

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

**DETECÇÃO AUTOMÁTICA DE FALHAS EM MOTORES DE
COMBUSTÃO INTERNA UTILIZANDO REDE NEURAL**

Dissertação apresentada
à Universidade Federal de Uberlândia por:

MECHELANGELO VIANA MANCUZO

Como parte dos requisitos para a obtenção do título de Mestre em
Engenharia Mecânica

Aprovada por:

Prof. Dr. Carlos Roberto Ribeiro	(UFU)-Orientador
Prof. Dr. João Antonio Pereira	(UNESP) - Ilha Solteira
Prof. Dr. Marcus Antonio Viana Duarte	(UFU)
Eng. Cesar Rocha	(FIAT)-Betim

Uberlândia, 27/08/1999.

**À Deus,
à minha esposa, Cássia
aos meus queridos pais, Nicolau e Eva
aos queridos primos, Marcus e Isabel
às minhas irmãs, Eliane, Andréia e Alessandra**

Agradecimentos

À Deus pela vida e pelos talentos.

Ao meu Anjo Guardião pela companhia integral.

À minha esposa, pelo carinho de todas as horas.

Aos meus pais, pela abnegação.

Aos meus primos, Marcus e Isabel pelo apoio decisivo.

Ao Professor Carlos Roberto Ribeiro, pela amizade, pela orientação e pela paciência com que sempre se dispôs a me auxiliar durante a elaboração deste trabalho.

Aos professores, Marcus Antônio Viana Duarte e Francisco Paula Lepore Neto pelas contribuições valiosas.

Ao professor Carlos Alberto de Melo pela amizade e pelas oportunidades a mim proporcionadas durante o período iniciação científica.

À todos os professores do Curso de Engenharia Mecânica da UFU.

Às secretárias do Curso de Pós-graduação em Engenharia Mecânica da UFU, Janete e Marta.

A todos os colegas e amigos da pós-graduação que direta ou indiretamente me ajudaram.

Aos técnicos da oficina mecânica, do setor de projetos e do laboratório de motores do DEEME-UFU.

Às funcionárias do DEEME, Alice e Natalícia.

À FIAT Automóveis S/A por ter aberto as suas portas, fornecendo apoio material e humano para que este trabalho se concretizasse.

À CAPES (Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelo apoio financeiro.

Mancuzo, M. V., 1999, "Detecção Automática de Falhas em Motores de Combustão Interna Utilizando Rede Neural ", Dissertação de Mestrado, Universidade Federal de Uberlândia, MG.

RESUMO

Este trabalho mostra a implementação de uma ferramenta de diagnóstico automático de algumas falhas encontradas em motores de combustão interna. Inicialmente é apresentado um estudo cinemático dos mecanismos geradores das falhas, e a análise modal parcial de um motor, objetivando prover informações sobre como a energia vibratória se propaga destes mecanismos até o sensor que capta a assinatura de vibração. Num segundo momento, especifica-se a cadeia de medição utilizada na aquisição dos sinais, e caracteriza-se a metodologia empregada no pré-processamento dos sinais adquiridos dos motores, disponibilizando-os para a fase de extração das características. Na sequência, utilizando-se da amplitude do espectro do envelope, em frequências características, foram definidos determinados padrões associados aos defeitos mais frequentemente encontrados durante os testes na linha de montagem. Conjuntos destes padrões foram apresentados a uma rede neural objetivando seu treinamento. O tipo de rede neural adotada foi a probabilística (PNN), por apresentar características desejáveis para resolver o problema em foco: a confiabilidade do modelo estatístico no qual ela é embasada, a facilidade de adição ou remoção de padrões no conjunto de dados de treinamento e validação, e o reduzido tempo computacional dispendido para o seu treinamento. O trabalho termina mostrando um procedimento de validação, onde foi testada a capacidade da rede treinada, de reconhecer padrões diferentes dos utilizados no seu treinamento. A rede PNN foi capaz de automatizar o diagnóstico das falhas, estabelecendo, assim, um critério objetivo de avaliação da condição de funcionamento dos motores.

Palavras chave: Diagnóstico automático de falhas, Rede Neural probabilística, Análise de Vibrações, Motor de Combustão Interna.

Mancuzo, M. V., 1999, "Automatic Fault Detection in Spark Engine Using Neural Network", M. Sc, Universidade Federal de Uberlândia, MG.

ABSTRACT

This work presents the implementation of an automatic diagnosis tool of some faults founded in spark engine. Firstly, a cinematic study of the fault generating mechanisms is presented, and a partially modal analysis of an engine is illustrated, objectifying to provide information on how the vibratory energy spreads of these mechanisms to the sensor that captures the vibration signature. In a second moment, the measurement instrumentation used in the engine data acquisition is specified, and the methodology employed in the pre-processing of engines data is characterized, disposing them for the phase of characteristics extraction. In the sequence, using the magnitude of envelope spectrum, in characteristic frequencies, certain patterns associated to the defects more frequently found during the tests in the assembly line were defined. Groups of these patterns were presented to a neural network objectifying its training. The type of neural network adopted, was the probabilistic neural network (PNN), which presents desirable characteristics to solve the problem in focus: the reliability of the statistical model in which it is based, the addition or removal easiness of patterns in data set of training and validation, and the reduced computational time expended in its training. The work finishes showing a validation procedure, in which the capacity of the trained net in recognizing patterns that are different from those used in its training, was tested. The PNN was capable to automate the fault diagnosis, establishing, like this, an objective approach for the control quality of spark engines operation condition.

Key Words: Automatic Fault Detection, Probabilistic Neural Network, Vibrations Analysis, Spark Engine.

LISTA DE FIGURAS

Figura	Pag.
2.1 - Vista frontal do motor	05
2.2 - Vista frontal do motor com tensor da correia do alternador desmontado	05
2.3 - Esquema de um rolamento de esferas.	07
2.4 - Esquema do mecanismo de acionamento das válvulas	07
2.5 - Diagrama no tempo do deslocamento(a), aceleração(b) e velocidade(c) da válvula.	08
2.6 - Esquema da distribuição do carregamento no rolamento.	10
2.7 - Esquema do ajuste entre o Came e a pastilha de regulagem de válvula:.	11
2.8 - Diagrama de blocos de um sistema de uma entrada e uma saída.	13
2.9 - Representação do espaço de Laplace. Ilustração de uma função de transferência em 3D.	14
2.10 - Subdivisão do conjunto $a(t)$ em (n) seguimentos de comprimento (T) .	15
2.11 - Sistema sem ruído.	16
2.12 - Sistema com ruído na saída.	17
2.13 - Sistema com ruído aditivo na saída.	18
2.14 - Esquema da cadeia de medição utilizada na obtenção da FRF do tensor da correia do alternador	20
2.15 - Ilustração da excitação efetuada sobre o tensor da correia do alternador	21
2.16 - FRF entre: tensor da correia do alternador e tampa da caixa do eixo comando de válvulas.	23
2.17 - FRF entre: tensor da correia sincronizada e tampa da caixa do eixo comando de válvulas.	24
2.18 -FRF entre eixo comando de válvulas e tampa da caixa do eixo comando de válvulas.	25

3.1	- Esquema do sistema de controle da qualidade de funcionamento dos motores.	27
3.2	- Bancada prova-motor e sistema de aquisição de dados na linha de montagem.	28
3.3	- Posicionamento do sensor de vibração no motor: acelerômetro(a); tampa do compartimento do eixo comando de válvulas(b).	29
3.4	- Esquema ilustrando o fluxo do sinal durante a aquisição.	30
3.5	- Esquema da técnica do envelope, adaptado de (Angelo,1987).	31
3.6	- Trecho de sinal de motores: com e sem defeito.	32
3.7	- Auto espectro do sinal de aceleração mostrado no domínio do tempo na Fig. 3.6.	33
3.8	- Ampliação do auto espectro da Fig. 3.7, entre 2700 e 4750 Hz .	33
3.9	- Envelope dos sinais mostrados na Fig. 3.6, no domínio do tempo.	34
3.10	- Espectro do envelope do sinal de aceleração.	34
4.1	- Esquema de um sistema motor - rotor desbalanceado	37
4.2	- Esquema ilustrando a correlação dos componentes do sinal de vibração com suas respectivas fontes	38
4.3	- Motor com tensor da correia sincronizadora rumoroso.	41
4.4	- Motor com tensor da correia do alternador rumoroso.	41
4.5	Motor com rumorosidade nos tensores aceitável, mas com batida de válvula.	42
4.6	- Motor com rumorosidade nos tensores aceitável, mas com batida de válvula. Ampliação da Fig. 4.5 na faixa de [0-2000] Hz.	42
4.7	- Espectro do envelope do sinal de aceleração de um motor com tensor da correia sincronizadora rumoroso.	44
4.8	- Padrões associados às condições de funcionamento dos motores.	47
4.9	- Padrões associados às condições de funcionamento dos motores.	48
5.1	- Exemplo 1 de um problema de classificação bivariável.	49
5.2	- Exemplo 2 de um problema de classificação bivariável.	50
5.3	- Estimador da fdp de Parzen para $\sigma = 0.035$.	53
5.4	- Estimador da fdp de Parzen para $\sigma = 0.004$.	53
5.5	- Estimador da fdp de Parzen para $\sigma = 0.05$.	54

5.6	- Estimador da fdp de Parzen para $\sigma = 0.09$.	54
5.6a	- Estimador da fdp de Parzen para $\sigma = 0.3$.	55
5.7	- Arquitetura básica da rede neural probabilística.	58
5.8	- Estimativa de uma fdp bivariável usando a Kernel Gaussiana.	60
5.9	- Estimativa de uma fdp bivariável usando a Kernel da Eq. 5.8 .	60
5.10	- Estimativa da fdp usando um valor muito pequeno para o parâmetro de escala $\sigma(0.15)$.	62
5.11	- Estimativa da fdp usando um valor um pouco menor do que o valor ideal para o parâmetro de escala $\sigma(0.75)$.	62
5.12	- Estimativa da fdp usando um valor um pouco maior do que o valor ideal para o parâmetro de escala $\sigma(1.5)$.	63
5.13	- Estimativa da fdp usando um valor muito grande para o parâmetro de escala $\sigma(4.0)$.	63
6.1	- Fluxograma do sistema de detecção automática de falhas em motores de combustão interna.	66
6.2	- Conjunto de treinamento(motores com batida de válvula) gerados a partir de um padrão básico.	68
6.3	- Ilustração do método de geração dos padrões simulados a partir de um padrão básico.	69
6.4	- Padrões base de motores sem batida de válvula.	70
6.5	- Padrões base de motores sem batida de válvula, no limite da aceitabilidade.	70
6.6	- Padrões base de motores com batida de válvula.	71
6.7	- Parte 1 do conjunto de treinamento(motores sem batida de válvula).	72
6.8	- Parte 2 do conjunto de treinamento(motores sem batida de válvula).	73
6.9	- Parte 3 do conjunto de treinamento(motores no limite da aceitabilidade).	74
6.10	- Parte 4 do conjunto de treinamento(motores com batida de válvula).	75
6.11	- Parte 4 do conjunto de treinamento(motores com batida de válvula).	76
6.12	- Parte 1 do conjunto de treinamento(motor sem defeito).	77
6.13	- Parte 2 do conjunto de treinamento(motor sem defeito).	78
6.14	- Parte 3 do conjunto de treinamento(motor sem defeito).	79
6.15	- Parte 4 do conjunto de treinamento(motor com rumorosidade no	

tensor da correia sincronizadora)	79
6.16 - Parte 5 do conjunto de treinamento(motor com rumorosidade no tensor da correia sincronizadora)	80
6.17 6.17 - Parte 6 do conjunto de treinamento(motor com rumorosidade no tensor da correia do alternador).	80
6.18 - Parte 7 do conjunto de treinamento(motor com rumorosidade no tensor da correia do alternador).	81
6.19 - Parte 8 do conjunto de treinamento(motor com rumorosidade nos dois tensores).	81
6.20 - Parte 9 do conjunto de treinamento(motor com rumorosidade nos dois tensores).	82
6.21 - Parte 10 do conjunto de treinamento(motor com rumorosidade nos dois tensores).	82
6.22 - Padrões de motores diferentes com o mesmo tipo de defeito, porém apresentando níveis diferentes de severidade para o problema de rumorosidade no tensor da correia sincronizadora, gerado a partir de um único padrão base.	83
7.1 - Esquema ilustrando os códigos de saída da rede PNN.	86
7.2 - Matriz de erro classificatório, ilustrando um caso ideal.	87
7.3 - Teste de padrão inédito, representando motor com tensor da correia sincronizadora rumoroso.	88
7.4 - Teste de padrão inédito, representando motor com tensor da correia sincronizadora rumoroso.	88
7.5 - Teste de padrão inédito, representando motor com tensor da correia sincronizadora rumoroso.	89
7.6 - Teste de padrão inédito, representando motor com tensor da correia do alternador rumoroso.	89
7.7 - Teste de padrão inédito, representando motor com tensor da correia do alternador rumoroso.	90
7.8 - Teste de padrão inédito, representando motor com tensor da correia do alternador rumoroso.	90
7.9 - Teste de padrão inédito, representando motor sem defeito.	91
7.10 - Teste de padrão inédito, representando motor sem defeito.	91

7.11	- Teste de padrão inédito, representando motor com ambos os tensores rumorosos.	92
7.12	- Teste de padrão inédito, representando motor com ambos os tensores rumorosos.	92
7.13	- Teste de padrão inédito, representando motor com ambos os tensores rumorosos.	93

LISTA DE TABELAS

Tabela		Pag.
2.1	- Especificação dos rolamentos utilizados nos tensores.	6
2.1	- Bandas de Frequência nas quais se verifica a amplificação do sinal de vibração.	26
4.1	- Descrição dos parâmetros constituintes dos padrões de defeito.	46

LISTA DE SÍMBOLOS

SÍMBOLOS ARÁBICOS

- $(y_{\bullet})_i$ - Parâmetro de um padrão simulado.
- $(y_{\square})_i$ -Parâmetro de um padrão adquirido.
- $A(f)$ -Transformada de Fourier do sinal de saída.
- $A(s)$ - Transformada de Laplace do sinal de saída.
- B_{1i} - Bandas de frequência.
- $i=1,2,3$
- B_i - Bandas de frequência.
- $i=1,2,3$
- c_k - Custo em se classificar erradamente a amostra k .
- d - Folga entre came e pastilha de regulação de válvula.
- d_e - Módulo diametral do rolamento.
- dt - intervalo de tempo.
- $F(f)$ -Transformada de Fourier do sinal de entrada.
- $F(s)$ -Transformada de Laplace do sinal de entrada.
- f_1 - Representa uma linha de frequência .
- f_2 - Representa uma linha de frequência .
- f_c - Fator de correção.
- f_{c1} - Frequência central do filtro passa banda utilizado na implementação da técnica do envelope.
- f_{c2} - Frequência de corte do filtro passa baixo utilizado na implementação da técnica do envelope.
- F_{ee} - Frequência de spin do do elemento rolante.
- $f_i(k)$ - Densidade da variável na proximidade da amostra.
- f_k - Linha de frequência no domínio discreto.
- F_{pepe} - Frequência de passagem do elemento rolante na pista externa do rolamento

F_{pepi} - Frequência de passagem do elemento rolante na pista interna do rolamento.

Fr - Ângulo de contato entre o elemento rolante e a pista de rolamento.

F_t - Frequência do trem dos elementos rolantes.

G_{aa} - Auto espectro do sinal de entrada.

G_{af} - Espectro cruzado da saída pela entrada.

G_{fa} - Espectro cruzado da entrada pela saída.

G_{ff} - Auto espectro do sinal de saída.

G_{mm} - Espectro do ruído na entrada.

G_{nn} - Espectro do ruído na saída.

G_{uu} - Espectro coerente do sinal de entrada.

G_{uv} - Espectro cruzado da entrada pela saída, coerente.

G_{vv} - Espectro coerente do sinal de saída.

$H(f)$ - Função de resposta em frequência.

$H(s)$ - Função de transferência.

H_1 - Estimador 1 da função de resposta em frequência.

H_2 - Estimador 2 da função de resposta em frequência.

h_k - Probabilidade da amostra k .

N - Comprimento do vetor T .

n - Número de médias utilizadas.

N_e - Número de elementos rolantes.

p - Frequência de rotação da pista girante em rpm.

R_{max} - Índice indicador de severidade de defeito.

T - Tempo total de aquisição do sinal.

$W(d)$ - Função de ponderação, ou janela Kernel.

x - Variável aleatória unidimensional.

$\mathbf{x}$ - Variável aleatória multidimensional.

x_i - Amostra unidimensional

$\mathbf{x}_i$ - Amostra multidimensional.

SÍMBOLOS GREGOS

- α - Percentual sistemático adicionado a um padrão.
- β - Percentual aleatório adicionado aos parâmetros do padrão.
- γ_{fa}^2 - Função coerência .
- σ - Parâmetro de escala da função Kernel.
- ϕ - ângulo de contato entre o elemento rolante e a pista de rolamento.
- ϕ_e - Diâmetro dos elementos rolantes.
- ϕ_p - Módulo diametral do rolamento, mostrado na Figura 2.3.

DETECÇÃO AUTOMÁTICA DE FALHAS EM MOTORES DE COMBUSTÃO INTERNA UTILIZANDO REDE NEURAL

SUMÁRIO

Lista de Figuras	I
Lista de Tabelas	V
Lista de Símbolos	VI
1 - Introdução	01
2 - Caracterização do Motor	04
2.1 - Identificação dos Elementos Geradores de Falha no Motor	04
2.2 - Os Mecanismos Geradores de Rumorabilidade nos Rolamentos	09
2.3 - Os Mecanismos Geradores de Batida de Válvula	11
2.4 - Os Fundamentos da Função de Resposta em Frequência(FRF) ...	13
2.5 - Os Estimadores da FRF	14
2.5.1 - FRF de Sistemas sem Ruído Aditivo	16
2.5.2 - FRF de Sistemas com Ruído Aditivo na Saída	17
2.5.3 - FRF de Sistemas com Ruído Aditivo na Entrada	18
2.6 - As Funções de Resposta em Frequência de Interesse	20
.....	
3.0 - Aquisição e Pré-processamento do Sinal de Vibração dos Motores	27

3.1 - Uma Visão Geral do Sistema de Diagnóstico Automático de Falhas	27
3.2 - A Aquisição do sinal de vibração	28
3.3 - O Pré-processamento e a Redução de Dados	30
4.0 - Extração das características dos Sinais e Definição dos Padrões Associadas aos Defeitos	36
4.1 - Análise no Domínio do Tempo	37
4.2 - Análise no Domínio da Frequência	38
4.3 - Análises Preliminares no Domínio da Frequência	39
4.4 - Identificação Discriminatória de Defeitos no Domínio da Frequência	43
4.5 - Determinação das Frequências Características Dos Rolamentos	44
4.6 - Definição dos Padrões Associados aos Defeitos nos Tensores	46
4.7 - Definição Dos Padrões Associados com o Defeito de Batida de Válvula	48
5.0 - A Rede Neural Probabilística	49
5.1 - O Método de Classificação de Bayes	51
5.2 - O Método Parzen de Estimação da fdp	52
5.3 - Extensão do Método Parzen de Estimação da fdp para o Caso de Amostras de Várias Variáveis	56
5.4 - A Rede PNN Elementar	57
5.5 - A Implementação da Rede PNN Elementar	58
5.6 - O Programa Utilizado no Diagnóstico Automático das Falhas nos Tensores	64
6.0 - Implementação do Modelo de Diagnóstico Automático de Falhas via Rede PNN	65
6.1 - O Treinamento da Rede Neural em Relação à Batida de Válvula	67

6.2 - O Treinamento da Rede Neural em Relação aos Defeitos nos Tensores	76
6.3 - A Saída do Programa PNN	84
7.0 - Validação da Rede PNN	85
8.0 - Conclusões	94
Referências Bibliográficas	96

CAPÍTULO I

Introdução

Nos últimos anos, para atender a um mercado cada vez mais exigente e competitivo, o setor automobilístico tem investido em técnicas modernas de projeto, de fabricação e na utilização da eletrônica embarcada nos veículos. Essa tecnologia tem sido usada, dentre outras coisas, para produzir motores de combustão interna que, além de mais eficientes, apresentem melhores características de funcionamento, agregando ao automóvel maior conforto e suavidade de operação.

Uma vez que um veículo apresente desempenho satisfatório no item potência, um item que influi de forma decisiva na avaliação do conforto oferecido pelo mesmo é o nível de ruído sonoro emitido pelo seu conjunto propulsor. Neste contexto, algumas montadoras ainda utilizam critérios subjetivos na avaliação da qualidade de funcionamento dos motores e sistemas de transmissão aplicados aos seus veículos, isto é, durante os testes na linha de montagem, a condição de funcionamento do conjunto propulsor dos carros é avaliada como aceitável ou inaceitável, tomando-se o julgamento humano como referência.

Em trabalho recente, (Alguindigue et al,1993) realizaram um estudo sobre o diagnóstico automático de falhas em mancais de rolamento utilizando uma rede neural convencional. (McCormick,1998) também realizou estudo sobre diagnóstico automático de falhas em mancais de rolamento, testou várias ferramentas estatísticas de classificação e verificou o desempenho das topologias de rede neural mais utilizadas em procedimentos de classificação. Nestes dois trabalhos o sinal de monitoramento era proveniente apenas das vibrações do mancal, sem a interferência de sinais de outros mecanismos geradores de vibração, como é o caso de um motor de combustão interna.

A análise de assinatura de vibrações foi usada como método de detecção de falhas em motores de combustão interna por (Botton et al,1998), que estudaram os resultados da introdução de defeitos tais como: afrouxamento dos parafusos suportes, adiantamento e atraso do ponto de ignição, desconexão do cabo da vela de ignição e descalibração do espaçamento do eletrodo da vela de ignição. Entretanto, o método não avalia automaticamente a condição de funcionamento do motor, deixando a decisão por conta do operador do teste.

Como o julgamento humano é fortemente dependente das suas condições psicológicas momentâneas, o controle de qualidade baseado em critérios subjetivos introduz perdas no processo produtivo, pois, com frequência, conjuntos considerados como aceitáveis por um operador da linha de montagem são reprovados por outro durante a avaliação final do veículo na pista de testes. A consequência deste desentendimento é o retorno do veículo à linha de montagem para as necessárias reparações.

Para minimizar este problema, propõe-se neste trabalho, a implementação de uma ferramenta matemático-computacional para o diagnóstico automático de três defeitos de funcionamento muito encontrados na linha de montagem: nível de rumorosidade elevada no tensor da correia do alternador, no tensor da correia sincronizadora e a batida de válvula(s).

As etapas a serem seguidas para a implementação desta ferramenta podem ser vistas na Figura 1.1.




Figura 1.1 - Etapas para a implementação da ferramenta de diagnóstico automático de falhas.

Na primeira etapa é feita uma análise dos defeitos que se pretende identificar, bem como das suas origens. Na etapa 2, é apresentada a uma análise modal parcial do motor, onde se encontra a função de resposta em frequência entre cada mecanismo gerador de defeito e o ponto de medição do sinal de vibração. As etapas 1 e 2 são desenvolvidas no capítulo II.

As etapas 3 e 4 são abordadas no capítulo III. Na etapa 3, sinais de vibração de motores com condições de funcionamento conhecidas (com e sem defeito) são adquiridos. Na etapa 4, pela aplicação sucessiva da técnica do envelope e da transformada de Fourier sobre o sinal adquirido, obtém-se o espectro do envelope do sinal de vibração. Utilizando-se da amplitude do espectro do envelope em frequências características, definem-se padrões associados à condição de funcionamento de cada motor testado, possibilitando assim a estruturação de um banco de dados associado às falhas.

Uma vez constituído o banco de dados, na etapa 5, este é apresentado à uma rede neural para o seu treinamento e a sua validação. O modo como os padrões foram definidos bem como a estruturação do banco de dados são apresentados no capítulo IV.

A rede neural é treinada com o fim de se automatizar a identificação de falhas, definindo um critério objetivo para o procedimento de controle da qualidade dos motores, que deve ser compatível com os critérios subjetivos de avaliação adotados pelo mercado consumidor.

Um estudo introdutório sobre redes neurais é feito no capítulo V, onde também são apresentadas as características que habilitam a rede neural probabilística(PNN) para a tarefa proposta, dentre as quais, podemos citar: a confiabilidade do modelo estatístico no qual ela é embasada, o reduzido tempo computacional despendido no seu treinamento e a facilidade de adição ou remoção de padrões no conjunto de dados de treinamento e de validação(Master,1995).

No capítulo VI é apresentada uma metodologia para gerar o conjunto de dados utilizado no treinamento da rede PNN, a partir dos dados experimentais.

No capítulo VII são apresentados os resultados de validação da rede PNN e no último capítulo, são apresentadas conclusões e comentários relativos às propostas de trabalhos futuros.

Capítulo II

Caracterização do Motor

Neste capítulo é feita uma caracterização parcial do comportamento dinâmico do motor. Inicialmente são apresentados: um levantamento sobre o modo de operação dos elementos geradores das falhas estudadas neste trabalho, e a identificação d mecanismo gerador de tais falhas. Em seguida é mostrada uma síntese sobre a estimação da função de resposta em frequência (FRF) e o capítulo é encerrado com a investigação das informações contidas nas FRFs de interesse.

2.1 Identificação dos Elementos Geradores das Falhas no Motor

Durante os testes na linha de montagem foram encontrados motores apresentando níveis elevados de ruído, de acordo com os critérios do fabricante. Na maioria dos casos, os elementos dos quais a rumorosidade se origina não possuem falhas propriamente ditas, tais como defeitos superficiais ou desvios de forma. As rumorosidades detectadas, em geral, originam-se de erros na aplicação de forças de tensionamento de correias e também de erros de tolerância no ajuste mecânico. Tal afirmação pode ser feita com segurança, visto que, corrigidas as forças de tensionamento das correias e os ajustes na interface entre os cames do eixo comando de válvulas e as pastilhas de regulagem dos tuchos de válvula, os ruídos diminuía para níveis aceitáveis.

Os elementos geradores das falhas de funcionamento encontradas com maior frequência na linha de montagem são três:

- Interface entre os cames do eixo comando de válvulas e as pastilhas de regulagem dos tuchos de válvula.

- Rolamento do tensor da correia do alterador.

- Rolamento do tensor da correia sincronizada.

A montagem de cada um dos tensores das correias, do alterador e sincronizada, pode ser vista nas Figuras 2.1 e 2.2, respectivamente.




Figura 2.1 - Vista frontal do motor: polia do eixo comando de válvulas(a); correia do alterador(b); tensor da correia do alterador(c); polia da bomba d'água(d).




Figura 2.2 - Vista frontal do motor com tensor da correia do alterador desmontado: polia do eixo comando de válvulas(a); correia sincronizadora(b); tensor da correia sincronizada(c); polia do eixo virabrequim(d).

Os motores testados são da marca Fiat, 1500 cc - mpi, quatro tempos, de fabricação nacional e os testes foram realizados nos bancos de prova de motores na linha de montagem da Fiat.

A foto da Figura 2.2 foi obtida desmontado-se o tensor da correia do alternador para permitir a visualização do tensor da correia sincronizadora.

Os rolamentos dos dois tensores operam de modo semelhante. Em cada um, o anel interno é fixo nos respectivos suportes e o anel externo gira. No tensor da correia do alternador existe, em torno do anel externo do rolamento, um anel confeccionado em material plástico que entra em contato com a correia. O rolamento do tensor da correia sincronizada é um rolamento especialmente projetado para esta função, pois, o anel externo do mesmo já possui um formato apropriado para o interfaciamento com a correia sincronizada. Na Tabela 2.1 estão especificados os rolamentos de cada tensor, onde:

Ne - número de elementos rolantes.

ϕ_e - diâmetro dos elementos rolantes.

ϕ_p - módulo diametral do rolamento, mostrado na Figura 2.3.

Tabela 2.1 - Especificação dos rolamentos utilizados nos tensores

Aplicação	Especificação	Ne	ϕ_e [mm]	ϕ_p [mm]
Tensor da correia do alternador	SKF 337155B	10	6.747	36.000
Tensor da correia sincronizada	BB1 630632C	11	7.140	42.500

Na Figura 2.4 está mostrado um esquema de um mecanismo de abertura e fechamento sincronizado das válvulas de admissão e escape. O sincronismo de movimentos entre os eixos comando de válvulas e virabrequim é assegurado pela correia sincronizada mostrada na Figura 2.2. Esta correia possui dentes que possibilitam o engrenamento das polias acopladas à cada um dos eixos acima citados, de modo a não permitir nenhum escorregamento entre eles. O came, visto na Figura 2.4, é um elemento de máquina que converte um esforço de torque em um esforço unidirecional, permitindo a abertura das válvulas de admissão e de escape. A pastilha de regulação da válvula, na mesma figura, é um elemento que permite a regulação do ajuste mecânico entre came e tucho de válvula. O tucho de válvula é um elemento que tem a função de limitar, somente à direção vertical, a aplicação do esforço impresso pelo came à válvula. Ele evita dificuldades na abertura e fechamento da válvula, bem como, a degeneração prematura da haste e da guia de válvula.

A mola de retorno, como o próprio nome diz, é o elemento que retorna a válvula à posição de fechamento.




Figura 2.3 – Esquema de um rolamento de esferas.




Figura 2.4- Esquema do mecanismo de acionamento das válvulas: came do eixo comando de válvulas(a); pastilha de regulação da válvula(b); cabeçote do motor onde é usinada a guia de válvula(c); tucho de válvula(d); mola de retorno da válvula(e); guia de válvula(f); válvula(g).

O perfil de um came depende do movimento que se pretende realizar. Este é definido pela lei de abertura em função do tempo, Fig. 2.5-a, por exemplo, ou seja, pelo perfil de translação obtido quando se transportam para as ordenadas os deslocamentos do tucho e para as abscissas os ângulos. No perfil do ressalto assim constituído distinguem-se uma parte em que a distância entre o tucho e o eixo de rotação do came é variável (fase ativa) e uma em que tal distância não varia (fase de repouso).




Figura 2.5- Diagrama no tempo do deslocamento(a), aceleração(b) e velocidade(c) da válvula.

A fase ativa corresponde à abertura da válvula e a fase de repouso ao fechamento da válvula. Na fase de repouso prevê-se uma folga entre o came e o tucho, para permitir dilatações térmicas produzidas durante o funcionamento do motor, com o que se garante o perfeito funcionamento da válvula. Caso exista a folga não se pode determinar com exatidão o ponto em que ocorrerá o contato entre o came e tucho de válvula e, por consequência, construir um perfil que evite todas as possibilidades de choque. Por isso, procura-se combinar o trecho lateral com o circular, por meio de um plano inclinado, de tal modo que o

choque ocorra com velocidade constante. O perfil de velocidade, Fig. 2.5-c, deve ser contínuo, pois descontinuidade nas velocidades significa a ocorrência de indesejáveis choques entre o came e o tucho.

O perfil do came deve partir do diagrama das acelerações da válvula, Fig. 2.5-b. Isto porque, para um bom funcionamento, necessita-se de suavidade no levantamento da válvula, e o grau dessa suavidade pode ser corretamente determinado à vista do diagrama das acelerações. Em geral faz-se que a aceleração negativa seja menor do que a positiva, pois é a negativa que determina a separação entre o came e o tucho (batida de válvula), separação essa compensada pela ação da mola de retorno. Já a aceleração positiva é menos importante, pois apenas aumenta a pressão entre o tucho e o came. Descontinuidades e pontos angulosos no diagrama indicam vibrações.

A transmissão do movimento ao tucho sempre vem acompanhada de vibrações, que nos altos regimes de rotação, assumem particular importância, pois, alteram profundamente a lei do movimento e podem provocar quebras na válvula, na mola e no tucho, sendo por tais motivos, extremamente complexo o projeto dos comes.

Conhecidos os componentes mecânicos geradores das falhas, sua montagem e o modo como operam, faz-se necessário o estudo dos mecanismos de produção do defeito nestes componentes, de modo a associá-los com as informações contidas no sinal proveniente dos motores.

2.2 Os Mecanismos Geradores de Rumorosidade nos Rolamentos

Como já foi mencionado na seção 2.1, na maioria dos casos, os elementos dos quais a rumorosidade se origina não possuem falhas propriamente ditas, tal como defeitos superficiais ou desvios de forma. Assim, os sinais das falhas em rolamentos de que estamos tratando têm muita semelhança com sinais oriundos de defeitos incipientes, pois geram uma série de pulsos agudos de pouca energia.

De acordo com (Braun, 1986), a carga P aplicada sobre um rolamento possui uma distribuição como a que está esquematizada na Figura 2.6. Nesta figura a reta vertical que passa pelo centro do rolamento é a referência para a medida do ângulo Ψ , de forma que, o carregamento é máximo em $\Psi=0$ e, vale zero para $\Psi_{\max}$ e $-\Psi_{\max}$.

Durante a operação dos rolamentos sob condições normais de projeto, na passagem dos elementos rolantes pela região de máximo carregamento, $\Psi=0$, Figura 2.6, são geradas deformações mecânicas nas pistas do rolamento. Tais deformações, em frequências elevadas e audíveis, são amplificadas pela estrutura do motor entre o ponto de geração do

signal de falha e o ponto de medição do sinal de vibração, pois excitam a estrutura de fixação do rolamento nas suas frequências naturais. O efeito disto será uma elevação no nível da vibração medida. Na situação em que o rolamento opera com sobrecarga, devido a um erro qualquer de montagem, tais deformações são mais severas, produzindo amplitudes mais elevadas de vibrações e ruído sonoro. Níveis elevados de ruído e vibração causam, respectivamente, desconforto ao dirigir e falha prematura do rolamento.

Na seção 4.2 do capítulo IV será apresentado um modelo para a determinação das frequências através das quais se pode diagnosticar a condição de funcionamento de um determinado rolamento.




Figura 2.6 – Esquema da distribuição do carregamento no rolamento.

2.3 Os Mecanismos Geradores de Batida de Válvula.

O fenômeno da batida de válvula(s) é causado, principalmente, pela existência de descontinuidade no diagrama de velocidade da válvula, como mencionado anteriormente, sendo agravado por um erro no ajuste mecânico(folga exagerada) entre o came do eixo comando de válvulas e a pastilha de regulagem de válvulas. Uma configuração deste ajuste e seu esquema amplificado podem ser vistos respectivamente nas Figs 2.4 e 2.7.




Figura 2.7 - Esquema do ajuste entre o Came e a pastilha de regulagem de válvula:.. ilustração da folga(a); ajuste sem batida de válvula(b); ajuste com batida de válvula(c).

Usualmente, a tolerância de projeto admitida para o ajuste mecânico entre o came do eixo comando de válvulas e a pastilha de regulagem de válvulas, ou seja a folga 'd' entre as duas peças, mostrada na Figura 2.7a, é ± 0.05 mm, entretanto, empiricamente, o fabricante encontrou um valor de ± 0.03 mm para o ajuste, dentro do qual, o motor opera sem apresentar o fenômeno de batida de válvula(s).

Apesar de já ter sido dito que o fenômeno de batida de válvula(s) é causado por descontinuidade(s) no perfil de velocidade do came, a lubrificação tem papel importante neste fenômeno e o seu efeito atenuador é fortemente dependente da folga 'd'. No caso de um ajuste com $d \leq + 0.03$ mm, no instante em que o came atingir a posição angular na eminência de abertura da válvula, como esquematizado na Figura 2.7b, existirá uma área entre o came e a pastilha de regulagem suficientemente grande para a ocorrência do contato, permitindo a formação de um colchão de lubrificante que minimiza o impacto de acoplamento entre as duas peças.

Admitindo agora a existência de uma folga $d = 0.05$ mm entre o came do eixo comando de válvulas e a pastilha de regulagem de válvulas, quando o came atingir a posição angular na eminência de abertura da válvula, como mostrado na Figura 2.7c, o

contato entre o came e pastilha se dará através de uma pequena área em torno da linha de contato, considerando as deformações elásticas existentes. Nestas circunstâncias, a reduzida área de contato não possibilita a formação do colchão de lubrificante e então o came impacta a pastilha de regulação de válvula gerando um ruído característico, parecido com uma martelada sobre um placa de aço, denominado de batida de válvula.

Uma vez que já se estudou as fontes dos defeitos e o modo como eles são gerados, faz-se necessário conhecer na sequência, a forma como a energia vibratória causada por eles é transmitida até o ponto de medição de sinal de vibração. Tal conhecimento é conseguido calculando-se a função de resposta em frequência, discutida na próxima seção.

2.4 Os Fundamentos da Função de Resposta em Frequência(FRF).

A função de transferência é um modelo matemático que define relações de entrada-saída de sistemas físicos. Na Figura 2.8 está mostrado o diagrama de blocos de um sistema de uma entrada e uma saída.



Figura 2.8- Diagrama de blocos de um sistema de uma entrada e uma saída.

A função de transferência de um sistema como o que está mostrado na Fig. 2.8 é definida como a razão entre a transformada de Laplace da saída e a transformada de Laplace da entrada, Eq. 2.1 .

$$H(s) = \frac{A(s)}{F(s)} \quad (2.1)$$

A função de resposta em frequência(FRF) é definida de forma similar à função de transferência e está matematicamente relacionada com a mesma. A FRF do sistema da Fig. 2.8 é dada pela razão entre a transformada de Fourier da saída e a transformada de Fourier da entrada :

$$H(f) = \frac{A(f)}{F(f)} \quad (2.2)$$

Dadas as definições acima pode-se concluir que a FRF é a função de transferência do sistema vista no plano $j\omega$ do espaço de Laplace, como está ilustrado na Figura 2.9.

Ao contrário da função de transferência, a FRF pode ser obtida facilmente através de medições experimentais e, fisicamente, representa a forma como a energia aplicada ao sistema no ponto de excitação é transmitida ao ponto de medição da resposta, no domínio da frequência.




Figura 2.9- Representação do espaço de Laplace. Ilustração de uma função de transferência em 3D.

Na Figura 2.9 é mostrado o gráfico tridimensional da transformada de Laplace de um sistema de dois graus de liberdade. Para as frequências naturais do sistema, observadas no gráfico da magnitude, a parte real passa por zero e a parte imaginária apresenta pontos de máximo ou mínimo. No gráfico da fase, sabe-se que há uma defasagem de 90° entre os sinais de excitação e de resposta do sistema.

2.5 – Os Estimadores da FRF.

Admitindo-se a existência de um conjunto de dados $a(t)$, de comprimento total T_r , estacionário, com média $\bar{a} = 0$, representando a resposta de um sistema dinâmico, pode-se dividir este conjunto em (n) seguimentos de dados, cada um de comprimento (T) , de modo que para cada seguimento $a_i(t)$, $(i-1)T \leq t \leq iT$, $i=1,2 \dots n$, como mostra a Fig. 2.10. Com o objetivo de tornar o conjunto de dados tratável computacionalmente, o mesmo deve ser discretizado em intervalos de tempo (dt) , de maneira que cada seguimento $a_i(t)$ possa ser representado por um vetor de (N) posições, tal que $T=N \cdot dt$ e $T_r=n \cdot N \cdot dt$.




Figura 2.10 - Subdivisão do conjunto $a(t)$ em (n) segmentos de comprimento (T) .

Discretizando-se o sinal de excitação do sistema, $f(t)$, da mesma maneira como feito para o sinal de resposta, $a(t)$, as funções de auto densidade espectral do sinal de entrada(f) e de saída(a) e, a função de densidade espectral cruzada unilateral, podem ser estimadas utilizando-se respectivamente as Eq. 2.3 a 2.5 que se seguem. Estas equações, bem como toda a formulação apresentada nesta seção, foram obtidas em (Bendat & Pierson, 1986).

$$\mathbf{G}_{ff}(f_k) = \frac{2}{N \cdot dt} \frac{1}{n} \sum_{i=1}^n [F_i^*(f_k) \cdot F_i(f_k)] \quad (2.3)$$

$$\mathbf{G}_{aa}(f_k) = \frac{2}{N \cdot dt} \frac{1}{n} \sum_{i=1}^n [A_i^*(f_k) \cdot A_i(f_k)] \quad (2.4)$$

$$\mathbf{G}_{fa}(f_k) = \frac{2}{N \cdot dt} \frac{1}{n} \sum_{i=1}^n [F_i^*(f_k) \cdot A_i(f_k)] \quad (2.5)$$

$$\mathbf{G}_{af}(f_k) = \mathbf{G}_{fa}^*(f_k) \quad (2.6)$$

Onde :

- $k = 0, 1, \dots, N/2$.
- F Transformada de Fourier do sinal de entrada f ($\text{fft}(f)$).
- A Transformada de Fourier do sinal de saída a ($\text{fft}(a)$).

- (*) símbolo que significa complexo conjugado .

Como pode ser observado o processo de média para a estimação das funções é efetuado para $N/2$ pontos dos vetores F e A .

Para simplificar o entendimento de como calcular os estimadores da função de resposta em frequência, nas próximas seções, pode-se assumir que o número (n) de vetores de dados é muito grande, de maneira, que o erro cometido ao utilizar os estimadores das funções densidade espectral no lugar de seus valores exatos, seja desprezível.

2.5.1 - FRF de Sistemas Sem Ruído Aditivo.




Figura 2.11- Sistema sem ruído.

Para sistemas de uma entrada e uma saída como o que está esquematizado na Figura 2.11, nos quais, não existem ruídos estranhos contaminando as medições, os sinais de entrada e saída são idênticos aos sinais de entrada e saída efetivos(sem ruído). Nesta circunstância existem dois modos de se calcular a FRF, dados pela Eq. 2.7 .


$$H(f) = H_1(f) = \frac{G_{fa}(f)}{G_{ff}(f)} = H_2(f) = \frac{G_{aa}(f)}{G_{af}(f)} \quad (2.7)$$

onde $G_{af} = G_{fa}^*$.

Na hipótese de ausência de ruídos, a função de coerência, Eq. 2.8 tem valor unitário em toda a banda de frequências. Nos experimentos reais sempre existe algum tipo de ruído contaminando as medidas, de sorte que H_1 e H_2 são, em geral, diferentes, e esta diferença, para uma dada frequência, será tanto mais acentuada quanto menor for o valor da função de coerência. Fisicamente, a função de coerência indica o quanto o sinal de saída de determinado sistema está linearmente correlacionado com o sinal de entrada do mesmo.

$$0 \leq \gamma_{fa}^2(f) = \frac{|G_{fa}(f)|^2}{G_{aa}(f) \cdot G_{ff}(f)} \leq 1 \quad (2.8)$$

2.5.2 - FRF de Sistemas com Ruído Aditivo na Saída.



onde: $f(t)=u(t)$, $a(t)=v(t)+n(t)$.

Figura 2.12 - Sistema com ruído na saída.

A Fig. 2.12 apresenta o esquema de um sistema com ruído aditivo na saída. G_{uu} e G_{vv} são os espectros coerentes da entrada e da saída respectivamente e, G_{nn} é o espectro do ruído. Admitindo a hipótese de que o ruído não possui correlação com o sinal de entrada, nem com o sinal de saída, obtém-se: $G_{ff} = G_{uu}$, $G_{uv} = G_{fa}$ e, $G_{aa} = G_{vv} + G_{nn}$.

Então um estimador da FRF de um sistema como o mostrado na Figura 2.12 é dado por:

$$H(f) = \frac{G_{uv}(f)}{G_{uu}(f)} = H_1(f) = \frac{G_{fa}(f)}{G_{ff}} \quad (2.9)$$

Pode-se observar que o estimador da FRF calculado pela Eq. 2.9 elimina a influência do ruído aditivo no sinal de saída. Outro estimador para a FRF deste sistema é o calculado pela Eq. 2.10.


$$H_2(f) = \frac{G_{aa}(f)}{G_{af}(f)} = \frac{G_{vv}(f) + G_{nn}(f)}{G_{vu}} = \frac{G_{vv}(f)}{G_{vu}} + \frac{G_{nn}(f)}{G_{vu}} = H(f) + \frac{G_{nn}(f)}{G_{vu}} \quad (2.10)$$

Usando-se o estimador H_2 , o resultado obtido será uma função superestimada da FRF, principalmente nas frequências onde G_{nn} for significativo quando comparado com G_{vu} . Isto pode ser verificado pela função coerência na Eq. 2.11 e, pelos espectros do ruído e da saída, na Eq. 2.12.

$$\gamma_{fa}^2(f) = \frac{|G_{fa}(f)|^2}{G_{aa}(f) \cdot G_{ff}(f)} = \frac{|G_{fa}(f)|^2}{G_{uu} \cdot (G_{vv}(f) + G_{nn}(f))} < 1 \quad (2.11)$$

$$\mathbf{G}_{vv} = \gamma^2_{fa} \mathbf{G}_{aa}, \quad \mathbf{G}_{nn} = (1 - \gamma^2_{fa}) \mathbf{G}_{aa} \quad (2.12)$$

2.5.3 - FRF de Sistemas com Ruído Aditivo na Entrada.



onde : $f(t)=u(t)+m(t)$, $a(t)=v(t)$.

Figura 2.13 - Sistema com ruído aditivo na saída.

Na Fig. 2.13 está representado esquematicamente um sistema com ruído aditivo na entrada. G_{uu} e G_{vv} são os espectros coerentes da entrada e da saída respectivamente e, G_{mm} é o espectro do ruído adicionado na entrada.

Com base na hipótese de que o ruído não possui correlação com o sinal de entrada, nem com o sinal de saída, obtém-se: $G_{ff} = G_{uu} + G_{mm}$, $G_{uv} = G_{fa}$, e $G_{aa} = G_{vv}$. Um estimador da FRF deste sistema é mostrado na Eq.2.13.

$$\mathbf{H}_2(f) = \frac{\mathbf{G}_{vv}(f)}{\mathbf{G}_{vu}(f)} = \frac{\mathbf{G}_{aa}(f)}{\mathbf{G}_{af}} = \mathbf{H} \quad (2.13)$$

Pode-se concluir pela Eq. 2.13 que H_2 é a melhor estimativa para a FRF do sistema, dado que nesta o efeito do ruído é eliminado. Utilizando-se o estimador H_1 , mostrado na Eq. 2.14, o resultado será uma função subestimada da FRF, principalmente nas frequências onde G_{mm} for significativo, quando comparado com G_{uu} , o que pode ser verificado pela função de coerência e pelo espectro do ruído dado na Eqs. 2.15 e 2.16 respectivamente. Na Eq. 2.17 está mostrada a forma de cálculo do espectro coerente do sinal de entrada.

$$H_1(f) = \frac{G_{fa}(f)}{G_{ff}(f)} = \frac{G_{uv}(f)}{G_{uu}(f) + G_{mm}(f)} = \frac{G_{uv}(f)}{G_{uu}(f) \left(1 + \frac{G_{mm}(f)}{G_{uu}(f)}\right)} = \frac{H}{\left(1 + \frac{G_{mm}(f)}{G_{uu}(f)}\right)} \Rightarrow H_1 < H \quad (2.14)$$

$$\gamma_{fa}^2(f) = \frac{|G_{fa}(f)|^2}{G_{aa}(f) \cdot G_{ff}(f)} = \frac{|G_{uv}(f)|^2}{(G_{uu}(f) + G_{mm}(f))} < 1 \quad (2.15)$$

$$G_{mm} = (1 - \gamma_{fa}^2(f)) G_{ff} \quad (2.16)$$

$$G_{uu} = \gamma_{fa}^2(f) \cdot G_{ff} \quad (2.17)$$

Deve ser mencionado que todas as FRFs calculadas neste trabalho foram obtidas usando o estimador H1, pois, de acordo com (Bendat & Pierson, 1986), este é o melhor estimador na hipótese de existir ruído aditivo correlacionado com o sinal de saída.

2.6 - As Funções de Resposta em Frequência de Interesse.

Com o objetivo de identificar as bandas de frequência de interesse na caracterização das falhas dos motores, fez-se necessário o conhecimento da função de resposta em frequência (FRF) entre cada elemento gerador de falha e o ponto de medição do sinal de vibração (na tampa do compartimento do eixo comando de válvulas). O sistema de aquisição do sinal usado para obter as estimativas de cada FRF constituiu-se de:

- 01 acelerômetro uniaxial, Bruel & Kjaer, sensibilidade = 1.94 pC/ms^{-2} ;
- 01 martelo de impacto, Bruel & Kjaer, com sensibilidade da célula de carga = 1.03 pC/N ;
- 01 conversor A/D de 12 bits, com dois canais simultâneos;
- 01 micro computador portátil equipado com programa de interface para o conversor A/D;
- Programa para cálculo do estimador das FRFs;

Na Fig. 2.14 pode ser visto o esquema de como os instrumentos da cadeia de medição são interligados durante a efetuação da análise modal do motor.




Figura 2.14 - Esquema da cadeia de medição utilizada na obtenção da FRF do tensor da correia do alternador: martelo de impacto instrumentado com célula de carga(a); acelerômetro(b); condicionadores de sinal(c); conversor analógico/digital(d); microcomputador com programas de interface para o conversor A/D e para cálculo das FRFs.

Na Fig. 2.15 é mostrada uma ilustração fotográfica do procedimento de excitação do tensor da correia do alternador, para a obtenção da FRF entre este tensor e o ponto de medição da resposta.




Figura 2.15 – Ilustração da excitação efetuada sobre o tensor da correia do alternador(b) para a obtenção da FRF entre este e a tampa da caixa do eixo comando de válvulas, onde foi posicionado o acelerômetro(a); martelo de impacto instrumentado(c).

Através da célula de carga acoplada ao martelo de impacto, Fig 2.15-c, a força excitação aplicada ao sistema, de natureza impulsiva, é adquirida, simultaneamente à aquisição do sinal vibratório resultante.

Na Fig. 2.16-a está mostrada a FRF entre o tensor da correia do alterador e a tampa da caixa do eixo comando de válvulas. Observando esta FRF conjuntamente com suas partes, real Fig. 2.16-b, imaginária Fig. 2.16-c e, com o a função de coerência Fig. 2.16-d, podem ser localizadas bandas de frequência em [480,520], [780,820], [1180,1220], [1430, 1460] e [2080, 2120]Hz, nas quais ocorre maior amplificação da energia de vibração gerada no rolamento do tensor da correia do alternador e que é mensurada na tampa da caixa do eixo comando de válvulas. As frequências centrais destas bandas são as frequências

naturais da estrutura analisada, assim, em tais frequências, o gráfico da parte real passa por zero, o gráfico da parte imaginária apresenta máximos ou mínimos e a função de coerência possui valor próximo da unidade.

Na Fig. 2.17-a, está mostrada a FRF entre o tensor da correia sincronizadora e a tampa da caixa do eixo comando de válvulas. Para esta FRF, observada conjuntamente com as Figs 2.17-b, 2.17-c e 2.17-d, podem ser localizadas bandas de frequência entre [700,1100], [1800,2200] e [2600, 2850] Hz onde ocorre maior amplificação da energia de vibração gerada no rolamento do tensor da correia sincronizadora e que é mensurada na tampa da caixa do eixo comando de válvulas.

Na Fig. 2.17-a é mostrada a FRF entre o eixo comando de válvulas e a tampa da caixa do eixo comando de válvulas. Nesta pode ser localizada uma banda de frequência entre [1250,2750] Hz na qual ocorre maior amplificação da energia de vibração gerada na interface came-tucho de válvula e que é mensurada na tampa da caixa do eixo comando de válvulas.




Figura 2.16 - FRF entre: tensor da correia do alternador e tampa da caixa do eixo comando de válvulas.




Figura 2.17 - FRF entre: tensor da correia sincronizadora e tampa da caixa do eixo comando de válvulas.




Figura 2.18- FRF entre eixo comando de válvulas e tampa da caixa do eixo comando de válvulas.

No início do trabalho pouco se sabia a respeito do comportamento dinâmico do motor, assim, com o intuito de conhecer a influência de outros mecanismos na resposta vibratória do mesmo, foram elaborados gráficos como os que estão mostrados nas figuras 2.16 a 2.18, a partir dos quais foi construída a tabela 2.2 .

Tabela 2.2 - Bandas de Frequência nas quais se verifica a amplificação do sinal de vibração que se propaga entre cada mecanismo(primeira coluna da tabela) ao ponto de medição da resposta (para todos mecanismos, a resposta foi medida sobre a tampa da caixa do eixo comando de válvulas, Fig. 2.15-a)

Mecanismo no qual é feita a excitação.	Bandas de Frequência(s) nas quais se verifica a amplificação do sinal de vibração.
Biela	[2750, 2810], [5590, 5650]
Virabrequim	[1440,1500], [2000, 2050]
Bomba D'água(excitação na polia)	[1130,1190], [2260, 3020] [5440, 5500], [6140, 6200]
Bomba D'água(excitação na correia)	[1130, 1190], [2960, 3010] [5440, 5600], [6140, 6700]
Tensor da correia sincronizadora (excitação no rolamento)	[700,1100], [1800,2200] [2600, 2850]
Tensor da correia sincronizadora (excitação na correia)	[3900, 4000]
Polia do Comando(excitação na polia)	[830, 880], [1760, 1780]
Polia do Comando(excitação na correia)	[830, 880], [1760, 1780]
Altrenador(excitação na polia)	[340, 380], [410, 450] [790, 820], [1140 , 1180]
Alternador(excitação na correia)	[345, 380], [400, 450] [800, 830], [1140,1170]
Motor de partida	[430, 460], [1320,1360] [2490, 2530], [4440,4490]
Tensor da correia do alternador (excitação no rolamento)	[480,520],[780,820], [1180,1220] [1430, 1460], [2080, 2120]
Tensor da correia do alternador (excitação na correia)	[500, 570]
Eixo Comando de Válvulas	[1250,2750]

Capítulo III

Aquisição e Pré-processamento do Sinal de Vibração dos Motores

Neste capítulo serão apresentados alguns detalhes da aquisição e do pré-processamento do sinal de vibrações dos motores, cuja ferramenta principal a técnica do envelope.

3.1 Uma Visão Geral do Sistema de Diagnóstico Automático de Falhas

O diagnóstico de falhas em máquinas ou em componentes é, intrinsecamente, uma tarefa de classificação. O sistema de controle de qualidade de funcionamento dos motores desenvolvido neste trabalho, como será detalhado nos próximos capítulos, opera de acordo com o esquema da Fig. 3.1.




Figura 3.1- Esquema do sistema de controle da qualidade de funcionamento dos motores.

3.2 A Aquisição do Sinal de Vibração

O monitoramento de sistemas através de sinais de vibração apresenta duas características desejáveis: possibilita a detecção de falhas incipientes, as quais geram diminutas quantidades de energia vibratória e, por ser um ensaio não destrutivo, permite a obtenção da assinatura de vibrações do sistema em plena operação.

Algumas dificuldades, entretanto, são encontradas durante a disponibilização do sinal de vibração para a análise: elevada sensibilidade, que o torna muito vulnerável à contaminação por ruído, e a necessidade do conhecimento prévio das características e dos efeitos do fenômeno, em estudo, como feito no capítulo II.

Antes de cada aquisição de sinal, os motores testados foram colocados em funcionamento à uma rotação constante de 3100 rpm, sujeitos entretanto, a pequenas oscilações em torno deste valor, devido às características de funcionamento inerentes a um motor de explosão operando sem carga. Quando o motor está frio tais oscilações são mais acentuadas, por isso, aguardou-se que o eletroventilador de arrefecimento ligasse e desligasse por uma vez antes de iniciar a aquisição dos dados.

Na Fig. 3.2 pode ser vista uma das bancadas prova-motor da linha de montagem. À frente, pode ser visto o sistema de aquisição de dados, constituído de um acelerômetro, um condicionador de sinal, um conversor analógico/digital, um programa de interface para o conversor A/D, com o qual é feito o controle da aquisição, e um microcomputador portátil.




Figura 3.2- Bancada prova-motor e sistema de aquisição de dados na linha de montagem.

Na Fig. 3.3 é mostrado o posicionamento do sensor de vibração do motor. A escolha deste ponto foi feita com base em dois critérios. Um deles é a facilidade de montagem e desmontagem do sensor durante o teste do motor, permitindo que o teste fosse realizado tanto no banco de provas, sobre uma bancada, quanto no veículo em marcha. O outro, é que a tampa do compartimento do eixo comando de válvulas funciona como um mecanismo amplificador do sinal proveniente dos defeitos, por se tratar de uma estrutura com características de membrana, fixada apenas através do perímetro externo.

Na Fig. 3.4 é mostrado um esquema ilustrativo do fluxo do sinal durante a sua aquisição, desde o sensor até o dispositivo de armazenamento. Inicialmente a energia vibratória se propaga na estrutura, a partir da fonte geradora de vibração, até o acelerômetro, Fig. 3.4a, onde ela é trasnduzida em um sinal elétrico. Do acelerômetro, o sinal elétrico segue para o condicionador, Fig. 3.4b, onde é amplificado e submetido à um filtro anti-fantasma. Posteriormente, o sinal elétrico é digitalizado através de um conversor A/D, Fig. 3.4c, e finalmente, é armazenado em algum dispositivo de memória, usualmente em um disco rígido, disponibilizando-o para o pós-processamento, que será estudado na próxima seção.




Figura 3.3- Posicionamento do sensor de vibração no motor: acelerômetro(a); tampa do compartimento do eixo comando de válvulas(b).




Figura 3.4- Esquema ilustrando o fluxo do sinal durante a aquisição. Acelerômetro (a); condicionador de sinal (b); conversor análogo/digital (c); micro computador portátil para gerenciamento da aquisição e gravação dos dados(d).

3.3 O Pré-processamento e a Redução de Dados

Dispondo-se do sinal gravado em disco, a próxima etapa a ser executada é a aplicação da técnica do envelope ao mesmo, disponibilizando-o para a extração das características associadas aos defeitos. Nesta primeira etapa do pré-processamento, já se consegue uma redução de dados da ordem de 95% em relação ao sinal no domínio do tempo.

O sinal de vibração de uma máquina na qual são gerados choques impulsivos periódicos tem muita semelhança com um sinal modulado em amplitude, sendo que as frequências de ressonância da estrutura podem ser consideradas como sendo as frequências portadoras. Existe, entretanto, diferença entre a verdadeira modulação em amplitude e a resposta de um sistema mecânico à entradas impulsivas periódicas. (Geropp,1995) mostrou que esta diferença pode ser desprezada se o fator de amortecimento da estrutura for grande, neste caso, a resposta vibratória pode ser considerada como um sinal modulado em amplitude.

Atualmente, uma das técnicas mais eficientes de se demodular um sinal em amplitude é a técnica do envelope. (Bendat,1986) e (Braun,1986) apresentaram uma metodologia de obtenção do envelope usando a transformada de Hilbert, que mostrou-se computacionalmente onerosa, por envolver uma transformação direta e uma transformação inversa de Fourier, de cada amostra temporal do conjunto de dados que representa uma condição de funcionamento do motor.

Com o objetivo de minimizar o esforço computacional envolvido no cálculo do envelope do sinal, (Angelo,1987) desenvolveu uma metodologia baseada em filtros, esquematizada na Fig. 3.5.




Figura 3.5- Esquema da técnica do envelope, adaptado de (Angelo,1987).

Esta técnica é implementada através dos seguintes procedimentos:

1 - O sinal no tempo do motor com defeito, ilustrado na Fig. 3.5a, é filtrado com um filtro passa-banda de frequência central $f_{c1}=(f_1+f_2)/2$ e largura da banda $b=(f_2-f_1)$, na qual se verifica o aumento no nível da vibração em relação a um motor sem defeito, como ilustrado na Fig. 3.5b. O sinal resultante desta operação, no tempo e na frequência, está ilustrado respectivamente nas Fig. 3.5c e Fig. 3.5d. As informações contidas neste sinal são isentas da maioria dos contaminantes provenientes de outras fontes de vibração(ruídos).

2 - O sinal é agora retificado e filtrado com um filtro passa-baixo, adotando-se uma frequência de corte com valor igual à metade da largura da banda da filtragem feita no item 1, isto é $f_{c2}=(f_2-f_1)/2$. O sinal resultante, no tempo, é ilustrado na Fig. 3.5e.

3 - Aplicando a transformada de Fourier ao sinal resultante do item 2 obtêm-se, finalmente, o espectro do envelope, ilustrado na Fig. 3.5f.

As Fig. 3.6 à 3.10 exemplificam os resultados obtidos em cada uma das etapas da técnica do envelope.

Na Fig. 3.6 são mostrados trechos de sinais de dois motores: um motor sem defeito e outro com tensor da correia sincronizadora rumoroso. Desta figura, que corresponde à Fig. 3.5a, a única inferência que pode ser feita, é que o motor com tensor rumoroso apresenta amplitudes de vibração mais elevadas em relação ao motor sem defeito. Nesta nota-se a dificuldade em se realizar qualquer análise que identifique a origem dos defeitos a partir de sinais no domínio do tempo.




Figura 3.6 - Trecho de sinal de motores: com e sem defeito.

Na Fig. 3.7, correspondente à Fig. 3.5b, são mostrados os auto-espectros dos sinais apresentados na Fig. 3.6, obtidos efetuando-se dez médias entre dez trechos análogos ao da Fig. 3.6. Pode ser visto, que há uma sobre-elevação do sinal correspondente ao motor com defeito em torno de 3000 Hz. Isto pode ser melhor observado na Fig. 3.8, que é uma ampliação da Fig. 3.7 no intervalo de [2700, 4750] Hz. Nesta figura está mostrada a banda na qual o sinal deve ser filtrado, correspondente à etapa 1 do esquema da técnica do envelope.

Na Fig. 3.9, está mostrado o envelope dos sinais mostrados na Fig. 3.6 (correspondente à Fig. 3.5e), também obtidos com dez médias, onde se pode observar picos semelhantes às entradas impulsivas produzidas nos rolamentos.

E finalmente na Fig. 3.10 (correspondente à Fig. 3.5f) é mostrado o espectro do envelope, do qual se pode extrair importantes informações à respeito da condição de funcionamento dos motores associados.




Figura 3.7- Auto espectro do sinal de aceleração mostrado no domínio do tempo na Fig. 3.6.




Figura 3.8- Ampliação do auto espectro da Fig. 3.7, entre 2700 e 4750 Hz .




Figura 3.9- Envelope dos sinais mostrados na Fig. 3.6, no domínio do tempo.




Figura 3.10- Espectro do envelope do sinal de aceleração.

A defasagem entre os picos nos espectros do envelope, observada na Fig. 3.9, é causada pela diferença na frequência de rotação(média) do motor durante a aquisição do sinal de vibração, e deve ser cuidadosamente considerada durante a fase de extração das características.

O procedimento que levou à construção da Fig. 3.10, foi aplicado aos sinais associados a cada tipo de defeito considerado neste trabalho. Nota-se, à primeira vista, a dificuldade de se analisar esta curva sem informações adicionais que melhor caracterizem a natureza do sinal. Este assunto será explorado no próximo capítulo

Capítulo IV

Extração das Características dos Sinais e Definição dos Padrões Associados aos Defeitos.

O sinal de vibração de um motor de combustão interna é composto de uma complexa combinação de respostas de múltiplas fontes de excitação. A chave para uma análise consistente é a redução deste sinal em suas componentes individuais, possibilitando a correlação das informações contidas no sinal com os defeitos encontrados.

Neste capítulo, é apresentada uma metodologia para extração das informações contidas no sinal de vibração dos motores, que intrinsecamente, constitui uma técnica de redução de dados. Um modelo cinemático de mancal de rolamento é utilizado como ponto de partida para a construção dos padrões associados às falhas nos dois tensores. Em seguida, utilizando-se de relações cinemáticas ordinárias, são construídos os padrões associados ao defeito de batida de válvula.

4.1 Análise no Domínio do Tempo

Uma maneira de extrair informações de sinais vibratórios, é analisar o seu comportamento no domínio do tempo. Apenas a título de ilustração, é apresentado a seguir o exemplo de um sistema motor – rotor desbalanceado, como mostrado na Fig. 4.1.

O gráfico da amplitude na Fig. 4.1 mostra claramente o comportamento vibratório do sistema com o tempo, que pode ser associado com as posições do desbalanceamento mostradas acima deste gráfico. Como os sensores de posição e de velocidade estão montados com uma defasagem física de 90° , o máximo valor positivo da amplitude de vibração coincidirá com o pulso gerado pela passagem da fita reflexiva na frente do sensor ótico do tacômetro. A amplitude do sinal será proporcional à grandeza do desbalanceamento e à velocidade de rotação do rotor.

Como se pode notar, este sinal é fácil de ser analisado, pois, neste exemplo, admite-se a existência de uma única fonte de excitação. Os sinais reais, entretanto, são muito mais complexos, tal como o trecho do sinal de vibração de um motor mostrado na Fig. 3.6, onde a

análise fica muito mais difícil. A saída é então partir para a extração das informações no domínio da frequência, o que é tratado na próxima seção.




Figura 4.1- Esquema de um sistema motor - rotor desbalanceado – mancais, sinal do tacômetro(a); sinal do sensor de deslocamento(b).

4.2 Análise no Domínio da Frequência

A grande vantagem da análise no domínio da frequência é que, praticamente, qualquer sinal oriundo de um sistema físico, expresso no domínio do tempo, pode ser decomposto em componentes senoidais, conforme mostrou Fourier um século atrás (Dimarogonas,1995), sem que, com a transformação, nenhuma informação seja perdida, nem mesmo de fase.

A Fig. 4.2 ilustra melhor a idéia da transformação de domínio tempo/frequência. No gráfico amplitude x tempo, observam-se os sinais vibratórios correlacionadas com as suas respectivas fontes e, mais à frente, no mesmo gráfico, está mostrado o sinal (sa) que é captado através do sensor de vibração sobre a tampa do compartimento do eixo comando de válvulas. Com base no sinal (sa) pouca ou nenhuma inferência pode ser feita à respeito da origem dos defeitos. Pela aplicação da transformada rápida de Fourier sobre o sinal (sa), cujo resultado é mostrado no

gráfico amplitude x frequência, torna-se possível identificar os seus componentes e, assim, correlacioná-los com a fonte do defeito.

Esta é a idéia básica de um procedimento de identificação de falhas em um sistema mecânico, a partir da análise de sinais de vibração. Neste exemplo foi assumido que os sinais provenientes dos defeitos são senóides simples, todavia, isto não corresponde à realidade, sendo que frequentemente, é necessária a utilização de técnicas avançadas de análise de sinais no domínio da frequência para que se consiga extrair informações coerentes a respeito do sistema. A técnica de análise utilizada neste trabalho é a técnica do envelope, discutida na seção 3.3, que é citada na literatura como uma das mais eficientes técnicas para o trato com defeitos tais como os estamos preocupados em identificar.




Figura 4.2 - Esquema ilustrando a correlação dos componentes do sinal de vibração com suas respectivas fontes.

4.3 Análises Preliminares no Domínio da Frequência

Durante o processo de análise de sinais dos motores, objetivando extrair deles as informações relacionadas com os defeitos, foram identificadas no auto espectro de vibrações, três bandas de frequência apresentando sensibilidade às falhas: B1=[600-1200]Hz, B2=[1600-2100] Hz; B3=[2800-4800] Hz. Para elaborar os padrões de defeito, a partir da variação na resposta vibratória dos motores defeituosos, em relação aos sem defeito, algumas considerações devem ser feitas para cada condição de funcionamento.

Rumorosidade nos tensores

Observou-se em vários testes realizados, que a sobre-elevação no auto espectro de um motor que apresentava problema em um dos tensores, ou nos dois tensores, relativamente a um motor sem defeito, sempre ocorreu dentro do intervalo de frequência correspondente à banda B3, como ilustrado nas Figs. 4.3 e 4.4. Tal sobre-elevação em geral, não ocupava toda a banda B3, assim, a fim de facilitar a extração das informações contidas no espectro do envelope e minimizar o esforço computacional na construção dos padrões da condição de funcionamento dos motores, foi executado o seguinte procedimento:

1 - Dividiu-se a banda B3 em três regiões de frequência: B31=[2800-3800], B32=[3300-4300] e B33=[3800-4300].

2 - Para cada uma dessas bandas de 1000 Hz , com superposição de 500 Hz, calcula-se o valor RMS do auto espectro de vibração dos motores, com e sem defeito, de modo a obter-se R_{max} , dado pela Eq. 4.1.

$$R_{max} = \max \left(\frac{RMS(Gaa)_{motor\ defeituoso}}{RMS(Gaa)_{motor\ sem\ defeito}} \right)_{Bi} \quad (4.1)$$

onde :

Gaa - auto espectro do sinal de aceleração.

RMS - raiz quadrada da média quadrática.

Bi - banda de análise.

3 - Observou-se, nos casos testados, que para valores de $R_{\max} > 1.8$, a rumorosidade em um dos tensores, ou em ambos, está acima do limite aceitável (de acordo com os critérios subjetivos do fabricante). Quando isto ocorria a técnica do envelope era executada na banda correspondente ao $R_{\max}$.

4 - Valores de $R_{\max} < 1.8$ indicam que o motor opera apresentando um nível aceitável de rumorosidade dos tensores.

Rumorosidade de batida de válvula(s)

Outra inferência feita a partir dos testes é que, se o motor apresenta somente o problema de batida de válvula, a sobre-elevação no auto espectro do motor defeituoso ocorria, de maneira mais acentuada, em uma das bandas, B1 ou B2, ou nas duas. Na Fig. 4.5 está mostrado um exemplo de sinal de um motor com rumorosidade de batida de válvula(s) inaceitável, e na Fig. 4.6 é mostrada uma ampliação da Fig. 4.5 na faixa de [0-2000] Hz. Nesta, é possível de se identificar a sobre-elevação no sinal do motor com batida de válvula em relação ao motor sem defeito na faixa de frequências correspondente à banda B1.

Também foi constatado durante a análise dos dados, que, para os motores apresentando rumorosidade de batida de válvula(s) inaceitável, $R_{\max} > 6.5$ na banda B1, ou, $R_{\max} > 6.0$ na banda B2, ou $R_{\max} > 6.0$ em ambas.

Rumorosidade simultânea, dos tensores e de batida de válvula

Como já foi dito, a sobre-elevação no auto espectro de um motor que apresentava problema em um dos tensores, ou nos dois, ocorre na banda B3, todavia, da análise dentro desta banda, ainda é possível detectar problema de batida de válvula(s). Isto ocorre porque quando um motor possui o problema em um dos tensores, a energia vibratória gerada pela batida de válvula(s) é carregada para a banda B3, amplificando a vibração nos dez primeiros harmônicos correspondentes à frequência de rotação do eixo comando de válvulas. Deste modo, se o motor possui simultaneamente os três defeitos, a análise feita somente em uma das bandas B31, B32 ou B33, será suficiente para a detecção e identificação do tipo de defeito que o motor apresenta.




Figura 4.3 - Motor com tensor da correia sincronizadora rumoroso.




Figura 4.4 - Motor com tensor da correia do alternador rumoroso.




Figura 4.5 - Motor com rumorosidade nos tensores aceitável, mas com batida de válvula.




Figura 4.6 - Motor com rumorosidade nos tensores aceitável, mas com batida de válvula. Ampliação da Fig. 4.5 na faixa de [0-2000] Hz.

Através de uma simples comparação entre os valores do $R_{\max}$ do sinal nas bandas B1 e B2, com os valores de referência encontrados, é possível avaliar a condição de funcionamento do motor em termos de rumorosidade de batida de válvula(s). Por outro lado, as informações presentes na banda B3 necessitam ser analisadas por uma rede neural, pois para esta banda é preciso, não só diagnosticar a presença de defeito, mas também, identificar qual é a sua origem.

4.4 Identificação Discriminatória de Defeitos no Domínio da Frequência

Como discutido na seção 4.2, se a sobrelevação do sinal do motor defeituoso em relação ao motor sem defeito ocorrer na banda B3=[2800-4800] Hz, o sinal deverá ser processado através da técnica do envelope, cujo resultado é o espectro do envelope, como o que está mostrado na figura 4.7.

Uma vez determinados os espectros do envelope dos sinais associados a cada tipo de defeito considerado neste trabalho, à primeira vista, pouca diferença foi encontrada entre o espectro de um motor com tensor da correia de distribuição rumorosa e o espectro de um motor com tensor da correia sincronizadora rumorosa. Uma alternativa seria utilizar todo o espectro para treinar uma rede capaz de distinguir qual é o tipo de defeito associado ao sinal. Esta não é a alternativa mais viável, pois um padrão com 600 parâmetros implicaria, como será visto na seção 5.4.1, em uma rede neural probabilística gigantesca e, conseqüentemente, muito onerosa em termos computacionais.




Figura 4.7 - Espectro do envelope do sinal de aceleração de um motor com tensor da correia sincronizadora rumoroso.

Uma possível abordagem para este problema é extrair do espectro completo apenas os componentes principais, como sugere (Masters,1995). Ainda assim, mesmo que se conseguisse uma redução da ordem de 95%, o número de parâmetros ficaria na casa dos 30, o que ainda resultaria em uma rede muito lenta de se treinar e de se utilizar.

Dadas as dificuldades citadas acima, utilizou-se de modelos cinemáticos dos rolamentos utilizados nos tensores para a definição dos padrões associados aos defeitos, o que resultou em padrões com 12 parâmetros, como mostrado na próxima seção.

4.5 Determinação das Frequências Características dos Rolamentos dos Tensores

Devido à dificuldade inicial na distinção dos defeitos associados à rumorosidade nos dois tensores, com base no espectro do envelope inteiro, foi utilizado um modelo de geração de vibrações em rolamentos com o qual se pôde determinar suas frequências características, conhecidas as suas dimensões e modo de operação. Estas frequências características são obtidas através das equações Eq. (4.1) a Eq. (4.4).

$$F_{pepe} = fc \left(\frac{n}{2} \right) \left(\frac{Fr}{60} \right) \left(1 - \frac{de}{p} \cos \phi \right) \quad (4.1)$$

$$F_{pepi} = fc \left(\frac{n}{2} \right) \left(\frac{Fr}{60} \right) \left(1 + \frac{de}{p} \cos \phi \right) \quad (4.2)$$

$$F_{ee} = fc \left(\frac{p}{2de} \right) \left(\frac{Fr}{60} \right) \left(1 - \left(\frac{de}{p} \right)^2 \cos^2 \phi \right) \quad (4.3)$$

$$F_t = \frac{fc}{2} \left(\frac{Fr}{60} \right) \left(1 - \frac{de \cos \phi}{p} \right) \quad (4.4)$$

Onde :

- F_{pepe} - frequência de passagem do elemento rolante na pista externa do rolamento.
- F_{pepi} - frequência de passagem do elemento rolante na pista interna do rolamento.
- F_{ee} - frequência de spin do elemento rolante.
- F_t - frequência do trem dos elementos rolantes.
- de - diâmetro do elemento rolante.
- p - módulo diametral do rolamento.
- Fr - frequência de rotação da pista girante em rpm.
- ϕ - ângulo de contato entre o elemento rolante e a pista de rolamento.
- fc - fator de correção

O fator fc foi inserido com o objetivo de melhorar o acerto na busca dos padrões associados aos defeitos, pois ele reduz a diferença entre os valores das frequências características calculadas e o valores encontrados na prática. Isto porque que as equações originais (Braun, 1986), foram deduzidas assumindo que os elementos rolantes executam somente

o movimento de rolamento, enquanto que na prática, estes podem apresentar movimentos de deslizamento em relação à pista de rolamento. O valor adotado para f_c foi de 0.975, determinado com base em observações de sinais de motores cuja condição de funcionamento era previamente conhecida. Outra medida que facilitou a definição dos padrões dos defeitos foi a inserção das frequências características de outro rolamento movido pela correia do alternador: o da bomba d'água. Com estas informações adicionais foi possível a elaboração dos padrões associados a cada tipo de defeito como é mostrado na próxima seção.

4.6 Definição dos Padrões Associados aos Defeitos nos tensores

Na definição dos padrões associados com os defeitos nos dois tensores, foram utilizados 12 parâmetros: a frequência central da banda analisada através da técnica do envelope e 11 frequências características dos rolamentos especificados no capítulo II, conforme mostra a Tabela 4.1.

Tabela 4.1. Descrição dos parâmetros constituintes dos padrões de defeito

nº	Identificação do(s) parâmetro(s)
1	Frequência central da banda analisada através da técnica do envelope, f_{c1}
2 a 8	Amplitude do espectro do envelope nas frequências características do rolamento do tensor da correia do alternador e do rolamento da bomba d'água.
9 a 12	Amplitude do espectro do envelope nas frequências características do rolamento do tensor da correia sincronizadora.

Na Fig. 4.8 cada padrão apresentado está identificado com uma dada condição de funcionamento do motor como segue: motor com tensor da correia sincronizadora ruidoso (padrão1); motor com tensor da correia do alternador ruidoso (padrão2); motor sem defeito (padrão3); motor com os dois tensores ruidosos (padrão4).

Numa primeira análise, baseando-se apenas na Fig. 4.8, existe uma grande tendência em se querer reduzir ainda mais o número de parâmetros dos padrões ali apresentados, todavia, é preciso levar em conta que um motor é um sistema não linear de complexidade apreciável.

Para que se entenda um pouco mais sobre o terreno em que se pisa, deve-se mencionar que apesar de ser fabricado e montado em série, cada motor apresenta características muito próprias em termos vibratórios, de maneira que dois motores com o mesmo tipo de falha podem,

perfeitamente, apresentar assinaturas de vibração muito diferentes. Isto se dá, devido à forma através da qual a energia de vibração é transmitida do ponto de geração até o ponto de medição, que é fortemente dependente da maneira como as partes estruturais do motor são ajustadas e fixadas. Isto pode ser comprovado ao longo da análise realizada sobre com os dados adquiridos dos motores.




Figura 4.8- Padrões associados às condições de funcionamento dos motores.

Algumas particularidades à respeito da elaboração dos padrões devem ser comentadas neste ponto. Uma delas diz respeito à referência usada no estabelecimento deste padrões, que foi definida satisfazendo os mesmos critérios utilizados pelo fabricante, pois, busca-se um critério objetivo, mas que atenda aos critérios subjetivos de avaliação usados pelos usuários e críticos do setor automotivo.

Como indicado na tabela 4.1, os parâmetros de 2 a 8 são os que possuem sensibilidade ao problema de rumorosidade no tensor da correia do alternador e, os de 9 a 12, os que possuem sensibilidade ao problema de rumorosidade no tensor da correia sincronizadora. Observando-se os padrões 1 e 2 na Fig. 4.8 pode ser visto o seguinte: os parâmetros 9,10 e 12 do padrão 2,

possuem níveis superiores aos parâmetros correspondentes do padrão 1. Então, numa primeira análise, o motor correspondente ao padrão 2 também possuiria problema de rumorosidade no tensor da correia sincronizadora, o que não corresponde à realidade. Da análise dos dados, foi observado que se um motor apresenta problemas com o tensor da correia do alternador, conseqüentemente ocorre uma elevação nos níveis dos parâmetros relacionados ao problema de rumorosidade no tensor da correia sincronizadora.

4.7 Definição dos Padrões Associados ao Defeito de Batida de Válvula.

As amplitudes do espectro do envelope na frequência de rotação do eixo comando de válvulas e nos seus nove primeiros harmônicos são os 10 parâmetros constituintes do padrão associado a um motor com rumorosidade de batida de válvula(s), visto que estas 10 frequências são suficientemente representativas para o diagnóstico. Tais padrões estão mostrados na Fig. 4.9 e são identificados como segue: motor sem batida de válvula(s) (padrão5); motor no limite de aceitabilidade para rumorosidade de batida de válvula(s) (padrão6); motor com rumorosidade de batida de válvula(s) inaceitável (padrão7).

Uma vez estabelecidos conjuntos de padrões como os mostrados nas seções 4.6 e 4.7, estes foram utilizados para o treinamento e a validação de uma rede neural.




Figura 4.9- Padrões associados às condições de funcionamento dos motores.

Capítulo V

A Rede Neural Probabilística

O algoritmo precursor da atual rede neural probabilística(PNN), foi descrito por (Meisel,1972), porém, permaneceu sub-utilizado até ser implementado como uma rede neural por (Specht,1990). O nome rede neural probabilística origina-se da teoria de probabilidade na qual a mesma se fundamenta.

A PNN é intrinsecamente um algoritmo projetado para executar tarefas de classificação, ou seja, a rede é treinada para avaliar amostras desconhecidas e associá-las com uma determinada classe do conjunto de treinamento.

Com o objetivo de exemplificar as sutilezas presentes no processo de treinamento, é apresentada a Fig. 5.1.




Figura 5.1- Exemplo 1 de um problema de classificação bivariável.

Nesta figura são mostradas duas classes (O,□), de modo que a coordenada horizontal de um elemento qualquer de uma das classes é definida por uma variável,

enquanto que a coordenada vertical é definida por outra variável. Se uma amostra desconhecida simbolizada na Fig. 5.1 por (?), for apresentada a um classificador que avalia apenas tendências centrais, ela será classificada como ($\square$), entretanto, esta amostra pertence verdadeiramente à classe dos (O). Um método que calcula a distância entre a amostra desconhecida e todos os membros do conjunto de treinamento, chamado comumente de “classificador do vizinho mais próximo”, terá bom desempenho numa circunstância como esta, entretanto, falha numa situação como a que é mostrada na Fig. 5.2. Verdadeiramente a amostra desconhecida(?) da Fig. 5.2 pertence a classe dos (O), a despeito de ela estar mais próxima de um membro da classe dos($\square$).

O argumento para sustentar tal afirmação é o fato de que a densidade dos ($\square$) em torno da amostra desconhecida(?) é muito pequena, enquanto que a densidade da classe dos (O) é muito maior. Basta observar que a classe dos (O) envolve a amostra desconhecida e que a classe dos ($\square$) possui apenas um representante da vizinhança da mesma. Esta é intuitivamente, a idéia central da PNN.




Figura 5.2- Exemplo 2 de um problema de classificação bivariável.

5.1 O método de classificação de Bayes

A rede PNN tem seus fundamentos no método estatístico de classificação de Bayes. Para explicar o método será admitida a existência de uma coleção de amostras aleatórias. Cada amostra, indexada de $k=1,2, \dots, K$ é um vetor $\mathbf{X} = \{x_1, x_2, \dots, x_m\}$. No caso mais geral admite-se que tais amostras tenham diferentes probabilidades, denominadas h_k . Quando um erro de classificação é cometido com um caso que certamente pertence à população k , o custo associado com este erro é c_k , entretanto, em muitos casos, senão na maioria deles, segundo (Masters, 1995), as probabilidades h_k são admitidas iguais para todas as amostras, e o mesmo é feito para o custo c_k .

A coleção completa é chamada conjunto de treinamento, contendo n_1 amostras da classe 1, n_2 amostras da classe 2, e n_k amostras da classe k . O que precisa ser gerado a partir deste procedimento é um algoritmo capaz de associar corretamente uma amostra desconhecida à uma das classes do conjunto de treinamento. Se for encontrado um algoritmo cujo custo de erro de classificação não seja maior do que qualquer outro, então este algoritmo é dito um Bayes ótimo.

Pode ser provado que se for fornecida a verdadeira função densidade de probabilidade (fdp) para toda a coleção de amostras, então existirá uma regra de decisão de Bayes ótima. O que se faz é classificar uma amostra desconhecida $\mathbf{X}$ como pertencente à uma classe i se :

$$h_i c_i f_i(\mathbf{X}) > h_j c_j f_j(\mathbf{X}) \quad (5.1)$$

para toda amostra $j \neq i$. A prova do que foi afirmado acima pode ser encontrado em muitas bibliografias de estatística, dentre elas (Koltz, 1982).

A densidade $f_k(\mathbf{X})$ corresponde à concentração de membros da classe k ao redor da amostra desconhecida, como discutido no exemplo da figura 5.2. Pela regra de Bayes, pode ser entendido que durante o processo de classificação se deve favorecer a classe que possui maior densidade de membros na vizinhança da amostra desconhecida. O problema da regra de Bayes é que geralmente não se conhece a verdadeira fdp $f_k(\mathbf{X})$, a solução é então utilizar uma estimativa para a mesma. (Parzen, 1962) apresenta um excelente estimador para a fdp unidimensional que converge para a verdadeira fdp quando o número de amostras cresce, que será estudado na próxima seção.

5.2 O Método Parzen de Estimação da fdp

O estimador da fdp de Parzen usa uma função de ponderação $W(d)$, também chamada de função Kernel(ou janela Kernel), que possui os maiores valores para $d=0$ e, cai rapidamente com o valor absoluto de d (por exemplo a função Gaussiana. Um Kernel é centrado em cada ponto da amostra, com o valor de cada uma destas funções, em uma coordenada x , determinado pela distância d entre x e o ponto da amostra. O estimador da fdp da amostra é uma soma escalonada destas funções para todos os casos da amostra, como ilustrado na Fig. 5.3, onde são observados oito pontos amostrais: [0.15, 0.20, 0.21, 0.25, 0.26, 0.35, 0.5 , 0.7]. Em cada um destes pontos amostrais foi centrada uma função Kernel bem comportada(linhas tracejadas), e é mostrado na mesma figura o gráfico do somatório ponderado destas funções janela(linha contínua).

O método Parzen é descrito matematicamente da seguinte forma:

Dado uma amostra de uma variável aleatória unidimensional de tamanho (n), a sua fdp pode ser estimada por:

$$g(x) = \frac{1}{n\sigma} \sum_{i=1}^n W\left(\frac{x - x_i}{\sigma}\right) \quad (5.2)$$

onde σ é o parâmetro de escala que define a largura da curva sino centrada em cada membro da coleção de dados.

Para que se possa ter uma idéia da influência do parâmetro de escala na estimação da fdp, são apresentadas as Fig. 5.4 a 5.6a. Estas quatro figuras foram geradas a partir da mesma amostra, e utilizando-se a mesma função de ponderação usada na elaboração da Fig. 5.3. Para um valor muito pequeno de σ , como é o caso da Fig. 5.4, o estimador tende a valorizar os pontos amostrais demasiadamente, e para valores muito grandes, o estimador despreza quase que completamente a influência dos pontos amostrais vizinhos, como pode ser visto na Fig. 5.6a.




Figura 5.3 - Estimador da pdf de Parzen para $\sigma = 0.035$.




Figura 5.4 - Estimador da pdf de Parzen para $\sigma = 0.004$.




Figura 5.5 - Estimador da pdf de Parzen para $\sigma = 0.05$.




Figura 5.6 - Estimador da pdf de Parzen para $\sigma = 0.09$.




Figura 5.6a - Estimador da pdf de Parzen para $\sigma = 0.3$.

As propriedades impostas para as funções candidatas à janela Kernel foram estabelecidas por Parzen(1962) e Specht(1990a), como segue:

- A função deve ser limitada

$$\max_x |W(x)| < \infty \quad (5.3)$$

- A magnitude da função de ponderação deve tender a zero à medida que o módulo do seu argumento aumenta. Tal restrição é expressa matematicamente por duas condições:

$$\int_{-\infty}^{+\infty} |W(x)| dx < \infty \quad (5.4)$$

$$\lim_{x \rightarrow \infty} |W(x)| = 0 \quad (5.5)$$

- A função de ponderação deve ser apropriadamente normalizada, de modo que :

$$\int_{-\infty}^{+\infty} W(x) dx = 1 \quad (5.6)$$

- A fim de obter um comportamento assintótico, a janela(função de ponderação) deve estreitar-se com o aumento do tamanho amostral. Expressando σ em função de n , duas condições devem ser satisfeitas:

$$\lim_{n \rightarrow \infty} \sigma_n = 0 \quad (5.7)$$

$$\lim_{n \rightarrow \infty} n\sigma_n = \infty$$

A função de ponderação mais utilizada é a função Gaussiana, tendo-se em mente que nenhuma suposição em relação à normalidade é considerada nesta circunstância e, que esta escolha é feita devido ao seu bom comportamento, à facilidade de cálculo e por satisfazer as condições requeridas pelo método de Parzen.

5.3 Extensão do Método Parzen de Estimação da fdp para o Caso de Amostras de Várias Variáveis.

No trato com problemas varias variáveis, que são a grande maioria dos problemas da vida real, um forte grau de complexidade é introduzido, pois, uma formulação mais geral é requerida para permitir que cada variável x_i necessária à identificação de um membro da amostra $\mathbf{X}$ tenha seu próprio σ_i . O modelo do estimador da fdp para o caso de varias variáveis foi apresentado por (Cacoullos,1966) :

$$g(x_1, \dots, x_p) = \frac{1}{n\sigma_1\sigma_2\dots\sigma_p} \sum_{i=1}^n W\left(\frac{x_1 - x_{1,i}}{\sigma_1}, \dots, \frac{x_p - x_{p,i}}{\sigma_p}\right) \quad (5.8)$$

De acordo com (Master,1995), é possível minimizar a complexidade da Eq. (5.8) pelo emprego de duas simplificações. A primeira consiste em se fazer $\sigma_1=\sigma_2\dots=\sigma$. A outra envolve a natureza da função Kernel varias variáveis. Uma simplificação notável é conseguida adotando-a como um produto das Kerneis unidimensionais, isto é:

$$W(x_1, \dots, x_p) = \prod_{i=1}^n W_i(x_i) \quad (5.9)$$

Esta equação indexa a função Kernel univariável de acordo com a variável em uso, de modo que se usa aproximadamente a mesma função Kernel para todas as variáveis, com a diferença apenas nas escalas.

O estimador da pdf variadas de variáveis mais empregado utiliza a função Kernel unidimensional do tipo Gaussiana com as duas simplificações, sendo dada pela Eq. 5.10. Nesta o argumento da função g está em negrito para evidenciar que o mesmo é um vetor.

$$g(\mathbf{X}) = \frac{1}{(2\pi)^{da/2} \sigma^{da} n} \sum_{i=1}^n e^{-\frac{|\mathbf{x} - \mathbf{x}_i|^2}{2\sigma^2}} \quad (5.10)$$

onde :

da - é a dimensão da amostra $\mathbf{x}$.

n - é o número de amostras $\mathbf{x}_i$.

σ - é o parâmetro de escala.

5.4 A rede PNN Elementar

A arquitetura da PNN de (Specht,1990), para uma rede neural pequena, treinada com (02) entradas, (03) classes e (02) casos de treinamento para cada classe é mostrada na Fig. 5.7. Numa rede treinada para executar tarefas de classificação o número de entradas é exatamente igual ao número de parâmetros necessários para identificar uma determinada classe. A camada de entrada é fictícia, pois seus neurônios não realizam nenhuma operação. A camada de classificação é constituída de um neurônio para cada caso do conjunto de treinamento. O processo de classificação inicia com a apresentação da amostra desconhecida para todos os neurônios da camada de classificação. Cada neurônio de classificação calcula a distância medida entre a amostra de entrada e o caso do conjunto de treinamento ao qual ele está associado. Esta distância será o argumento da função de ativação do neurônio, que é essencialmente uma janela Parzen. Cada neurônio da camada de somatório simplesmente soma a saída dos neurônios da camada de classificação correspondente à sua classe. O nível de ativação do neurônio somador k é o valor da fdp

estimada da população k . O neurônio da camada de saída é um classificador simples, que decide qual das entradas provenientes da camada de somatório possui o valor máximo.

Partindo da arquitetura básica, como a que é mostrada na Fig. 5.7, é possível agregar modificações com o objetivo de melhorar o desempenho computacional da PNN, principalmente no que diz respeito à otimização do parâmetro de escala do estimador Parzen.




Figura 5.7- Arquitetura básica da rede neural probabilística.

5.5 A Implementação da Rede PNN Elementar

Examinando mais uma vez a Eq. 5.1, seção 5.2, que mostra como classificar usando a regra de Bayes, pode-se notar que a estimativa da fdp aparece em ambos os lados da equação. Segundo(Master,1995), para propósitos de classificação, pode-se remover a restrição da função de ponderação $W(x)$, expressa pela Eq. 5.6, e ainda, usar o mesmo parâmetro de escala para todas as classes envolvidas na classificação. Com a introdução de tais simplificações, a estimativa da pdf de amostras de várias variáveis pode ser obtida através da Eq. 5.11.

$$g(\mathbf{X}) = \frac{1}{n} \sum_{i=1}^n w\left(\frac{\|\mathbf{x} - \mathbf{x}_i\|}{\sigma}\right) \quad (5.11)$$

Na Eq. 5.11, não é obrigatório o uso da distância Euclidiana para o cálculo de $(x-x_i)$, porém, ela é a mais usada. Ainda, a função de ponderação(Kernel) mais usada é a Gaussiana não normalizada, dada pela Eq. 5.12.

$$W(x) = e^{-d^2} \quad (5.12)$$

Com $d^2 = |x - x_i|^2$.

Uma função de ponderação do tipo Gaussiana agrega duas grandes vantagens: uma é de apresentar uma superfície sino menos espalhada, assim, a influência exercida por um determinado ponto amostral fica limitada apenas às proximidades deste ponto, e outra é o seu histórico de sucesso na estatística. A única desvantagem do uso deste tipo de Kernel é o custo computacional associado ao cálculo da função exponencial .

Outra função Kernel que aparece como alternativa é a que está mostrada na Eq. 5.13.

$$W(x) = \frac{1}{1 + d^2} \quad (5.13)$$

Esta alternativa é muito mais rápida de se calcular do que a Gaussiana, porém ela apresenta o defeito de atribuir uma ênfase indevida para alguns pontos amostrais, e além disto, a sua superfície sino possui abas largas que prolongam a influência de determinados pontos por uma considerável distância. Deve ser levado em conta, ainda, que a severidade destes defeitos aumenta para pequenos conjuntos de treinamento.

As Figs. 5.8 e 5.9 são apresentadas com o objetivo de ilustrar a diferença entre estas duas Kernel na estimação da pdf para quatro amostras bivariável. Na Fig. 5.8 as abas da superfície sino são muito mais justas ao pico, quando comparadas com as abas da superfície sino mostrada na Fig. 5.9.




Figura 5.8 - Estimativa de uma pdf bivariável usando a Kernel Gaussiana.




Figura 5.9 - Estimativa de uma pdf bivariável usando a Kernel da Eq. 5.13 .

Um parâmetro da Eq. 5.11 que exerce grande influência no desempenho da rede PNN é o parâmetro de escala σ . A título de ilustração, considere uma amostra bivariável de oito pontos de uma população simples. Suponha que a população apresente dois modos, e que a amostra tenha quatro pontos para cada modo. As funções densidade estimadas utilizando uma Kernel Gaussiana para vários valores do parâmetro de escala σ são mostradas nas Fig. 5.10 a 5.13.

Na Fig. 5.10 pelo uso de um parâmetro de escala muito pequeno, observa-se que a influência combinada dos vizinhos na região dos modos é totalmente eliminada.

A Fig. 5.11 mostra uma boa escolha de para o valor de σ , pois cada modo populacional está bem definido. A Fig. 5.12 ainda é uma boa escolha para o valor de σ , embora as abas das superfícies sino associadas à cada modo já se estendam excessivamente.

A Fig. 5.13 mostra o efeito de se utilizar um valor de σ muito grande. Nesta figura pode ser observado que a definição dos modos não existe mais, e isto é um fator extremamente negativo no processo de classificação.

O algoritmo usado para o treinamento da rede PNN elementar, consiste apenas de um procedimento de otimização da escolha do parâmetro σ , de modo, que o erro de classificação seja minimizado em relação ao conjunto de dados de treinamento da rede. Os diversos tipos de procedimentos de otimização que podem ser utilizados na escolha do σ ótimo são encontrados em (Master,1995) e (Vanderplaats, 1984).




Figura 5.10 - Estimativa da pdf usando um valor muito pequeno para o parâmetro de escala $\sigma(0.15)$.




Figura 5.11 - Estimativa da pdf usando um valor um pouco menor do que o valor ideal para o parâmetro de escala $\sigma(0.75)$.




Figura 5.12 - Estimativa da pdf usando um valor um pouco maior do que o valor ideal para o parâmetro de escala $\sigma(1.5)$.




Figura 5.13- Estimativa da pdf usando um valor muito grande para o parâmetro de escala $\sigma(4.0)$.

5.6 O Programa Utilizado no Diagnóstico Automático dos Defeitos nos Motores.

O programa utilizado neste trabalho para a detecção automática de falhas foi desenvolvido por (Master,1995) e denominado PNN. O PNN é um programa múlti-propósito, implementado em linguagem C++, construído a partir de conceitos probabilísticos, apresentados nas seções anteriores e, implementado utilizando uma série de melhorias em relação à rede PNN original. A PNN é intrinsecamente, um classificador, entretanto o programa desenvolvido por Timothy Master pode operar em três modos distintos:

- Classificação. Neste modo, a rede é treinada para identificar a qual classe do conjunto de treinamento pertence uma amostra desconhecida a ela apresentada.
- Auto associação. Este é um modo no qual as entradas são automaticamente associadas com uma saída, de modo que o usuário não necessita especificar as saídas correspondentes às entradas.
- Mapeamento. Com este modo é possível se obter regressões generalizadas, isto é, $\Re^n \rightarrow \Re^n$, e assim, implementar uma grande variedade de modelos.

Neste trabalho foi utilizado apenas o modo de classificação do programa e alguns detalhes do mesmo serão tratados oportunamente no capítulo VI.

Capítulo VI

Implementação do Modelo de Diagnóstico Automático de Falhas Via Rede PNN

Nos capítulos precedentes foram apresentados: (capítulo II) uma metodologia de caracterização do sistema em análise e um estudo dos defeitos a serem identificados; (capítulo III) alguns detalhes da aquisição dos dados e uma técnica de análise de sinais; (capítulo IV) uma metodologia para a elaboração dos padrões associados a cada condição de funcionamento dos motores e, (capítulo V), um estudo introdutório sobre as redes neurais. Como etapa final de construção de um sistema automático de identificação de falhas, resta que se efetue o treinamento da rede PNN, o que é feito neste capítulo. Aqui, são apresentados os procedimentos utilizados no treinamento da rede e uma metodologia desenvolvida para contornar as dificuldades de obtenção de um banco completo de padrões relacionados às falhas em questão.

Apresenta-se na Fig. 6.1 o fluxograma da metodologia empregada na detecção automática das falhas em motores de combustão interna, abordadas neste trabalho.

Primeiramente o sinal é adquirido, como detalhado na seção 3.1 e então pré-processado, disponibilizando-o para a etapa de análise preliminar no domínio da frequência, como discutido na seção 4.3. De acordo com os resultados desta análise, deverão ser executados os procedimentos à esquerda ou à direita do primeiro bloco de decisão do fluxograma.

Caso a sobrelevação do sinal ocorra na banda B3, de maneira que $R_{\max} > 1.8$, será necessário o pós-processamento do sinal, representado no fluxograma pelo ramo à esquerda do primeiro bloco de decisão. O sinal será então submetido à técnica do envelope, apresentada na seção 4.2.1, que o disponibilizará para a etapa de extração de características e possibilitará a construção do padrão associado à condição de funcionamento do motor. Feito isto, o padrão resultante é submetido à uma rede PNN treinada, que fará, automaticamente, a diagnose do defeito apresentado pelo motor em teste.

Por outro lado se a sobrelevação do sinal ocorrer em uma das bandas, B1 ou B2, não é necessário o pós-processamento do sinal e, através de um simples comparador, será possível

avaliar a condição de funcionamento do motor em termos de batimento de válvula(s), como está mostrado no ramo à direita do primeiro bloco de decisão.




Figura 6.1- Fluxograma do sistema de detecção automática de falhas em motores de combustão interna.

Dos procedimentos mostrados no fluxograma apresentado na Fig. 6.1, falta apenas mostrar o modo como a rede é treinada a partir dos padrões exemplificados nas seções 4.3 e 4.4 do capítulo IV, o que é feito na próxima seção, completando o modelo objeto deste trabalho.

6.1- O Treinamento da Rede Neural em Relação à de Batida de Válvula.

O tipo de treinamento que mais se adequa à este tipo de aplicação é o treinamento supervisionado, no qual são apresentados à rede os padrões associados à cada condição de funcionamento do motor e a classe a que pertencem. O treinamento da rede PNN, como já dito anteriormente, consiste de um procedimento de otimização da escolha dos parâmetros, σ , associados à cada padrão, de modo, que o erro de classificação seja minimizado em relação ao conjunto de dados de treinamento.

Durante o pós-processamento dos sinais adquiridos, observou-se, como era de se esperar, que diferentes motores com a mesma condição de funcionamento apresentavam padrões similares, porém, nunca iguais. O ideal seria que fosse possível construir um banco de dados completo, constituído de um número estatisticamente representativo de cada um dos padrões associados a cada condição de funcionamento do motor. Tal prática contudo, introduziria um transtorno na linha de produção de consequências econômicas inadmissíveis.

Uma solução encontrada para resolver o problema da escassez de dados foi a geração de amostras através de simulação numérica, a partir de alguns poucos padrões básicos obtidos com a aquisição de sinais dos motores. Como exemplo, é apresentada a Fig. 6.2, onde pode ser visto um conjunto de padrões simulados (curvas de linha contínua), gerados a partir de um padrão básico associado a um motor com batida de válvula inaceitável (linha rotulada com quadrados preenchidos).

A fim de ilustrar o método de geração dos padrões simulados a partir de um padrão básico, considere a Fig. 6.3. A curva marcada com ($\square$), obtida experimentalmente, representa um padrão básico associado a uma dada condição de funcionamento do motor (motor com batida de válvula, por exemplo). A curva marcada com ($\bullet$) é uma curva construída a partir da curva básica ($\square$), que simula um outro motor com a mesma condição de funcionamento; porém com outro nível de vibração.

O método utilizado neste trabalho para construir a curva simulada ($\bullet$), a partir da curva básica ($\square$), é o seguinte:

Dado o parâmetro p_i , $i=1,2,\dots,10$, calcula-se:

$$(y_{\bullet})_i = (y_{\square})_i \cdot (1 + \alpha) + (y_{\square})_i \cdot (1 + \beta_i) \quad (6.1)$$

onde α é uma perturbação percentual sistemática aplicada sobre a curva básica como um todo, e β_i , uma perturbação aleatória aplicada para cada parâmetro p_i .

Variando-se α e β , é possível construir uma infinidade de curvas em torno do padrão básico.

Com o objetivo de explicar a seleção dos valores de α e β , são apresentados nas Fig. 6.4 a 6.6, os padrões básicos de motores com batida de válvula, adquiridos experimentalmente. Na primeira, estão mostrados os padrões dos motores sem batida de válvula, na segunda, podem ser vistos os padrões dos motores no limite da aceitabilidade para rumorosidade de batida de válvula e, na terceira, estão mostrados os padrões dos motores que apresentaram batida de válvula. Estes três grupos foram estabelecidos de acordo com os critérios seguidos pelo fabricante.




Figura 6.2- Conjunto de treinamento(motores com batida de válvula) gerados a partir de um padrão básico.

Conforme pode ser inferido das Figs. 6.4 a 6.6, é possível estabelecer, empiricamente, um valor limite de aceitabilidade para o nível do espectro do envelope, em torno de (1.7), de modo que se um ou mais parâmetros do padrão estão acima deste valor, dentro de uma dada

tolerância, o motor é considerado como rumoroso, e abaixo do qual, o motor é considerado sem defeito em relação ao defeito de batida de válvula.




Figura 6.3- Ilustração do método de geração dos padrões simulados a partir de um padrão básico.

Assim, para os padrões que não apresentam o defeito de batida de válvula, as parcelas sistemática e aleatória adicionadas, isto é, os valores de α e de β , devem ser tais, que o valor do maior parâmetro não ultrapasse o valor do limite de aceitabilidade estabelecido para o nível do espectro do envelope(1.7). Neste caso, o padrão gerado por simulação, mais afastado do padrão básico, é limitado superiormente em torno de (1.7).

Por outro lado, para os padrões que apresentam o problema de batida de válvula o valor do maior parâmetro deve estar acima do limite de aceitabilidade(1.7).




Figura 6.4- Padrões base de motores sem batida de válvula.




Figura 6.5- Padrões base de motores sem batida de válvula, no limite da aceitabilidade.




Figura 6.6- Padrões base de motores com batida de válvula.

No treinamento de uma rede para reconhecer defeito de batida de válvula, são definidas duas classes, uma para motores com batida de válvula e outra para motores sem batida de válvula, sendo necessária a definição um conjunto de treinamento para cada uma das duas classes.

Nas Figs. 6.7 a 6.9 são mostradas as partes do conjunto de treinamento da rede, relativas aos padrões dos motores sem batida de válvula, e nas Figs. 6.10 e 6.11, as partes do conjunto de treinamento relativa aos motores com batida de válvula.

Nas Fig. 6.7 a 6.11, pode-se observar, que os dados gerados por simulação constituem uma envoltória em torno do padrão básico. Com esta metodologia a rede apreende que, se um padrão desconhecido se encaixa em uma destas envoltórias, ele pertencerá à classe do padrão base que deu origem àquela envoltória.




Figura 6.7- Parte 1 do conjunto de treinamento(motores sem batida de válvula).




Figura 6.8- Parte 2 do conjunto de treinamento(motores sem batida de válvula).




Figura 6.9- Parte 3 do conjunto de treinamento(motores no limite da aceitabilidade).




Figura 6.10- Parte 4 do conjunto de treinamento(motores com batida de válvula).




Figura 6.11- Parte 4 do conjunto de treinamento(motores com batida de válvula).

6.2 - O Treinamento da Rede Neural em Relação às Falhas nos Tensores.

De modo semelhante ao que ocorreu com relação ao defeito de batida de válvula, o conjunto de dados relacionado às falhas nos tensores, também foi adquirido em número insuficiente para a construção de um banco de dados estatisticamente representativo.

A solução adotada para resolver o problema de construção de um conjunto de treinamento, com relação aos defeitos nos tensores, foi exatamente a mesma adotada para a elaboração do conjunto de dados de treinamento referente à falha de batida de válvula, ou seja, foram gerados conjuntos de padrões simulados a partir de poucos padrões básicos.

Para os defeitos nos tensores, contudo, não foi possível encontrar um limite de aceitabilidade simples, como foi feito para o defeito de batida de válvula. Este é o argumento que mais justifica a utilização de uma rede neural para o diagnóstico automático das falhas, pois, tal dificuldade, introduziu a necessidade de se usar um procedimento de classificação mais sofisticado, que conseguisse apreender as particularidades dos padrões associados a cada condição de funcionamento dos motores.

Para o defeito nos tensores, os valores de α e de β , utilizados na Eq. 6.1, foram definidos de maneira que a distorção gerada nos padrões simulados, não chegasse a anular a

semelhança destes com os padrões básicos que lhe deram origem, ou ainda, que definissem padrões com níveis de amplitude do espectro do envelope irrealísticos.

Os dados das Fig. 6.12 à 6.21 constituem o conjunto de dados utilizado para o treinamento da rede neural com relação aos defeitos nos tensores, gerados com os valores percentuais de α e de β_i tais que:

$$-35 \leq \alpha \leq +35 \text{ e}$$

$$-3 \leq \beta_i \leq +3.$$

Um outro conjunto de dados diferente do conjunto de dados de treinamento, gerado da mesma maneira, foi construído afim de ser utilizado como conjunto de validação da rede treinada. O treinamento se constitui de um procedimento de atualização dos pesos que conectam os neurônios da rede entre si, utilizando-se dos dados do conjunto de treinamento.

Como pode ser visto ainda, nas Fig. 6.12 a 6.21, todos os parâmetros dos padrões são da mesma ordem de grandeza, de modo que nenhuma normalização precisou ser feita e, também aqui, os padrões simulados constituem envoltórias em torno dos padrões básicos.




Figura 6.12- Parte 1 do conjunto de treinamento(motor sem defeito).

Os padrões básicos das Figs. 6.12 a 6.14, foram obtidos pela aplicação da técnica do envelope sobre o sinal de um mesmo motor sem defeito, respectivamente, nas bandas B31=[2800-3800] Hz, B32=[3300-4300] Hz e B33=[3800-4800] Hz. Da comparação destas três figuras, pode-se inferir que o nível do espectro do envelope diminui da banda B31 para a banda B33.

Utilizando-se das Figs. 6.12 a 6.14, e a Fig. 6.16, é possível justificar o uso da frequência central da banda de análise, fc_1 , discutida na seção 3.2.1, como um dos parâmetros constituintes dos padrões relacionados ao defeito de rumorosidade nos tensores. Comparando-se o primeira curva(de baixo para cima) da Fig. 6.16 com a curva correspondente ao padrão básico da Fig. 6.12, à primeira vista, se poderia dizer que aquela curva da Fig. 6.16, representa um motor sem defeito, enquanto ela representa, realmente, um motor com tensor da correia sincronizadora defeituoso. Tal afirmativa pode ser feita com segurança, pois, observando-se o primeiro parâmetro destas duas curvas, nota-se que os padrões básicos foram obtidos pela aplicação da técnica do envelope em bandas diferentes, o que resulta em níveis da amplitude do espectro do envelope também diferentes. Este é um importante detalhe que não se pode deixar de informar à rede.




Figura 6.13 – Parte 2 do conjunto de treinamento(motor sem defeito).




Figura 6.14 - Parte 3 do conjunto de treinamento(motor sem defeito).




Figura 6.15 - Parte 4 do conjunto de treinamento(motor com ruídos no tensor da correia sincronizadora)




Figura 6.16 - Parte 5 do conjunto de treinamento(motor com rumorosidade no tensor da correia sincronizadora)




Figura 6.17 - Parte 6 do conjunto de treinamento(motor com rumorosidade no tensor da correia do alternador).




Figura 6.18 - Parte 7 do conjunto de treinamento(motor com rumorosidade no tensor da correia do alternador).




Figura 6.19 - Parte 8 do conjunto de treinamento(motor com rumorosidade nos dois tensores).




Figura 6.20 - Parte 9 do conjunto de treinamento(motor com rumorosidade nos dois tensores).




Figura 6.21 - Parte 10 do conjunto de treinamento(motor com rumorosidade nos dois tensores).




Figura 6.22- Padrões de motores diferentes com o mesmo tipo de defeito, porém apresentando níveis diferentes de severidade para o problema de rumorosidade no tensor da correia sincronizadora, gerado a partir de um único padrão base.

Deve ser mencionado neste ponto, que a escolha de se gerar um conjunto de dados, de maneira que cada parte deste conjunto constituísse uma envoltória para o padrão básico que lhe deu origem, não foi uma escolha arbitrária, resultando de testes de aprendizado da rede. Para explicar isto, é mostrada a Fig. 6.22, onde os dados simulados, foram gerados permitindo-se que a parcela percentual aleatória, β , assumisse valores mais significativos do que a parcela percentual sistemática, α , mas sem destruir a semelhança com o padrão básico. O teste de aprendizado da rede constituiu-se em apresentar à rede, 50 conjuntos de padrões como o que é mostrado na Fig. 6.22, simulando 600 padrões adquiridos. Após treinada, a rede era capaz de reconhecer qualquer um dos 600 padrões pertencentes ao conjunto de treinamento. Todavia, se um padrão diferente dos 600 padrões aprendidos fosse apresentado à mesma, ele não era reconhecido. Uma rede com estas características exigiria um constante atualização do seu conjunto de treinamento, o que é pouco prático para o dia a dia de uma linha de montagem.

6.4- A Saída do Programa PNN(Master,1995).

A saída da rede treinada para diagnosticar rumorosidade nos tensores, através de padrões como os que foram mostrados na seção 6.3, possui quatro dígitos, [P1 P2 P3 P4], onde $0 \leq P_i \leq 1$. Nesta saída os dígitos estão associados com a condição de funcionamento do motor da seguinte forma :

P1 - motor com tensor da correia sincronizadora rumoroso.

P2 - motor com tensor da correia do alternador rumoroso.

P3 - motor sem defeito.

P4 - motor com ambos os tensores rumorosos.

Quando um padrão de um motor com condição de funcionamento desconhecida é apresentado à rede para a classificação, a classe a que pertence aquele padrão é aquela correspondente ao dígito da saída da rede com o valor mais próximo da unidade. Por exemplo, se a saída da rede for [0.2139 0.0000 0.7861 0.0000], deve-se inferir que a rede identificou o padrão como sendo de um motor sem defeito.

No caso da rede treinada para identificar o problema de batida de válvula, a saída da rede é constituída apenas dois dígitos, [P1 P2], onde $0 \leq P_i \leq 1$, de modo que:

P1 - motor sem defeito.

P2 - motor com batida de válvula.

De forma semelhante ao que é feito para a rede de diagnóstico de rumorosidade nos tensores, o maior dígito indicará a condição de funcionamento do motor no que diz respeito ao problema de batida de válvula.

Capítulo VII

Validação da rede PNN

Neste capítulo são mostrados alguns resultados dos testes realizados com a rede neural treinada.

O procedimento de validação da rede é tão importante quanto o seu treinamento, pois, é a partir do resultados da validação, que o projetista assegura-se de que o conjunto de treinamento representa satisfatoriamente o fenômeno em análise. Neste trabalho, por exemplo, o objetivo da validação é verificar se a forma como os padrões foram definidos, e o número de padrões do conjunto de treinamento são representativos das condições de funcionamento do motor analisadas.

Como já mencionado na seção 5.6, para o reconhecimento das falhas, o programa desenvolvido por (Master,1995), foi utilizado no modo de classificação. Na etapa de validação da rede, é calculada a matriz de erro classificatório, que é um dos indicadores de como a rede apreendeu os padrões a ela apresentados. A fim de entender o significado desta matriz, considere a configuração da rede para o diagnóstico de falhas nos tensores, mostrada na Fig. 7.1. Como se observa no bloco da Fig. 7.1a, à cada condição de funcionamento dos motores é associada uma classe, constituída por dois conjuntos de dados, um de treinamento e o outro de validação.

Ao término do processo de aprendizado da rede, representado pela Fig. 7.1b, o programa lista a matriz de erro classificatório, que neste caso, possui dimensão 4x5, Fig. 7.1c . O que se deve entender deste resultado, com relação à validação, é o seguinte:

- linha (01) - a rede classificou os 30 padrões dos dados relacionados à classe 1, como pertencentes à esta classe.
- linha (02) - a rede classificou os 30 padrões dos dados relacionados à classe 2, como pertencentes à esta classe.
- linha (03) - dos 45 padrões dos dados relacionados à classe 3, 41 foram classificados como desta classe, e 4 como da classe 1.

- linha (04) - dos 60 padrões dos dados relacionados à classe 4, 58 foram classificados como desta classe, e 2 como da classe 2.

Ainda, na Fig. 7.1c, pode-se observar que a última coluna, para todas as linhas, é nula. Isto significa que apesar de ter ocorrido erros de classificação em pequena porcentagem, para as classes 3 e 4, nenhum dos padrões do conjunto de validação foi considerado como desconhecido pela rede.




Figura 7.1- Esquema ilustrando os códigos de saída da rede PNN.

No caso ideal, a matriz de erro classificatório apresentar-se-ia como a que é mostrada na Fig. 7.2, indicando um conjunto de treinamento perfeitamente representativo, uma condição difícil de ocorrer na prática.

·

·

·

Dados de saída da rede
.....
Linha (01) da matriz de erro classificatório 30 0 0 0 0
Linha (02) da matriz de erro classificatório 0 30 0 0 0
Linha (03) da matriz de erro classificatório 0 0 45 0 0
Linha (04) da matriz de erro classificatório 0 0 0 60 0

Figura 7.2- Matriz de erro classificatório, ilustrando um caso ideal.

Nas Figs. 7.3 a 7.13, os padrões rotulados com um triângulo invertido, são os padrões básicos a partir dos quais foi gerado conjunto de treinamento mostrado na seção 6.3, e os rotulados com um círculo preenchido, são padrões inéditos (que simulam dados de motores não apresentados à rede). Estes últimos, foram gerados através da Eq. 6.1, com os valores de α e β_i , tais que, $\alpha = 0$ e $-35 < \beta_i < +35$.

Nas Figs. 7.3 a 7.5 são mostrados três casos de validação da rede com motores apresentando tensor da correia sincronizadora rumoroso.

Nas Figs. 7.6 a 7.8 são mostrados três casos de validação da rede com motores apresentando tensor da correia do alternador rumoroso.

Nas Figs. 7.9 e 7.8 são mostrados dois casos de validação da rede com motores sem defeito.

Nas Figs. 7.10 a 7.13 são mostrados três casos de validação da rede com motores apresentando ambos os tensores ruidosos.




Figura 7.3- Teste de padrão inédito, representando motor com tensor da correia sincronizadora ruidoso.




Figura 7.4- Teste de padrão inédito, representando motor com tensor da correia sincronizadora ruidoso.




Figura 7.5- Teste de padrão inédito, representando motor com tensor da correia sincronizadora ruidoso.




Figura 7.6- Teste de padrão inédito, representando motor com tensor da correia do alternador ruidoso.




Figura 7.7- Teste de padrão inédito, representando motor com tensor da correia do alternador ruidoso.




Figura 7.8- Teste de padrão inédito, representando motor com tensor da correia do alternador ruidoso.




Figura 7.9- Teste de padrão inédito, representando motor sem defeito.




Figura 7.10- Teste de padrão inédito, representando motor sem defeito.




Figura 7.11- Teste de padrão inédito, representando motor com ambos os tensores rumorosos.




Figura 7.12- Teste de padrão inédito, representando motor com ambos os tensores rumorosos.




Figura 7.13- Teste de padrão inédito, representando motor com ambos os tensores rumorosos.

Constatou-se através de testes com a rede treinada, que se um padrão inédito se enquadra em uma das envoltórias do conjunto de treinamento apresentado na seção 6.3, ele é corretamente classificado. Por outro lado, se um único parâmetro do padrão desconhecido fica fora da envoltória a que ele mais se enquadra, o padrão é considerado desconhecido pela rede. Esta mesma constatação foi feita durante os testes da rede treinada para o diagnóstico do problema de batida de válvula.

Capítulo VIII

Conclusões

Este trabalho implementou uma ferramenta de detecção automática de falhas em motores de combustão interna a partir da assinatura de vibrações adquirida dos mesmos.

Tanto o estudo cinemático dos mecanismos geradores de defeito no motor, quanto os resultados da análise modal parcial executada, auxiliaram significativamente na compreensão do comportamento vibratório do motor.

Comprovou-se a grande utilidade da técnica do envelope no diagnóstico de falhas incipientes, cujo potencial é aumentado com a utilização de um modelo de geração de vibrações em rolamentos.

Conseguiu-se, para o restrito banco de dados adquirido, o sucesso no diagnóstico automático de rumorosidade nos tensores, e de batida de válvula, mesmo que os padrões inéditos apresentassem características muito diferentes em relação aos padrões do conjunto de treinamento da rede.

Apesar do êxito no diagnóstico do problema de batida de válvula, não se conseguiu identificar qual das válvulas do motor era a causa do defeito, o que, se alcançado, melhoraria a produtividade da linha de montagem dos motores.

Com base nos resultados, confirmou-se o bom desempenho da rede PNN como classificador. Convém ressaltar, no entanto, que é necessário ampliar o banco de dados experimentais a partir dos quais são gerados os padrões básicos, de maneira a garantir a confiabilidade estatística da metodologia.

Como desafios futuros, propõe-se:

- Utilizar o sensor de vibração acoplado à algum dispositivo, projetado especificamente para fixar o sensor no motor em teste, de maneira: a se garantir a reprodutibilidade da rigidez de fixação, evitar o desgaste prematuro do sensor e facilitar o procedimento de aquisição dos dados.

- Utilizar um sinal de referência vinculado ao eixo comando de válvula, a fim de promover duas melhorias na ferramenta :

- Permitir o pré-processamento do sinal pela aplicação da média sincronizada no domínio do tempo, que constitui uma poderosa técnica de maximização da relação sinal/ruído.
- Prover uma referência que permita identificar a válvula do motor causadora da rumorosidade elevada.
- Pesquisar a substituição da técnica do envelope pela transformada de wavelet na definição dos padrões associados aos defeitos.

REFERÊNCIAS BIBLIOGRÁFICAS

Alguindigue I. E., Loskiewicz-Buczak A. E. Uhrig R. E., 1993; "Monitoring and Diagnosis of Rolling Element Bearings Using Artificial Neural Networks", IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS, VOL. 40, NO. 2, pp. 209 - 217.

Angelo, M., 1987, "Vibration Monitoring of Machines", Bruel & Kjaer Technical Review 1.

Assunção, E. E Minhote, M. C., 1994; "Seleção Ótima de Auto-Valores em Redução de Modelos com Rede Neural de Hopfield", Congresso Latino Americano de Automática, Rio de Janeiro, pg. 1192 - 1197.

Baxa, D. E., 1982, "Noise Control in Internal Combustion Engines", JOHN WILEY & SONS, Lodon.

Bendat, Julius S. and Pierson, Allan G. , Random Data - Analysis and Measurement Procedures, Wiley-Interscience, 1986.

Bernieri. M., Sansone L. E Savastano M., 1994; "a Neural Network Approach for Identification and Fault Diagnosis on Dynamic Systems", IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT, VOL. 43, n^o. 6, pp. 867 - 873.

Botton, G. de, Ben-Ari, G., Itzhaki, R. e Sher, E. , 1998, "Vibration Signature Analysis as a Fault Detection Method for SI Engines", International Congress and Exposition, February 23-26, Detroit, Michigam.

Braun, S., 1986, "Mechanical Signature Analysis: theory and applications", Academic Press, Lodon.

Cacoullos, T., 1996, "Estimation of a Multivariate Density", Annals of institute of Statistical Mathematics, Tokyo, n^o 18, pag. 179-189.

Craig Jr., R. R., 1987, " A Review of Time-Domain and Frequency-Domain Component Mode Synthesis Methods ", Journal of Modal Analysis, p. 59 - 72.

Dimarogonas, A., 1995, "Vibration for Engineers", Prentice Hall, Upper Saddle River.

Duarte, M. A. V., 1997, "Manutenção Preditiva via Monitoramento de Vibrações", apostila utilizado no Curso de Engenharia Mecânica da Universidade Federal de Uberlândia.

Hewlett Packard®, Application Note 243, "The Fundamentals of signal Analysis ", <http://www.tmo.hp.com>

Hewlett Packard®, Application Note 243-1, "The Fundamentals of Modal Testing", <http://www.tmo.hp.com>

Hewlett Packard®, Application Note 243-3, "Effective Machinery Measurement using Dynamic Signal Analyzers", <http://www.tmo.hp.com>

Geropp, B. , 1995, Schwingungsdiagnose an Walzlagern mit Hilfe der Hullkurvenanalyse, Dissertation RWTH Aachen.

Kotz, S., Norman. J., 1982, "Encyclopedia of Statistical Sciences", John Wiley & Sons, New York.

Kovács, Z. L., 1996, "Redes Neurais Artificiais: Fundamentos e Aplicações", Edição Acadêmica São Paulo.

Mamede, W. F., 1997, "Análise De Falhas Em Redutores Utilizando Transformada de Wavelet", Dissertação de Mestrado defendida pela Universidade Federal de Uberlândia.

Marple Jr., S. L., 1987, " Digital Spectral Analysis With Applications ", Prentice-Hall. Inc., New Jersey, E.U.A.

Masters, T., 1993, "Practical Neural Network Recipes in C++", Academic Press, Inc. New York.

Masters, T., 1995, "Advanced Algorithms for Neural Networks", JOHN WILEY & SONS, New York.

McCormick, A. C., 1998, "Cyclostationary and Higher-Order Statistical Signal Processing Algorithms for Machine Condition Monitoring", tesis, University of Strathclyde, Unite Kindon.

McFadden, P. D., Smith, J. D., 1984, "Vibration Monitoring of Rolling Element Bearings by the High-Frequency Resonance Technique - a Review", TRIBOLOGY International, February, vol 17, No 1.

Meisel, W., 1972, "Computer-Oriented Aproaches to Pattern Recognition", Academic Press, New York.

Moraes, J. V. And Weber, H. I., 1997; "Using Orthonormal Wavelet Transform for Extracting Impulse

Response Functions", DINAME 97, 03 a 07 de março, Agra dos Reis, Rio de Janeiro, Brazil, pp. 181 - 183.

Nepomuceno, L., X., 1989; "Técnicas de Manutenção Preditiva", Editora Edgard Blücher Ltda, São Paulo, Brasil.

Newland, D. E., 1994; "Wavelet Analysis of Vibration, Part I: Theory", Journal of Vibration and Acoustics, VOL 116, pp. 409 - 416.

Newland, D. E., 1994; "Wavelet Analysis of Vibration, Part II: Wavelet Maps", Journal of Vibration and Acoustics, VOL 116, pp. 417 - 425.

Nunes, M. A. C., 1986; "Diagnóstico de Defeitos em Rolamentos pela Técnica do Envelope", Dissertação de Mestrado defendida na Universidade Federal de Santa Catarina, julho de 1989.

Parzen, E., 1962, "On Estimation of a Probability Density Function and Mode", Annals of Mathematical Statistics, 33:1065-1076.

Peck, J. P. And Burrows, J., 1994; "On-line Condition Monitoring of Rotating Equipment Using Neural Networks", ISA Transactions 33; pp. 159 - 164

Pena, J. L. P. E Duarte, M. A. V., 1997; "Sobre a Utilização de Redes Neurais na Redução de Dados", 1º SCPGEM-UFU, 23 a 24 de outubro de 1997, Uberlândia.

Randall, R. B., 1973; "Cepstrum Analysis and Gearbox Fault Diagnosis", BRÜEL&KJAER Application Notes.

Specht, D., 1990, "Probabilistic Neural Network", Neural Networks, 3:109-118.

Staszewski, W. J. And Tomlinson, G. R., 1995; "Fault Detection Procedures Employing the Wavelet Transform", ISMA19 - Tools for Noise and Vibration Analysis, pp. 372 - 384.

Wagstaff, P. R., Luo Q. And Yadavar, M., 1997; "Signal Processing Techniques for the Identification of Noise and Vibrations Sources", DINAME 97, 03 - 07 março de 1997, Angra dos Reis, Brasil.