pela rede.

Para cada vetor de entrada, uma saída é estimada. Esta saída, cujos valores podem variar entre -1 e 1, é primeiro arredondada para valores 0 ou 1 para permitir a comparação com a saída teórica que também apresenta valores 0 ou 1, conforme a codificação apresentada no item 6.4.

6.9 FLUXOGRAMA

O fluxograma do programa para leitura dos arquivos com os registros de vibração, geração das amplitudes no domínio frequência com a FFT, preparação dos vetores de entrada e saída para as redes neurais, criação, treinamento e teste da rede e apresentação dos resultados, é apresentado a seguir. O código do programa em MATLAB encontra-se no Apêndice A.



7 RESULTADOS

Como citado no item 6.8, após o treinamento, foram apresentados registros inéditos à rede no total de 200, previamente classificados por um especialista em vibração. Como a saída da função de ativação logarítmica sigmoideal se situa na faixa $[0 \ 1.0]$, ou seja, pode assumir qualquer valor contínuo neste intervalo, e os valores alvos são discretos (1 ou 0), foi necessário desenvolver um procedimento de discretização. Com o procedimento, por exemplo, um vetor de saída da rede igual a $[-0.0000 \ 0.0025 \ 0.9975 \ 0.0032]$, se transforma em um vetor $[0 \ 0 \ 1 \ 0]$ para efeito de comparação com o alvo $[0 \ 0 \ 1 \ 0]$.

Como citado no item 4.1, gerou-se também um “grau de confiança” da rede com os resultados da saída. Define-se esta variável como sendo a razão entre o maior valor de cada vetor de saída e a soma dos quatro componentes deste vetor. Continuando com o exemplo do parágrafo anterior, o maior valor entre os campos do vetor de saída foi de 0.9975 e a soma dos valores dos quatro componentes foi de 1.0032. Com isto o “grau de confiança” foi de $0.9975/1,0032$, ou seja, 0.9943, neste caso. Quanto mais próximo de 1, maior o grau de confiança.

Para testar o desempenho da rede e a validade das regras citadas no item 3.6, variou-se a quantidade de neurônios na camada escondida, mantendo-se constante o valor do parâmetro

de inicialização dos pesos (*seed*), verificando-se o efeito no índice de acerto. O resultado pode ser visto na figura 7.1.

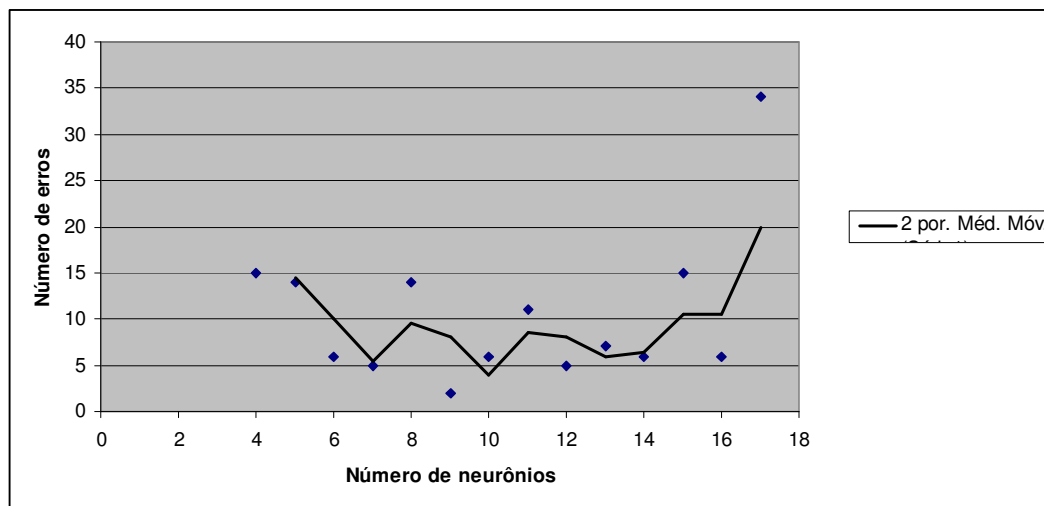


Figura 7. 1 - Efeito da variação do número de neurônios.

Verifica-se que o melhor resultado ocorreu com o número de neurônios igual a 9 na camada escondida. Neste caso o índice de acertos foi de 99 % (198 acertos em 200), o que pode ser considerado um resultado muito bom, especialmente se considerado que o treinamento foi realizado com dados artificiais para o reconhecimento de 200 casos reais.

A linha de tendência gerada sugere o efeito do sobre-treinamento (*overfitting*). Ao se aumentar o número de neurônios o índice de acerto melhora até certo ponto, depois começa a se deteriorar, como esperado.

Para analisar os erros no caso em que o sistema teve o melhor desempenho, com 9 neurônios na camada escondida, é reproduzida uma tabela que mostra os resultados. Esta tabela destaca os casos em que ocorreram divergências entre a classificação esperada e a classificação do sistema.

Tabela 7.1 . Resultados do sistema

Registro	saída teórica				saída rede				saída arredondada				Grau confiança	Obs.
UU30	0	0	1	0	-0.032	-0.032	0.348	0.653	0	0	0	1	0.653	ERRO
UD14	0	0	0	1	-1.857	1.853	2.510	-1.505	0	0	1	0	2.509	ERRO

É possível observar que, para o caso dos registros D4 e UD13, as divergências ocorreram devido a entrada da rede conter amplitudes de harmônicos que se situam no limite de classificação, o que também provocaria divergência entre especialistas humanos. Por exemplo, para o registro UU30, os três primeiros harmônicos são mostrados na figura 7.2 e o vetor de entrada é $Z = [19.419 \ 4.854 \ 3.6809]$. O segundo harmônico está bem próximo do valor 5, limite no critério adotado para mudança de classe. A classificação do especialista é Desbalanceamento, mas o sistema classificou como Desalinhamento associado a Desbalanceamento. Conforme análise detalhada, a classificação da RNA não é entendida como um erro. Pode-se verificar também que o sistema expressou um grau de confiança bem diferente de 1 nos dois casos o que, em uma situação real, serviria de alerta para o especialista responsável pelo diagnóstico final consultar outras informações e dar coerência aos resultados obtidos.

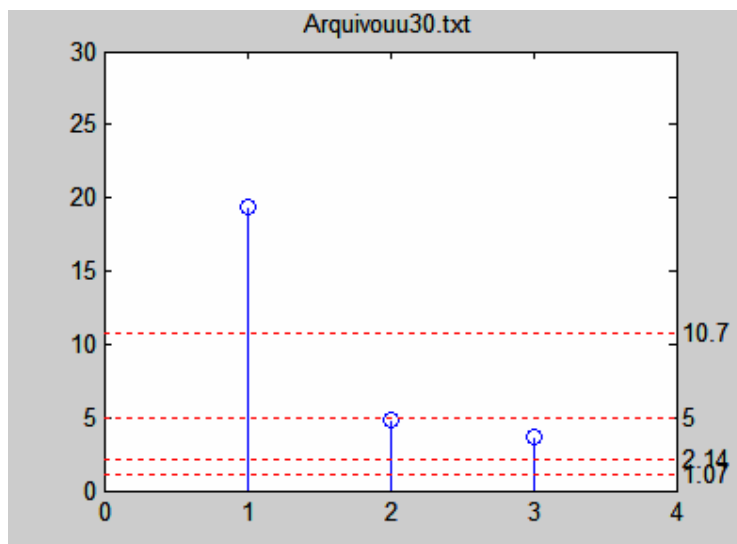


Figura 7. 2 - Harmônicos 1, 2 e 3 do espectro de D4

Para avaliar o desempenho do sistema como um todo, elaborou-se uma matriz de confusão, cruzando os resultados definidos pelos especialistas com os resultados obtidos pela RNA.

Tabela 7. 2. Comparação resultados esperados x resultados do sistema.

ESPECIAL. \RNA	Normal	Desalin.	Desbal.	Desb. + Desal.
Normal	99			
Desalinhamento		10		
Desbalanço			75	1
Desb. + Desal.			1	14

Observa-se que para o universo de testes (200 registros), há 100% de acerto na diferenciação entre equipamentos normais ou com problemas de vibração. O índice geral de acerto foi de 99%.

Para avaliar o efeito da inicialização dos pesos da rede no resultado do sistema, variou-se o valor do parâmetro *seed*

mantendo-se o número de neurônios igual a 9, onde ocorreu o melhor resultado. Isto é feito alterando-se o valor do argumento da função *seed* do Matlab, que associa a semente para a geração de números aleatórios. Com isto, os pesos da rede são gerados aleatoriamente, mas asseguram repetibilidade para cada valor do parâmetro de inicialização. Não foram verificados efeitos significativos no índice de acerto da RNA.

Também foram feitos vários experimentos variando-se o tipo da função de ativação na camada intermediária (tangente sigmoideal). Também não foram observados efeitos significativos no índice de acerto.

8 CONCLUSÃO

Foi desenvolvido um Sistema Baseado em Conhecimento para reconhecimento de padrões de vibração do tipo desbalanceo e desalinhamento, implementado no ambiente do MATLAB, com a utilização de redes neurais artificiais.

A este sistema são apresentados registros de vibração em arquivo texto, contendo uma seqüência temporal discretizada de amplitudes de vibração, obtidas de coletor de vibração portátil, conforme fluxograma do item 6.9.




Figura 8. 1 - Diagrama em blocos do sistema

Os melhores resultados alcançados foram obtidos com uma rede do tipo *feed-forward* com 4 entradas, 9 neurônios com função de ativação logarítmica sigmoideal na camada escondida e 4 saídas.

De acordo com o que foi citado no item 3.4., uma rede neural com uma única camada escondida pode aproximar qualquer função com qualquer grau de incerteza especificado, mas não é certo saber o número de neurônios necessários para isso, assim como, a possibilidade do treinamento convergir para mínimos locais não assegura encontrar uma matriz de pesos ótimos. No caso desta pesquisa, foram feitos vários experimentos na tentativa de encontrar um ajuste dos pesos que mostrasse que o sistema tem capacidade de generalização que permita utilizá-lo como um sistema de diagnóstico de vibração confiável para uso industrial.

Este problema parece estar associado muito mais a as dificuldades da representação do conhecimento do que às limitações das redes neurais. Como mencionado no item 3.5, a parte crítica é gerar exemplos suficientes para cobrir todo o domínio da aplicação e nesta parte, o mais difícil é traduzir para a linguagem do computador o conhecimento do especialista na classificação dos defeitos.

Por outro lado, como acontece atualmente com qualquer Sistema Baseado em Conhecimento, o sistema proposto e testado nesta pesquisa pode ser usado como uma ferramenta auxiliar para reconhecimento de padrões de vibração em máquinas rotativas, sem, no entanto, dispensar o conhecimento de um especialista na tomada de decisão. É importante verificar não só a classificação dada, como também o "grau de confiança" expresso pelo sistema. Além disso, trabalhou-se com exemplos de muitas máquinas em situações e processos diferentes. O sucesso obtido indica que o desempenho pode ser ainda melhorado para casos restritos a aplicação do sistema ao acompanhamento de uma máquina ou mesmo de um grupo de máquinas.

A abordagem adotada nesta pesquisa difere das abordagens usuais pela geração de exemplos artificiais para o treinamento e validação com dados reais. A geração de entradas artificiais resolve o problema muito comum em aplicações com redes neurais que é a necessidade de separar parte dos dados para o treinamento e utilizar os dados restantes para a validação. Em situações reais, muitas vezes não se consegue uma quantidade de exemplos suficientes para um bom treinamento da rede e com isto o processo de aprendizagem fica prejudicado. Além do mais, a validação fica restrita ao restante dos dados disponíveis o que pode prejudicar as conclusões sobre a capacidade de generalização da rede. Por outro lado, a validação com casos reais, ao invés de casos gerados em

laboratório, proporciona um teste mais próximo da realidade para o sistema.

Embora tenham sido utilizados apenas os três primeiros harmônicos para compor o vetor de entrada, devido às características de baixa frequência dos tipos de vibração considerados na pesquisa, o algoritmo de extração das amplitudes e formação do vetor de entrada não restringe este número e permite trabalhar com qualquer quantidade de harmônicos e em qualquer frequência. Com isto pode se estender facilmente o sistema para reconhecer outros padrões de vibração, como o causado por defeitos em rolamentos, que apresentam amplitudes elevadas em altas frequências.

O programa desenvolvido é bastante flexível, permitindo a geração de exemplos que representem o universo da aplicação, bastando para isto a criação de novas regras de classificação no algoritmo mostrado na figura 6.10.

O sistema conseguiu diferenciar corretamente os registros classificados como normais dos registros classificados com algum problema de vibração em 100% dos casos, e índice geral de acerto de 98%. Considerando-se que a validação foi feita com registros de vibração de diversas máquinas com características diferentes, o que dificulta a criação de regras de classificação para a fase de treinamento, pode-se considerar este resultado muito bom.

Por fim, como o código em linguagem computacional é aberto, este pode ser facilmente entendido, avaliado e aperfeiçoado, servindo de base para pesquisas futuras.

Como proposta de trabalho futuro, a metodologia deve ser aprimorada para gerar um equipamento protótipo para diagnóstico de vibração em máquinas rotativas em um ambiente industrial, incluindo outras classes de vibração não consideradas neste estudo como, por exemplo, os causados por problemas em engrenagens ou rolamentos. Como a classificação dos padrões de vibração realizada pelos especialistas emprega

critérios essencialmente vagos e imprecisos, deve-se também pesquisar a utilização da Lógica Fuzzy em combinação com a Rede Neural para auxiliar a formulação das regras de classificação para geração de exemplos de treinamento e avaliação do resultado final. Com isto espera-se alcançar um melhor desempenho do sistema pela incorporação das características típicas do raciocínio humano, o que é próprio da metodologia Fuzzy.

REFERÊNCIAS

- BO, L.I. *Neural-network-based motor rolling bearing fault diagnosis*. USA: IEEE Transactions on Industrial Electronics, vol. 47, no.5, 2000.
- BODRE, R. *Vibration book*. Washington, USA: DLI Engineering Corporation, 2003. Disponível em <<http://www.dliengineering.com/vibman.htm>>.
- BRAGA, A.P. *et al. Redes neurais artificiais*. In: REZENDE, S. *Sistemas inteligentes: fundamentos e aplicações*. São Paulo: Editora Manole, 2003.
- CERA, M.C. *Uso de redes neurais para o reconhecimento de padrões*. Rio Grande do Sul: UFRGS: Trabalho da disciplina Arquiteturas Especiais de Computadores, 2005.
- CHOW, M. *Methodologies of using neural network and fuzzy logic technologies for motor incipient fault detection*. USA: World Scientific Publishing Co. Ltd., 1997.
- CYBENKO, G. *Approximation by superpositions of a sigmoidal function*. In: *Mathematics of Control, Signals, and Systems*. Londres: Springer London, p. 303-314, 1989.
- GOLDMAN, S. *Vibration Spectrum Analysis a Practical Approach*. USA: Industrial Press Inc., 1999.
- GRALL, A. *et al. Continuous-Time Predictive-Maintenance Scheduling for a Deteriorating System*. In: *IEEE Transactions on Reliability*. USA: IEE Reliability Society, p. 141-150, vol. 51, 2002.
- HARTOG, J.D. *Vibrações nos sistemas mecânicos*. São Paulo: Ed. Edgard Blucher, 1972.
- HAYES, M.H. *Digital Signal Processing*. USA: McGraw-Hill, 1999.
- HAYT, W.; KEMMERLY, J. *Análise de circuitos em engenharia*. São Paulo: McGraw-Hill do Brasil, 1975.
- HINES, J. W. *Fuzzy and neural approaches in engineering*. MATLAB Supplement. USA: John Wiley and Sons, 1997.
- HOSOM, J.; COLE, R.; FANTY, M. *Speech recognition using neural networks*; USA: Center for Spoken Language Understanding, Oregon Graduate Institute of Science and Technology, 1999.
- ISO 10816-1. *Mechanical vibration - evaluation of machine vibration by measurements on non-rotating parts - part 1: General guidelines*. USA: International Standard Association, 1995.
- LOURAKIS, M.; ARGYROS, A. *Is Levenberg-Marquardt the most efficient optimization algorithm for implementing bundle*

adjustment?. Grécia: Institute of Computer Science, Foundation for Research and Technology ,2005.

MARÇAL, R. F. M. *Um método para detectar falhas incipientes em máquinas rotativas baseado em análise de vibração e Lógica Fuzzy*.2000. 124 f. Tese de Doutorado em Engenharia em Ciências dos Materiais e Instrumentação Eletro-Eletrônica - Universidade Federal do Rio Grande do Sul, Porto Alegre.

MASULI, F.; PARENT, R.; STUDER, L.; *Neural modeling of non-linear processes:relevance of the Takens-Mané theorem*. Itália: Istituto Nazionale per la Fisica della Matéria, 1998.

PIETROBOM, H. *Implementação de um sistema de reconhecimento de comandos de fala usando uma rede neural tipo feedforward com o algoritmo back-propagation*. Relatório do projeto final da disciplina Inteligência Artificial em Controle e Automação. São Paulo: Instituto Tecnológico da Aeronáutica, 2000.

REIS, C. ALBUQUERQUE, M; CASTRO, S.; *Introdução ao reconhecimento de padrões utilizando redes neurais*. Rio de Janeiro: Centro Brasileiro de Pesquisas Físicas - CBPF, 1996.

REZENDE,S.O.; PUGLIESI, J.B.; VAREJÃO,F.M.; *Sistemas baseados em conhecimento*; In: Sistemas inteligentes fundamentos e aplicações. Compilação de Rezende, S.O. São Paulo: Editora Manole, 2003.

ROBINSON, T. *Speech Analysis*. Inglaterra:University of Cambridge. Disponível em <<http://mi.eng.cam.ac.uk/milab.htm>>.

SANTIAGO, D.F.A. *Diagnóstico de falhas em máquinas rotativas utilizando transformada de wavelet e redes neurais artificiais*. 2004. 274 f. Tese de doutorado em Engenharia Mecânica - Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas.

UNIVERSIDADE DE SÃO PAULO. *Análise de vibrações*. Disponível em <<http://www.bibvirt.futuro.usp.br/>>.

UNIVERSITY OF RHODE ISLAND.*FFT tutorial*. USA: Department of Electrical and Computer Engineering. Disponível em: <<http://www.ele.uri.edu/~hansenj/projects/ele436/fft.pdf>>.

XU, M; MARANGONI, R.D. *Vibration analysis of a motor-flexible coupling-rotor system subject to misalignment and unbalance. Part I: theoretical model and analysis*. USA: Journal of Sound and Vibration, pg.663-679, 1994.

APÊNDICE A – Código do programa em MATLAB

Código gerado para leitura dos dados de vibração em arquivos tipo texto, criação da rede neural, treinamento da rede, teste da rede treinada, quantificação dos erros e apresentação dos resultados. As figuras em Matlab no texto principal também foram geradas por este programa.

```
function vib=programa(Mostra,Qte,N,NExemplos,MaxnovosNN,MaxnovosD,MaxnovosUU,n);

% Funcao para ler arquivos com padroes, treinar a rede e fazer a validacao
%
% Sintaxe: programa (Mostra,Qte,N,NExemplos,MaxnovosNN,MaxnovosD,MaxnovosUU,n);
% Onde:Mostra = 1/0, para mostrar os gráficos das FFT dos sinais (Default = 0);
%       Qte = Quantidade de neuronios camada escondida (Default = 9);
%       N = Numero de ruídos, caso desejado (Default = 0)
%       NExemplos = Numero de arquivos para treinamento da rede vindo dos exemplos
%       (Default=0)
%       MaxnovosXX = quantidade registros reais tipo XX que sera lido
%       n = número de exemplos artificiais para treinamento
%
% Para rodar nos valores default, simplesmente tecle <programa>

clc          % Limpa tela
close all    % Fecha figuras abertas

% =====
% Analisa parametros passados pelo usuario para definir parametros default
if nargin<9 % Nao definiu a semente para a geração dos vetores para treinamento
    seed=3;
end
if nargin<8 % Nao definiu num. de exemplos gerados artificialmente para treinamento
    n=4000;
end
if nargin<7 % Nao definiu num. registros tipo UU
    MaxnovosUU=76;
end
if nargin<6 % Nao definiu num. registros tipo DD
    MaxnovosDD=10;
end
if nargin<5 % Nao definiu num. registros tipo NN
    MaxnovosNN=99;
end
if nargin<4 % Nao definiu NExemplos vindos dos registros
    NExemplos=0;
end
if nargin<3 % Nao definiu N (NUMERO DE RUIDOS)
    N=0;
end
if nargin<2 % Nao definiu Qte (num. neuronios camada escondida)
    Qte = 9;
end
if nargin<1 % Nao definiu Mostra
    Mostra = 0; % 1 para mostrar
```



```

end

MaxnovosUD=15; % Quantidade de registros tipo UD

% =====
% Daqui começa o programa propriamente dito

tipos_saidas; % Define padroes de tipos de saida e salva em arquivo
X=[];         % Inicializa matriz com vetores de entrada

Y=[];         % Inicializa matriz com respectivos vetores de saida

% =====
% geração das matrizes de entrada e saida para treinamento

rand('seed',seed); % garante a repetibilidade
yn=[1 0 0 0]; % saida para a classe Normal
yd=[0 1 0 0]; % saida para a classe Desalinhamento
yu=[0 0 1 0]; % saida para a classe Desbalanceamento
yud=[0 0 0 1]; % saida para a classe Desbalanceamento com Desalinhamento
X=10*rand(3,n); % geração aleatoria dos vetores de entrada
Y=zeros(4,n); % inicialização da matriz de saida
L=5.1;
for i = 1:n
    if (X(1,i)<=L & X(2,i)<=L & X(3,i)<=L) Y(:,i)=yn; % Normal (H1, H2, H3 baixos)
    elseif (X(1,i)<=L & X(2,i)<=L & X(3,i)> L) Y(:,i)=yd; % Desalinhamento (H3 alto)
    elseif (X(1,i)<=L & X(2,i)> L & X(3,i)<=L) Y(:,i)=yd; % Desalinhamento (H2 alto)
    elseif (X(1,i)<=L & X(2,i)> L & X(3,i)> L) Y(:,i)=yd; % Desalinhamento (H2 e H3 altos)
    elseif (X(1,i)> L & X(2,i)<=L & X(3,i)<=L) Y(:,i)=yu; % Desbalanceamento (H1 alto)

    else
        % casos de incertezas onde 1a harmonica> L e 2a ou 3a também > L
        Y(:,i)=yud; % região onde há Desbalanço e Desalinhamento
    end
end

%=====

[X,Y]=embaralhar(X,Y); % Para embaralhar amostras.

% =====
% Criar a rede
Tam=size(X,1); % Tamanho do vetor de entrada (para montar o Range)
Range_entrada(1:Tam,1)=min(min(X)); % Assume automaticamente o minimo valor visto de X
Range_entrada(1:Tam,2)=max(max(X)); % Assume automaticamente o máximo valor visto de X
Qte_neuron = [Qte size(Y,1)] % Qte= camada intermed; numero de neuronios de saida eh igual
ao comprimento do vetor de saida
net=newff(Range_entrada,Qte_neuron,{'logsig' 'purelin'}); % Cria rede
% net=newff(Range_entrada,Qte_neuron,{'logsig' 'logsig' 'purelin'}); %Cria rede 2 camadas
escondidas

% =====
% Treinar a rede
% Parametros para o treinamento da RNA
net.trainParam.epochs = 500;
net.trainParam.goal = 1e-15;
net = train(net,X,Y);
save net
disp('Rede Treinada. Tecle <ENTER> para processo de validacao');
% pause

```

```

close all          % Fecha eventuais figuras abertas

% =====
% Validar a rede
% Testa todos os arquivos que não foram para o treinamento

[X,Y]=le_novos('NN','D','UU','UD',NExemplos+1,[MaxnovosNN MaxnovosDD MaxnovosUU
MaxnovosUD],Mostra);% de Qte+1 ateh Maxnovos (mudar este valor qdo tiver mais arquivos)

Ynet = sim(net,X); % Valores de saida calculados pela RNA
YnetA=um_e_zero(Ynet); % Troca valores numéricos arredondados por UM e ZERO, onde UM indica
a posição do maximo

% Deixa resultados na tela
erro=Y-YnetA; % Erro na matriz de 1/0
e=max(erro); % maior erro de cada coluna
plot(e);
soma=sum(e);
title(strcat(num2str(soma),' Erros em ',num2str(length(erro))))
Erro=soma; % Parametro que "volta"
% % Q1=(NExemplos+1:Maxnovos);
Q1=(NExemplos+1:MaxnovosNN);
Q2=(NExemplos+1:MaxnovosDD);
Q3=(NExemplos+1:MaxnovosUU);
Q4=(NExemplos+1:MaxnovosUD);
Numbers = [Q1 Q2 Q3 Q4]';
CONF=[];
mostra_result(Y,Ynet,YnetA,CONF,Numbers);

% =====
% ===== FIM DO PROGRAMA PRINCIPAL =====
% =====

function mostra_result(Y,Ynet,YnetA,CONF,Numbers);
Y=Y';
Ynet=Ynet';

MAX=[];
SUMA=[];
for i=1:length(Ynet)
SUBYnet=Ynet(i,:);% vetor formado pela linha i de Ynet(saida da rede treinada)
MAIOR=max(SUBYnet);% maior valor entre os elementos da linha
MAX(:,size(MAX,2)+1)=MAIOR; % insere nova coluna no vetor MAX
SOM=sum(SUBYnet);% soma os elementos do vetor SUBYnet (linha i de Ynet)
SUMA(:,size(SUMA,2)+1)=SOM;% insere nova coluna na matriz SUMA
end
MAX=MAX'% transforma o vetor linha MAX em vetor coluna MAX
SUMA=SUMA'; % transforma o vetor linha suma em vetor coluna MAX
CONF=MAX./SUMA % expressao do grau de confiança

YnetA=YnetA';
disp(' Ver saidas Y , Ynet, Ynet Arredondado e Numeros dos Arquivos')
YY=[Y Ynet YnetA CONF Numbers]
save YY

% =====
% Funcao para ler os dados de um arquivo e jah colocar no formato de
% entrada/saida para a RNA

```

```

function [X,Y]=le_arquivo(tipo,i,X,Y,nruídos,Mostra);
    numero=num2str(i);          % String do numero associado ao arquivo

    % Leitura da entrada x
    nome_arqx=strcat(tipo,numero,'.txt'); % Compoe o nome do arquivo X a ser lido
    nome_dados=strcat(tipo,numero);      % Recupera o nome dos dados de entrada X do arquivos
    v=load (nome_arqx); % carrega os dados do arquivo txt
    rpm=v(1,9); %extrai a rotaçao nominal
    V=[v(1:256,2); v(1:256,4);v(1:256,6);v(1:256,8)];%exclui as colunas de tempo
    %V e um vetor de 1 coluna 1024 linhas
    Vt=[v(1:256,1); v(1:256,3);v(1:256,5);v(1:256,7)];%vetor das colunas tempo
    comp=length(Vt);
    tmax=Vt(comp); %numero de amostras
    passo=tmax/comp; % intervalo entre amostras
    fs=1/passo; %frequencia da amostragem
    F=abs(fft(V,length(V)));%transformada de Fourier do sinal de vibracao
    F=(F(1:length(F)/2)/500); % Reduz a dimensao de F em um vetor de 512 linhas (1024/2);
    F1=(F(1:length(F)/8)/100); % vetor que sera mostrado no grafico
    freq=(0:(comp-1)/2)*fs*50; %50 e um fator de ajuste(58.5 se ajusta melhor aos dados)
    % a divisao por 2 eh porque o grafico eh simetrico em torno do centro
    % a divisao por 500 eh para as amplitudes ficarem igual aos registros da Tecvib.

    %=====EXTRATOR DE PRIMEIROS HARMONICOS=====

    [vv,ih]=min(abs(freq-rpm));% ih indice da rotaçao nominal
    %   indice=ih

        %d1=6
        d1=6; % valor da faixa
        if ih>40
            Z=[max(F(ih-d1:ih+d1));max(F((ih*2)-d1:(ih*2)+d1));0.5]; %
        elseif ih<=3
            Z=[max(F(ih-2:ih+d1));max(F((ih*2)-3:(ih*2)+d1));max(F((ih*3)-5:(ih*3)+d1))];
        else
            Z=[max(F(ih-d1:ih+d1));max(F((ih*2)-d1:(ih*2)+d1));max(F((ih*3)-d1:(ih*3)+d1))]; % maximo
das amplitudes em torno de uma faixa nos 1o. e 2o. e 3o. harmonicos
        end
    % =====FIM DO EXTRATOR DE HARMONICOS=====

    %===== % Se for para mostrar os graficos=====
    if Mostra

        F1=(F(1:length(F)/8)); % vetor que sera mostrado
        freq=(0:(comp-1)/2)*fs*50; % forma o eixo das freqüências
        freq1=freq(1:length(F1));

        figure(1)
        stem(freq1,F1) % Mostra o sinal no dominio Frequencia
    %   stem(F1*100)          % Mostra o sinal de vibracao ateh 500 msec
        xx=strcat('Arquivo ',nome_dados);
    %   title('Sinal de vibracao ate 500 msec')
        title(xx)
        set(gcf,'position',[250 460 392 320])

        figure(2)
        plot (V(1:500))% mostra o sinal de vibracao ateh 500 msec
    %   title(arquivo)
    %   xlabel ('tempo em ms')
        set(gcf,'position',[25 100 392 287])

```

```

figure(3)
limite=[ 1.07 2.14 5.0 10.7];
stem(Z) % Mostra media do sinal (o que vai entrar para a RNA)
title('Amplitudes ate o 3o. harmonico')
xlabel=strcat('Arquivo ',nome_dados);
set(gcf,'position',[800 100 392 287])
axis([ 0 4 0 20])
hold on
for L=1:size(limite,2) % Numero de colunas = limites dados = 4; (numero de linhas que serao
traçadas)
    plot([0 4],[limite(L) limite(L)],'r:');
    text(4.05, limite(L),num2str(limite(L)));
end
hold off

figure(4)
stem(freq,F) % Mostra o sinal no dominio Frequencia
xx=strcat('Arquivo ',nome_dados);
title(xx)
set(gcf,'position',[410 100 392 287])

disp('Tecla <ENTER> para continuar')
pause
end
x=Z;
X(:,size(X,2)+1)=x; % Insere nova coluna na matriz de entrada

% Leitura da respectiva saida y
nome_arqy=tipo; % Compo o nome do arquivo Y a ser lido
load(nome_arqy); % Le arquivo especificado
nome_var=strcat('y',tipo); % Decobre o nome da variavel no arquivo
y=eval(nome_var); % Asscia os valores da variavel a saida Y

Y(:,size(Y,2)+1)=y; % Insiro nova coluna na matriz de saida

% =====
% Para embaralhar dados lidos - pode ajudar o treinamento
function [X,Y]=embaralhar(X,Y);

ordem_aleatoria=rand(size(X,2),1); % da uma ordem aleatorio as linhas
[ordenado,indice]=sort(ordem_aleatoria);

for i=1:length(indice)
    x(:,i)=X(:,indice(i));
    y(:,i)=Y(:,indice(i));
end

X=x;
Y=y;

% =====
% Le todos dados que nao foram utilizados no treinamento
function [X,Y]=le_novos(Tipo1,Tipo2,Tipo3,Tipo4,Ini,Fim,Mostra);

X=[]; % Inicializa matriz com vetores de entrada
Y=[]; % Inicializa matriz com respectivos vetores de saida

```

```

% Loop para leitura e montagem das matrizes com base nos arquivos
for i=Ini:Fim(1) % Le ate o ultimo arquivo do Tipo1
    [X,Y]=le_arquivo(Tipo1,i,X,Y,0,Mostra);
end
for i=Ini:Fim(2) % Le ate o ultimo arquivo do Tipo2
    [X,Y]=le_arquivo(Tipo2,i,X,Y,0,Mostra);
end
for i=Ini:Fim(3) % Le ate o ultimo arquivo do Tipo3
    [X,Y]=le_arquivo(Tipo3,i,X,Y,0,Mostra);
end
for i=Ini:Fim(4) % Le ate o ultimo arquivo do Tipo4
    [X,Y]=le_arquivo(Tipo4,i,X,Y,0,Mostra);
end

%=====
function tipos_saidas;

yNN=[1 0 0 0]';
save NN yNN

yD =[0 1 0 0]';
save D yD

yUU =[0 0 1 0 ]';
save UU yUU

yUD= [0 0 0 1 ]';
save UD yUD

%=====
% Discretização das saída (transforma numeros aproximados em uns e zeros)

function Ynet=um_e_zero(Ynet);
save Ynet
% Ynet = abs(Ynet) % retirar se der erro
m=max(Ynet); % Indica maximos de cada coluna de dados
for j=1:size(Ynet,2) % Varre cada coluna
    Ynet(:,j)=Ynet(:,j)==m(j); % Troca valores reais pelos numeros inteiros 1 e 0, 1 indica a
    posicao do maximo
end
%=====

```

APÊNDICE B - RELAÇÃO DE MÁQUINAS

APLICAÇÃO	ROTAÇÃO NOMINAL (RPM)	POTÊNCIA (kW)
Ventilador de Ar Secundário da Caldeira	1.790	260
Ventilador Lavador do Tanque Dissolução	1.190	55
Bomba de Mistura para Tanque de Massa	1.760	260
Picador de Disco	1.180	1.000
Bomba de Licor para Lavagem	1.775	22
Bomba de Mistura para Estágio	1.790	150
Compressor de Ar Atlas Copco	3.572	595
Moto Bomba de Vácuo	1.790	220
Ventilador de Ar Primário da Caldeira	1.190	75
Ventilador de Ar Terciário da Caldeira	1.790	90
Ventilador de Gás GNC	1.200	70
Bomba de Mistura	1.180	1.000
Bomba do Sistema Refrigeração	1.780	22
Compressor de Ozônio	1.780	132
Desagregador do Tanque da Cortadeira	1.180	260