

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA EM PÓS-GRADUAÇÃO ENGENHARIA MECÂNICA

**DETECÇÃO DE FALHA NA MONTAGEM DE COMPRESSORES
HERMÉTICOS POR REDES NEURAIIS ARTIFICIAIS**

DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE FEDERAL DE SANTA
CATARINA PARA A OBTENÇÃO DO GRAU DE MESTRE EM
ENGENHARIA MECÂNICA

FABIANO ALVES DENCKER

Florianópolis, junho de 2002

UNIVERSIDADE FEDERAL DE SANTA CATARINA

PROGRAMA EM PÓS-GRADUAÇÃO

ENGENHARIA MECÂNICA

DETECÇÃO DE FALHA NA MONTAGEM DE COMPRESSORES

HERMÉTICOS POR REDES NEURAIS ARTIFICIAIS

FABIANO ALVES DENCKER

Esta dissertação foi julgada adequada para a obtenção do título de

MESTRE EM ENGENHARIA

ESPECIALIDADE ENGENHARIA MECÂNICA

sendo aprovada em sua forma final.

Prof. Arcanjo Lenzi, Ph. D. Orientador

Prof. Acires Dias, Dr. Eng. Co-orientador

Prof. José Antônio Bellini da Cunha Neto, Dr.
Coordenador da Pós Mec

BANCA EXAMINADORA

Prof. Roberto Jordan, Dr. Eng.

Prof. Mauro Roisenberg, Dr. Eng.

Prof. Jonny Carlos da Silva, Dr. Eng.

Eng. Eduardo Alvarenga, M. Eng.

“... sempre aprendendo, mas nunca podendo chegar ao pleno conhecimento da verdade”.

II Timóteo 3,7

AGRADECIMENTOS

Agradeço a Deus pela inspiração e sabedoria recebidas para a realização deste trabalho. É com sinceridade que agradeço aos meus pais, em especial, e tios pela compreensão, carinho e incentivo ao estudo por todos estes anos.

Externo minha gratidão aos professores, colegas de pesquisa da engenharia mecânica e do programa de pós-graduação em engenharia mecânica da UFSC que diretamente ou indiretamente contribuíram para a realização deste trabalho. Agradeço especialmente aos professores Arcanjo Lenzi e Acires Dias pelo incentivo e ao colega Gilberto Amado pelo companheirismo e ajuda. Também agradeço as contribuições feitas por Adriane Beatriz Moretti e Carlos H. Beuter.

Agradeço ainda à Embraco S/A pela disponibilidade de pessoal e de equipamentos que permitiram a realização de medições e testes. A eles meus sinceros agradecimentos.

Agradeço também ao suporte financeiro disponibilizado pela CAPES.

Por todas as dificuldades enfrentadas e por todas as etapas vencidas, agradeço sublimemente a meu Senhor e Salvador Jesus Cristo.

SUMÁRIO

LISTA DE FIGURAS	ix
LISTA DE TABELAS	xii
NOMENCLATURA	xiii
RESUMO	xv
ABSTRACT	xvi
CAPÍTULO 1 INTRODUÇÃO GERAL	
1 Introdução	1
1.1 Objetivos	1
1.2 Conteúdo da dissertação	2
CAPÍTULO 2 CARACTERÍSTICAS GERAIS DO SISTEMA	
2.1 Introdução	4
2.2 Características gerais do compressor	4
2.3 Sistema de controle de qualidade	5
2.4 Comentário	10
CAPÍTULO 3 CONCEITOS BÁSICOS	
3.1 Introdução	11
3.2 Rede Neural Artificial – RNA	11
3.2.1 Introdução	11
3.2.2 Analogia entre neurônios biológicos e artificiais	12
3.2.3 Funções de ativação e transferência	13
3.2.4 Principais estruturas de RNAs	14
3.2.5 O perceptron	16
3.2.6 Redes MLP	17
3.2.7 Reconhecimento de padrões	18
3.2.8 Aprendizado	19
3.2.9 Regra delta generalizada	21
3.3 Treinamento	25
3.4 Análise da Árvore de Falha – FTA	26
3.5 Análise dos Modos de Falha e Efeitos – FMEA	28

3.5.1 Modo de falha, efeito e causa	30
3.6 Relação entre FMEA e FTA	31
3.7 Teste de Desempenho Estatístico (TDE) aplicado a detecção de falhas	31
3.7.1 Sensibilidade e Especificidade	32
3.8 Comentário	34

CAPÍTULO 4 MODELO PROPOSTO

4.1 Introdução	35
4.2 Escolha da Rede Neural	35
4.2.1 Configurações de redes	35
4.3 Arquitetura e Topologia da rede neural	37
4.4 Bloco funcional	38
4.4.1 Modelo proposto para o padrão de entrada da RNA	38
4.4.2 Dinâmica do reconhecimento de padrões	39
4.5 Camada de classificação	40
4.5.1 Padrão de entrada e saída da RNA de classificação	41
4.5.2 Dinâmica da rede neural de classificação	42
4.5.3 Treinamento da RNA de classificação	44
4.6 Camada de identificação	44
4.6.1 Treinamento da RNA de identificação	45
4.7 Base de regras	46
4.8 Fluxograma funcional da detecção e análise de falhas	47
4.9 Procedimento construtivo do módulo de qualidade via programação	48
4.10 FMEA e FTA em compressores herméticos	49
4.11 Comentário	50

CAPÍTULO 5 RESULTADOS

5.1 Introdução	51
5.2 Implementação do sistema proposto	51
5.3 Aplicação da FMEA e FTA: Banco de dados de falhas	56
5.3.1 Análise dos modos de falha e efeito em compressores herméticos	57
5.4 Primeira aplicação: Testes em laboratório	59
5.4.1 Padrões de treinamento: Primeira aplicação	60
5.4.2 Treinamento	62

5.4.3 Resultados da primeira aplicação	62
5.5 Segunda aplicação: Implementação na pré montagem de compressores	65
5.5.1 Padrões de treinamento: Segunda aplicação	69
5.5.2 Resultados da segunda aplicação	69
5.6 Terceira aplicação: Validação do modelo proposto	71
5.6.1 Padrões de treinamento: Terceira aplicação	73
5.6.2 Resultados da terceira aplicação	73
5.7 Análise final dos resultados	76
CAPÍTULO 6 CONCLUSÕES	
6.1 Introdução	78
6.2 Considerações gerais	78
6.3 Considerações sobre o modelo	78
6.4 Trabalhos futuros	79
REFERÊNCIAS BIBLIOGRÁFICAS	81
APÊNDICES	84
APÊNDICE 1 – SIMBOLOGIA PARA A CONSTRUÇÃO DA ÁRVORE DE FALHAS	85
APÊNDICE 2 – RESUMO DAS PRINCIPAIS ARQUITETURAS DE REDES NEURAIIS ARTIFICIAIS	87
APÊNDICE 3 – ÁRVORES DE FALHAS	90

LISTA DE FIGURAS

Figura 2.2.1	Figura esquemática de um modelo de compressor	5
Figura 2.3.1	Coleta de informações do painel: a) Medição dos sinais de ruído; b) Medição dos sinais de vibração	6
Figura 2.3.2	Esquema básico de um painel de controle de qualidade na montagem de compressores herméticos	7
Figura 2.3.3	Esquema de tempo de teste de um compressor	8
Figura 2.3.4	Critério de segregação atual	8
Figura 3.2.1	Estrutura de um neurônio biológico	12
Figura 3.2.2	Modelo de um neurônio artificial	13
Figura 3.2.3	Principais estruturas de RNAs	15
Figura 3.2.4	Unidade de processamento do perceptron	16
Figura 3.2.5	Representação vetorial de classes de padrões	18
Figura 3.2.6	Aprendizado supervisionado	19
Figura 3.2.7	Aprendizado não supervisionado	20
Figura 3.2.8	Treinamento com algoritmo de retropropagação	21
Figura 3.4.1	Diagrama típico de uma árvore de falha	27
Figura 3.5.1	Diagrama de blocos de FMEA	28
Figura 3.5.2	Dispositivo de partida de um compressor hermético	30
Figura 3.6.1	Árvore de falha e FMEA	31
Figura 3.7.1	Decisões do sistema de qualidade	32
Figura 4.3.1	Topologia da rede proposta	38
Figura 4.4.1	Estruturação do padrão de entrada da RNA	39
Figura 4.4.2	Exemplo de sinal em função do tempo	40
Figura 4.4.3	Exemplo do sinal por faixa de frequência	40
Figura 4.5.1	Rede neural de classificação de múltiplas camadas <i>feedforward</i>	41
Figura 4.5.2	Influência do <i>momentum</i> no aprendizado	43
Figura 4.6.1	Rede neural de identificação de múltiplas camadas <i>feedforward</i>	45
Figura 4.8.1	Procedimento de detecção de falhas em compressores herméticos	47
Figura 4.9.1	Procedimento seqüencial de análise da interface SISNAV	48
Figura 4.10.1	Exemplo de árvore de falha	50
Figura 5.2.1	Tela principal do programa	52
Figura 5.2.2	Tela do SISNAV: <i>menu</i> principal	52
Figura 5.2.3	Tela do SISNAV (<i>submenu</i> de visualização): Exemplo de um sinal na frequência	53

Figura 5.2.4	Tela do SISNAV: Exemplo de um sinal por faixa de frequência	54
Figura 5.2.5	Tela do SISNAV (<i>submenu</i> rede neural): Exemplo de um sinal por faixa de frequência	54
Figura 5.2.6	Tela do SISNAV: Modo de falha e suas causas	55
Figura 5.3.1	Gráfico de Pareto dos principais modos de falha	57
Figura 5.3.2	Exemplo de árvore de falha para um modo de falha	57
Figura 5.4.1	Configuração da rede neural utilizada na primeira aplicação	60
Figura 5.4.2 a	Exemplo de padrão de treinamento de um compressor em funcionamento normal	61
Figura 5.4.2 b	Exemplo de padrão de treinamento de um compressor com modo de falha 1	61
Figura 5.4.2 c	Exemplo de padrão de treinamento de um compressor com modo de falha 2	61
Figura 5.4.2 d	Exemplo de padrão de treinamento de um compressor com modo de falha 3	62
Figura 5.4.2 e	Exemplo de padrão de treinamento de um compressor com modo de falha 4	62
Figura 5.4.3	Erro médio quadrático para rede neural de classificação do conjunto de treinamento (curva inferior) e do conjunto de teste (curva superior)	63
Figura 5.4.4	Erro médio quadrático para rede neural de identificação do conjunto de treinamento	63
Figura 5.5.1 a	Compressor em funcionamento normal	66
Figura 5.5.1 b	Manifestação do modo de falha 1	66
Figura 5.5.1 c	Manifestação do modo de falha 2	66
Figura 5.5.1 d	Manifestação do modo de falha 3	66
Figura 5.5.1 e	Manifestação do modo de falha 4	67
Figura 5.5.1 f	Manifestação do modo de falha 5	67
Figura 5.5.1 g	Manifestação do modo de falha 6	67
Figura 5.5.1 h	Manifestação do modo de falha 7	67
Figura 5.5.1 i	Manifestação do modo de falha 8	68
Figura 5.5.1 j	Manifestação do modo de falha 9	68
Figura 5.5.2	Configuração da rede neural utilizada na Segunda aplicação	68
Figura 5.5.3	Comparação média dos padrões de treinamento	69
Figura 5.5.4	Erro médio quadrático para rede neural de classificação do conjunto de treinamento (curva inferior) e do conjunto de teste (curva	

	superior)	70
Figura 5.5.5	Erro médio quadrático para rede neural de identificação do conjunto de treinamento	70
Figura 5.6.1	Exemplo de classes de compressores com defeito	72
Figura 5.6.2	Configuração da rede neural utilizada na terceira aplicação	72
Figura 5.6.3	Comparação entre os padrões de treinamento	73
Figura 5.6.4	Erro médio quadrático para rede neural de classificação do conjunto de treinamento (curva inferior) e do conjunto de teste (curva superior)	74
Figura 5.6.5	Erro médio quadrático para rede neural de identificação do conjunto de treinamento	74
Figura A3	Árvores de falha dos principais modos de falha	92

LISTA DE TABELAS

Tabela 4.2.1	Análise de tipos de arquiteturas de redes neurais	36
Tabela 4.5.3	Exemplo das saídas desejadas para RNA de classificação	44
Tabela 4.6.1	Exemplo das saídas desejadas para RNA de identificação	46
Tabela 5.3	Principais modos de falha	56
Tabela 5.3.1	FMEA dos principais modos de falha aplicado em compressores	58
Tabela 5.6.2	Resultados da terceira aplicação	75
Tabela 5.7	Comparação dos resultados	76
Tabela A1	Símbolos construtivos da árvore de falha	86
Tabela A2	Resumo das principais arquiteturas de redes neurais artificiais	89

NOMENCLATURAS

$\Phi_m^{x,y}$	Vetores de entrada contendo as classes de falhas x e y, em m padrões	
f_{X_n}	Número de faixas de frequência da classe de falha X	
$\bar{\nabla}_j^{(k)}$	Gradiente instantâneo do neurônio j na camada k	
$d_j^{(k)}$	Derivada do erro quadrático associado ao j-ésimo neurônio na k-ésima camada	
ω	Frequência angular	[rad/Seg]
θ	Valor de limiar (<i>threshold</i>)	
η	Taxa de aprendizado	
α	Constante de momento (<i>mumentum</i>)	
λ	Parâmetro de suavidade da curva	
$\pm\gamma$	Valores quaisquer constantes em uma faixa	
ω_0	Incremento da frequência em intervalos discretos	
ε^2	Erro quadrático calculado na saída da rede neural	
C_n	Coefficiente de $x(t)$	
d_{ij}	Saída j desejada para a entrada i	
d_j	Saída desejada no neurônio j	
DFT	Discrete Fourier Transform	
$E(W)$	Erro quadrático	
E_{ij}	Erro na saída j para entrada i	
Espc	Especificidade	
f	Frequência	[Hz]
$f(s_j)$	Função de transferência	
FA	Falso Aprovado	
FFT	<i>Fast Fourier Transform</i>	
FMEA	<i>Failure Mode and Effect Analysis</i>	
FS	Falso Segregado	
FTA	<i>Fault Tree Analysis</i>	
JTFA	<i>Join Time Frequency Analysis</i>	
m	Número de padrões contendo o mesmo modo de falha, número de neurônio na última camada	

MCP	Neurônio McCulloch e Pitts	
m_k	Número de neurônios na k-ésima camada	
MLP	<i>Multilayer Perceptron</i>	
n	Número de terminais de entrada da rede neural	
PRef	Padrão de referência	
RNA	Rede Neural Artificial	
S(t)	Valor atual da derivada do erro em relação ao peso	
S(t-1)	Valor passado da derivada do erro em relação ao peso	
Sens	Sensibilidade	
SISNAV	Sistema Neuro Acústico e Vibracional de Controle de Qualidade	
T	Período	[Seg]
VA	Verdadeiro Aprovado	
VLPA	Valor Preditivo Aprovado	
VLPS	Valor Preditivo Segregado	
VS	Verdadeiro Segregado	
X(f)	Transformada de Fourier de $x(t)$ expressa em frequência em Hz	
X(i ω)	Transformada de Fourier de $x(t)$ expressa em frequência angular	
$x(t)$	Sinal no domínio do tempo	
$X_{ij}^{(k+1)}$	i-ésima entrada do j-ésimo neurônio da camada k-1	
y_{ij}	Saída j obtida para a entrada i	
y_j	Saída obtida no neurônio j	

RESUMO

Este trabalho consiste no desenvolvimento de uma metodologia para a avaliação da qualidade de montagem dos compressores produzidos. São aqui abordadas as ferramentas de Redes Neurais Artificiais (RNAs), Análise do Modo de Falha e Efeito (FMEA) e a Análise da Árvore de Falha (FTA). Com base nesta abordagem são propostas a análise dos principais modos de falha na montagem de compressores herméticos e a identificação automática destes modos através de redes neurais. Este estudo visa reduzir o número de compressores montados fora dos padrões recomendados pela empresa. Esta proposta objetiva extrair características de um sinal primitivo através de sensores instalados no painel de medição e classificar com uma rede neural os sinais de compressores bons e/ou ruins. Na avaliação da proposta os resultados obtidos são confrontados com o atual modelo de medição. Destaca-se o índice de acerto do modelo proposto que é entre 97% e 100% de padrões identificados corretamente. Sem dúvida, a identificação de problemas através de redes neurais artificiais mostra-se bastante promissora e com um alto índice de acerto.

ABSTRACT

This work concerns in a methodology development to evaluate the quality control in the assembly line compressors. Here it's deal with the tools of Artificial Neural Network (ANNs), Failure Mode and Effects Analysis (FMEA) and Fault Tree Analysis (FTA). Base on this approach there are the proposals of: main failure modes in the airtight compressors assembly line analysis and automatic identification of this cases through neural networks. This study intends to reduce the number of assembled compressors under the enterprise recommended standards. This proposal aim at to extract feature of a primitive signal through installed sensors in the measurement panel and classify with a Neural Network signs of perfect or defective compressors. To evaluate the proposal the obtained results are compared with the actual model of measurement. The rightness index of the proposed model is between 97% and 100% of correctly patterns identification. The problems identification through Artificial Neural Network is indeed very promising due the high level of certainty.

CAPÍTULO 1 – INTRODUÇÃO GERAL

1 – Introdução

As fortes pressões do mercado consumidor têm levado as empresas a desenvolverem seus produtos de forma contínua, buscando o aprimoramento das características técnicas e a redução do custo. Nesse processo insere-se também o aperfeiçoamento do sistema de avaliação da qualidade do produto, instalado no final da linha de montagem, a fim de evitar que produtos com defeitos adquiridos durante a montagem cheguem ao consumidor. O custo de reposição de cada um destes produtos pode chegar a centenas de vezes o seu custo de fabricação. Isto requer um controle rigoroso da qualidade na linha de montagem.

Esta tem sido uma das preocupações da Empresa Brasileira de Compressores S/A, sediada no estado de Santa Catarina, responsável por 20% da produção mundial de compressores herméticos usados em sistemas de refrigeração. Passam diariamente pelas linhas de montagem, apenas da unidade fabril catarinense, aproximadamente 35000 compressores. Este volume de produção exige eficiência, confiabilidade e rapidez do sistema de controle de qualidade na detecção de falhas. Atualmente o processo de medição utiliza como tomada de decisão um dispositivo passa/não-passa. Propõe-se neste estudo o uso de redes neurais artificiais para a análise e segregação de compressores herméticos em comparação com a técnica atualmente empregada nas linhas de produção.

1.1 – Objetivos

O objetivo desta dissertação consiste em desenvolver uma metodologia de segregação de compressores defeituosos e identificar automaticamente os principais modos de falha, com base na análise dos sinais de ruído e vibração adquiridos em um painel de teste instalado no final das linhas de montagem. Compressores com defeitos apresentam sinais cujos níveis diferem daqueles encontrados em compressores em perfeito estado de funcionamento.

Em uma primeira etapa será implementado um algoritmo de segregação e identificação de defeitos através de Redes Neurais Artificiais – RNAs. Na segunda etapa será montada a árvore de falhas (FTA – Análise da Árvore de Falha) para um modelo de compressor, juntamente com a Análise do Modo de Falha e Efeito – FMEA, para a identificação dos modos de falha mais frequentes.

O processo evolutivo atual de reconhecimento de padrão tem se mostrado promissor em diversas áreas de estudo. A sua aplicabilidade como ferramenta na resolução de problemas complexos tem sido valiosa, o que justificaria o seu uso em uma variedade de aplicações práticas.

A escolha de redes neurais deve-se ao fato de poder ser desenvolvida no tempo disponível para a dissertação e realizar as tarefas de identificação com eficiência. A aplicação da inteligência artificial no processo de detecção de falhas se justifica pela capacidade de generalização dos problemas.

As redes neurais artificiais são capazes de extrair informações não apresentadas de forma explícita através dos exemplos de treinamento. Não obstante, as RNAs são capazes de atuar como mapeadores universais de funções multi-variáveis, ou em outras palavras, as redes transformam um conjunto de variáveis não representativas em um modelo matemático correspondente. Outras características importantes são a capacidade de auto-organização dos parâmetros extraídos dos padrões de treinamento e da rapidez no processamento das informações.

Apesar das vantagens das aplicações das redes neurais, alguns cuidados devem ser tomados na escolha da rede ideal para cada aplicação específica. A escolha de uma arquitetura ideal para uma rede depende muito da tentativa e erro e da experiência do projetista. Este trabalho aborda testes de redes com configurações diferentes, buscando uma que seja adequada para o problema apresentado.

1.2 – Conteúdo da dissertação

O conteúdo apresentado neste trabalho está dividido em seis capítulos e três apêndices, seguidos das referências bibliográficas.

O capítulo dois apresenta as características gerais do compressor e do sistema de qualidade. O teste aplicado é mostrado de forma intuitiva e simples indicando a importância dessa avaliação na qualidade. A necessidade de rapidez é abordada como sendo crucial para atender a produção diária.

O suporte às principais ferramentas utilizadas neste estudo é apresentado no capítulo três. Neste capítulo, é mostrada uma definição sobre redes neurais artificiais, reconhecimento de padrões, aprendizado de redes, treinamento e o algoritmo de treinamento, demonstrando a importância desta técnica ao contexto atual de interpretação dos modos de

falha associados às deficiências de montagem dos componentes. Alguns conceitos sobre FTA e FMEA traduzem a aplicabilidade utilizada para entendimento do sistema de avaliação de compressores. Ao final deste capítulo é apresentado um breve conceito sobre a análise estatística dos resultados de parâmetros como: sensibilidade, especificidade, Valor Preditivo Aprovado (VLPA) e Valor Preditivo Segregado (VLPS), que reflete a probabilidade de uma falha ser ou não detectada.

O capítulo quatro apresenta a aplicação das ferramentas estudadas. Preocupou-se apenas em demonstrar um procedimento concreto entre as ferramentas associadas para detectar falhas nos compressores potencialmente defeituosos. O resultado desta análise gerou como aplicação a interface SISNAV (Sistema Neuro Acústico e Vibracional de Controle de Qualidade). No capítulo cinco, os resultados do modelo proposto são apresentados.

O capítulo seis apresenta as conclusões e sugestões para trabalhos futuros.

CAPÍTULO 2 – CARACTERÍSTICAS GERAIS DO SISTEMA

2.1 – Introdução

O presente capítulo retrata, em uma forma concisa, o princípio de funcionamento de compressores herméticos. As grandes variações da pressão no cilindro representam uma das principais fontes de vibrações transmitidas para a carcaça. A pulsação do *muffler* (filtro acústico) de sucção representa uma fonte de excitação do campo sonoro formado na cavidade, que excita também vibração na carcaça. Este é, também, um mecanismo importante de geração de ruído do compressor. Sendo assim, um sistema de controle de qualidade a ser instalado na linha de montagem de compressores pode basear-se na análise dos sinais de ruído e vibrações para posterior avaliação da qualidade do produto.

2.2 – Características gerais do compressor

Os compressores herméticos alternativos são envoltos externamente por uma carcaça formada por duas partes separadas, corpo e tampa, que permitem a instalação do conjunto interno. A Figura 2.2.1 mostra componentes que fazem parte deste conjunto. Ao final da montagem a tampa é soldada ao corpo. Fixados ao corpo encontram-se a placa-base, o terminal hermético, o limitador de oscilação e os passadores de sucção, de descarga e de processo. A função da placa-base é fixar o compressor ao sistema de refrigeração (refrigerador), enquanto o terminal hermético fixado à carcaça faz a conexão elétrica entre o conjunto e a rede elétrica, como mostrado na Figura 2.2.1.

Os componentes internos dividem-se em dois grupos principais: parte mecânica – compressor, e parte elétrica – motor de indução do tipo gaiola, montados de forma sobreposta e ligados por um eixo. Todo conjunto motor-compressor é apoiado sobre molas. O limitador de oscilação evita danos ao conjunto durante o transporte. As molas são as principais responsáveis pela transmissão de vibrações à carcaça. O óleo lubrificante, depositado no fundo da carcaça, é levado às partes superiores do compressor por meio de uma bomba fixada ao rotor.

O gás de refrigeração ocupa o espaço formado entre a carcaça e o conjunto motor-compressor, aqui denominado cavidade. É succionado para o interior do cilindro através do *muffler* de sucção e que possui a importante função de atenuar as fortes pulsações criadas pelos movimentos de grande amplitude da válvula de sucção. A pulsação ainda restante na

extremidade do *muffler* representa a principal fonte de excitação do campo sonoro na cavidade. Este, por sua vez, induz vibrações na carcaça. As principais fontes de vibrações transmitidas à carcaça através das molas, são geradas no conjunto motor-compressor, devido às grandes variações da pressão no cilindro.

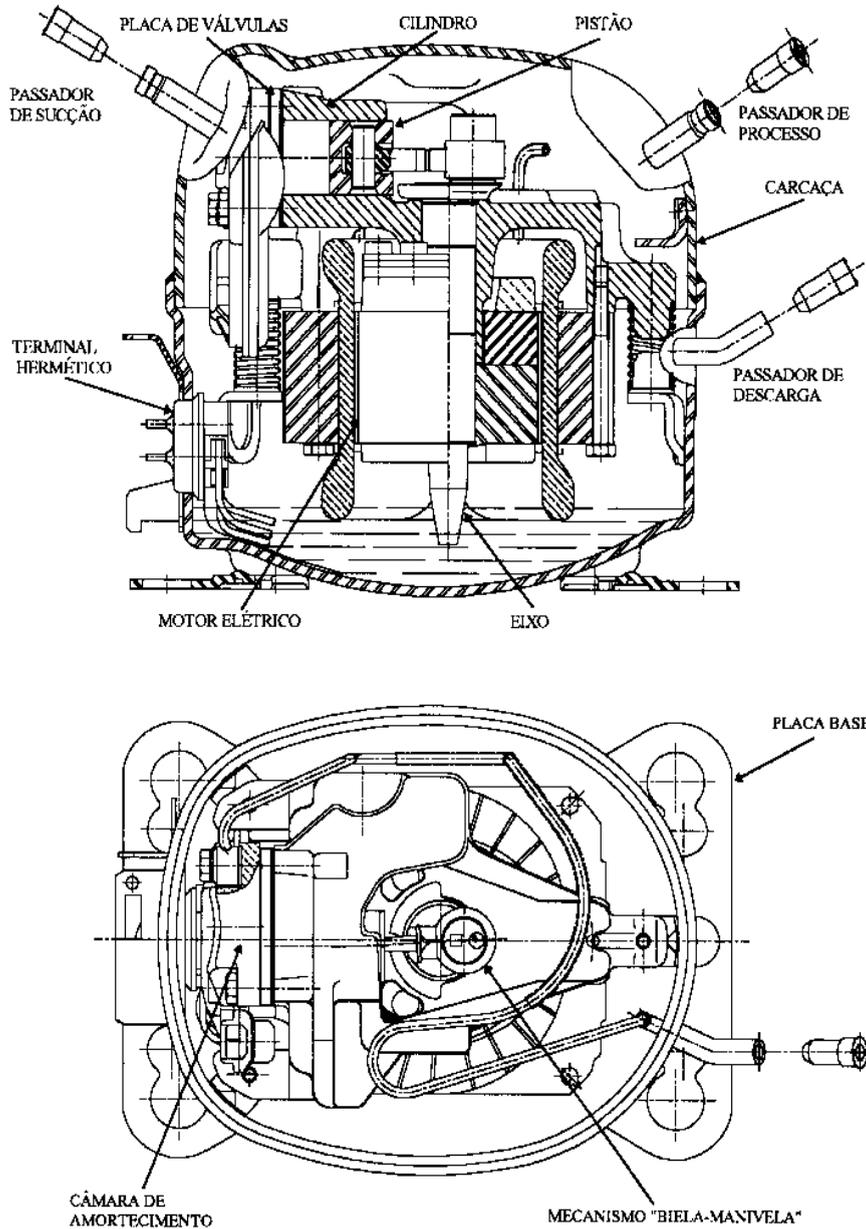


Figura 2.2.1 – Figura esquemática de um modelo de compressor

2.3 – Sistema de controle de qualidade

A empresa dispõe atualmente de sistemas de controle de qualidade de fabricação e montagem com base nas análises dos sinais de ruído e de vibração de compressores medidos

no final da linha de produção, com a finalidade de detectar defeitos, justamente antes do produto atingir o mercado consumidor (Figura 2.3.1a e b). Este sistema opera como um filtro passa/não-passa, o qual consiste em analisar os sinais obtidos e compará-los com resultados de espectros obtidos de compressores considerados normais e de boa qualidade.

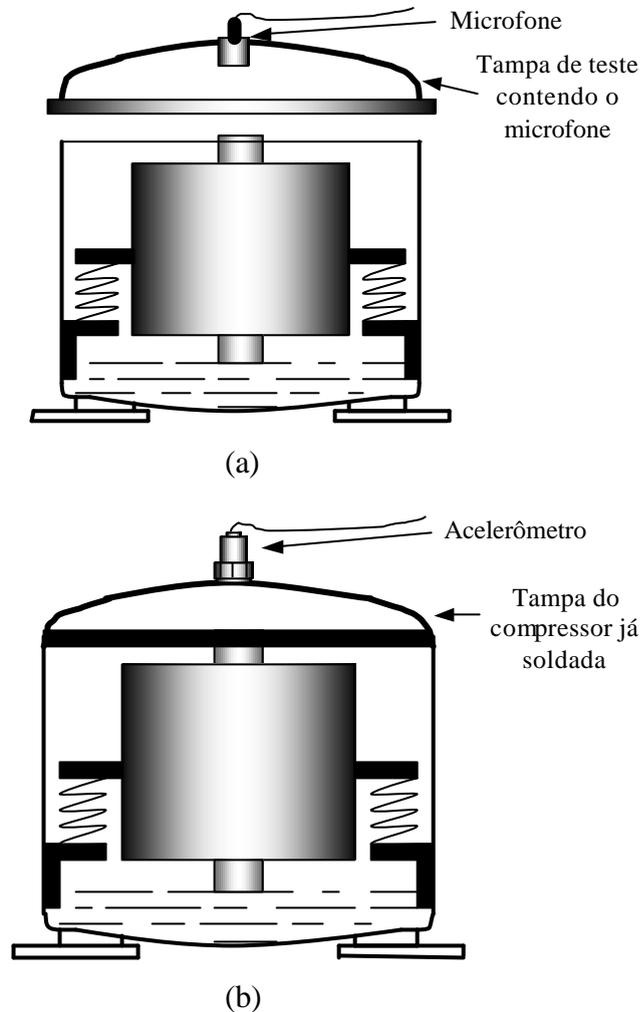


Figura 2.3.1 – Coleta de informações do painel: a) Medição dos sinais de ruído; b) Medição dos sinais de vibração

Os tipos de medições realizadas neste sistema são:

Ruído e vibrações → Testa o nível de ruído no interior da cavidade na região acima das partes móveis e abaixo da tampa da carcaça. Os níveis de vibração são medidos na tampa da carcaça, no final da linha de montagem, com o compressor completo, pronto para ser embalado.

Capacidade → Testa as pressões máximas que o compressor é capaz de produzir.

Consumo elétrico → Testa o consumo de corrente elétrica.

Permanência → Testa a capacidade que o compressor tem de manter a pressão, ou seja, verificar a existência de vazamento da linha de descarga do compressor.

A Figura 2.3.2 mostra um fluxograma do tratamento dos sinais analisados pelo painel.

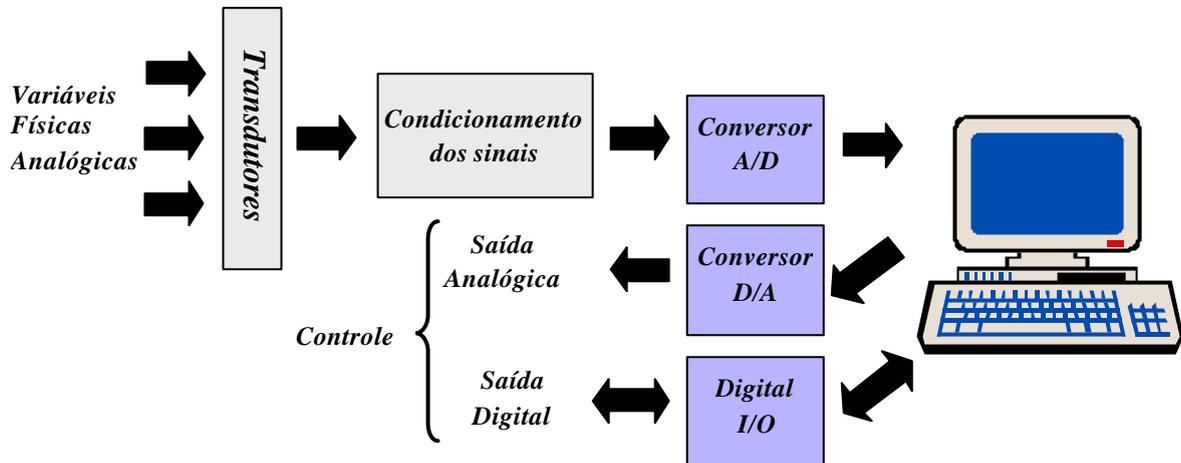


Figura 2.3.2 – Esquema básico de um painel de controle de qualidade na montagem de compressores herméticos

A análise dos sinais obtidos deve ser realizada em um curto espaço de tempo visto que a necessidade de rapidez é inevitável para atender toda a produção diária. A Figura 2.3.3 mostra o tempo de teste no qual um compressor hermético avança na linha de produção (CRISTALLI, 2000). O tempo total disponível para teste é 8 segundos, e o compressor avança fixado, automaticamente, sobre a mesa de teste. Uma vez posicionado, a tampa dotada de um microfone (Figura 2.3.1 a) é fixada ao corpo (carcaça) do compressor*. O compressor é ligado e, inicialmente, a rotação do compressor é aumentada rapidamente dentro de um limite de tempo da ordem de 2 segundos. Após entrar em regime permanente, são realizados os testes de ruído e vibrações (e outros). Ao final desta operação reduz-se a rotação do compressor até que o mesmo pare. Após o término desta operação o compressor é liberado da mesa de teste. Durante o regime normal de operação o sistema de controle adquire os sinais de ruído gerados pelos componentes internos e as vibrações na carcaça. Este teste define a qualidade final do produto.

* O teste de vibrações segue o mesmo princípio. O compressor neste teste está hermeticamente fechado e o painel possui um acelerômetro no lugar da tampa e do microfone (Figura 2.3.1 b).

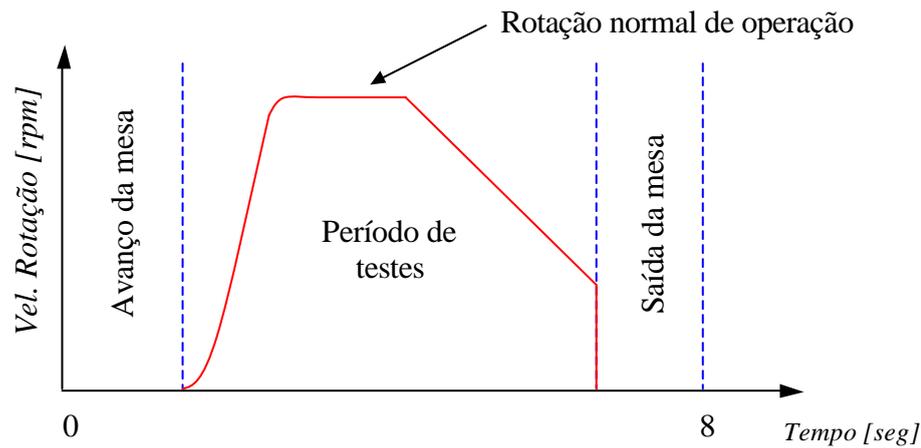


Figura 2.3.3 – Esquema de tempo de teste de um compressor

O critério atual de segregação do painel consiste em comparar sinais de compressores defeituosos com um padrão de referência. Na Figura 2.3.4 tem-se em vermelho um espectro referente a um determinado defeito, e em azul os limites medidos em compressores normais (padrão de referência). Este exemplo hipotético mostra algumas faixas de frequência nas quais os níveis são bastantes distintos. Para tanto, busca-se uma relação entre este tipo de análise e a respectiva falha que a caracterizou. O sinal coletado pelo sistema de qualidade, é comparado com um padrão de referência dado por um compressor em funcionamento normal. Havendo diferenças em relação aos níveis do padrão de referência, pode-se verificar ou não a presença de uma falha.

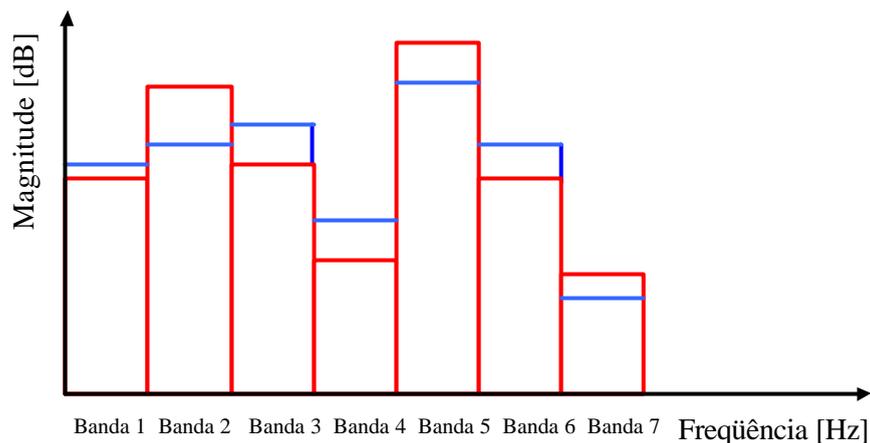


Figura 2.3.4 – Critério de segregação atual

Pesquisas estão sendo realizadas para a redução do número de compressores segregados indevidamente. Atualmente o painel mede sinais de ruído e vibrações. Em ambos

os casos o sinal medido é transformado para o domínio da frequência através da Transformada de Fourier para análises e comparações posteriores.

A Transformada de Fourier é uma ferramenta de análise espectral sendo que a aplicação mais comum desta técnica matemática é a análise de sistemas lineares invariantes no tempo (E. Oran Brigham, 1974). Seja uma função periódica $x(t)$ que é expressa pela função

$$x(t) = \frac{1}{2} \sum_{n=0}^{\infty} (C_n e^{in\omega_o t} + C_n^* e^{-in\omega_o t}) \tag{2.3.1}$$

sendo o coeficiente C_n , nesta expressão, dado pela equação

$$C_n = \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} x(j) e^{-in\omega_o j} dj \tag{2.3.2}$$

onde T é o período. A Equação 2.3.2 indica que $C_n^* = C_{-n}$, podendo-se, então, reescrever a Equação 2.3.1 na forma

$$\begin{aligned} x(t) &= \sum_{n=-\infty}^{\infty} C_n e^{in\omega_o t} \\ x(t) &= \sum_{n=-\infty}^{\infty} \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} x(j) e^{-in\omega_o j} e^{in\omega_o t} dj \end{aligned} \tag{2.3.3}$$

A frequência $\omega = n\omega_o$ é especificada em intervalos discretos, e o seu incremento é

$$\Delta\omega = (n+1)\omega_o - n\omega_o = \omega_o = \frac{2\pi}{T}$$

Substituindo $1/T$ por $\Delta\omega/2\pi$ e considerando $T \rightarrow \infty$, $\Delta\omega \rightarrow d\omega$ e $n\omega_o \rightarrow \omega$, a Equação 2.3.3 torna-se

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \left\{ \int_{-\infty}^{\infty} x(j) e^{-i\omega j} dj \right\} e^{i\omega t} d\omega \tag{2.3.4}$$

Considerando que a expressão dentro de chaves é uma função somente de $i\omega$, pode-se reescrever a Equação 2.3.4 em duas parcelas

$$X(i\omega) = \int_{-\infty}^{\infty} x(j) e^{-i\omega j} dj \quad (2.3.5)$$

e

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(i\omega) e^{i\omega t} d\omega \quad (2.3.6)$$

onde $X(i\omega)$ é a Transformada de Fourier de $x(t)$. As duas equações acima são denominadas de par Transformadas de Fourier. A Equação 2.3.5 reduz $x(t)$ a componentes harmônicos $X(i\omega)$, enquanto que a Equação 2.3.6 reduz $X(i\omega)$ a componentes na função original $x(t)$. Na prática é mais conveniente expressar a frequência angular ω [rad/seg] em frequência f [Hz]. Desta forma, as expressões de Transformada de Fourier tornam-se

$$X(f) = \int_{-\infty}^{\infty} x(j) e^{-i2\pi f j} dj \quad (2.3.7)$$

e

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(f) e^{i2\pi f t} df \quad (2.3.8)$$

A Transformada Rápida de Fourier é utilizada no bloco funcional da rede neural conforme será apresentado mais adiante. A essência do cálculo da FFT (*Fast Fourier Transform*) é uma série de operações matemáticas conhecidas como DFT (*Discrete Fourier Transform*) que é um conjunto de m variáveis no domínio da frequência a partir de um conjunto de n amostras no domínio do tempo. A importância desta ferramenta na classificação é a identificação automática das falhas em compressores herméticos. A diferença dos níveis em dB por faixa de frequência é o critério de avaliação utilizado pela rede na classificação.

2.4 – Comentário

Os fabricantes expressam grande preocupação com a não segregação de compressores ruins, dado que a manifestação das falhas será inevitavelmente percebida pelo cliente. A insatisfação e o custo de reposição do produto são fatores importantes a serem considerados. Isto demanda forte investimento no desenvolvimento de técnicas que executem esta tarefa de forma mais eficiente. Neste sentido será apresentado no capítulo 3 o método de redes neurais artificiais. O objetivo é apropriar esse conhecimento ao estudo que vem sendo realizado atualmente no painel para segregação de compressores ruins.

CAPITULO 3 – CONCEITOS BÁSICOS

3.1 – Introdução

Este capítulo apresenta uma revisão sobre redes neurais artificiais e das ferramentas FTA (Análise da Árvore de Falha) e FMEA (Análise dos Modos de Falhas e Efeito). Serão apresentados conceitos básicos relacionados aos métodos que serão empregados neste trabalho.

3.2 – Rede Neural Artificial – RNA

3.2.1 – Introdução

Redes Neurais Artificiais – RNAs são sistemas paralelamente distribuídos compostos por unidades de processamento que computam determinadas funções matemáticas normalmente não-lineares. Estas unidades de processamento são normalmente dispostas em camadas e interligadas por um grande número de conexões. Cada conexão está associada a um peso, os quais armazenam o conhecimento aprendido pela rede e servem para ponderar a entrada recebida por cada neurônio da rede. A inspiração da estrutura física e do funcionamento teve sua analogia no cérebro humano (DUARTE, 2000).

Segundo HAYKIN (1999), uma RNA é um processador distribuído paralelamente composto de unidades de processamento simples que têm a função natural de armazenar conhecimento de experiências sendo estas disponíveis para uso. As redes neurais artificiais se assemelham ao cérebro em dois aspectos:

- 1 – O conhecimento da rede é adquirido através de um processo de aprendizado.
- 2 – São usadas forças entre as conexões, conhecidas como pesos sinápticos, para armazenar o conhecimento adquirido.

O trabalho de redes neurais foi motivado pela capacidade que o cérebro possui em computar informações de um modo completamente diferente da computação digital convencional.

A solução de problemas através de RNAs é bastante atrativa, haja vista que a sua capacidade de representar informações, extraídas de um conjunto de padrões de treinamento e sua capacidade de generalizar a informação aprendida são, sem dúvida, os atrativos principais

desta ferramenta. Outras características importantes são a capacidade de auto-organização e de processamento temporal.

3.2.2 – Analogia entre neurônios biológicos e artificiais

Os neurônios biológicos são divididos em três seções: o corpo da célula, os dendritos e o axônio, sendo cada uma destas funções específicas e complementares. Os dendritos têm por função receber as informações, ou impulsos nervosos oriundos de outros neurônios, e conduzi-los até o corpo celular. Ali, a informação é processada e novos impulsos são gerados. Estes impulsos são transmitidos a outros neurônios, passando através do axônio até os dendritos dos neurônios seguintes. O ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro é chamado de sinapse. É pelas sinapses que os neurônios se unem funcionalmente, formando as redes neurais. As sinapses são capazes de controlar o fluxo de informações entre os neurônios. A Figura 3.2.1 ilustra, de forma simplificada, os componentes do neurônio (DUARTE, 2000).

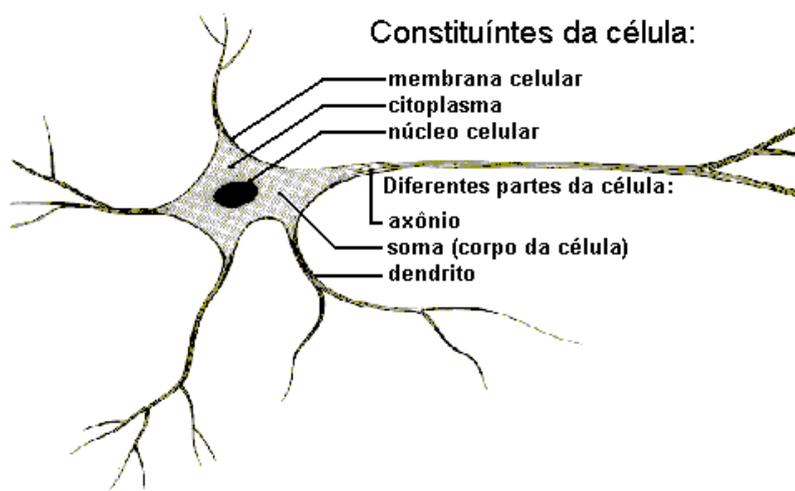


Figura 3.2.1 – Estrutura de um neurônio biológico

Através do mesmo princípio, o neurônio artificial mostrado na Figura 3.2.2 recebe um conjunto de sinais de outros neurônios, onde é computada a soma entre os sinais de entrada e os pesos das respectivas conexões. Depois de acumulado, o valor somado dos produtos entre as entradas e os pesos é aplicado à função de transferência, produzindo uma ativação do neurônio.

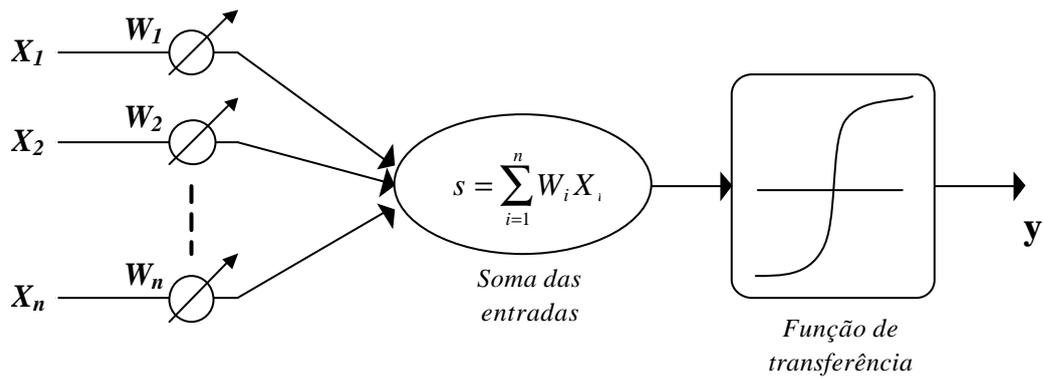


Figura 3.2.2 – Modelo de um neurônio artificial

A descrição matemática resultou em um modelo com n terminais de entrada (X_1, X_2, \dots, X_n), que representam os dendritos, e apenas um terminal de saída, y , representando o axônio. Para representar o comportamento das sinapses, os terminais de entrada do neurônio têm pesos que funcionam como resistores acoplados (W_1, W_2, \dots, W_n) cujos valores podem ser positivos ou negativos, dependendo das sinapses correspondentes serem excitatórias ou inibitórias respectivamente.

Normalmente, existe um valor de s que ocasiona um disparo súbito do neurônio quando a soma dos impulsos que ele recebe ultrapassa o seu limiar de excitação q , também conhecida como limiar lógico *threshold*. O corpo do neurônio, por sua vez, é emulado por um mecanismo simples que faz a soma dos valores $X_i W_i$ recebidos pelo neurônio e decide se o neurônio deve ou não disparar comparando a soma obtida ao limiar do neurônio. Na descrição original do modelo MCP proposto por McCulloch e Pitts (LOESCH, 1996), a função de ativação é dada pela função de limiar, descrita pela Equação 3.2.1. O neurônio MCP terá, então, sua saída ativa quando

$$s = \sum_{i=1}^n X_i W_i \geq q \quad (3.2.1)$$

sendo n , o número de entradas do neurônio; W_i , o peso associado à entrada X_i , e q , o limiar do neurônio.

3.2.3 – Funções de ativação e transferência

A ativação do neurônio é obtida através da aplicação da função de ativação, que antecede a função de transferência. Segundo Tafner (1995), a função de ativação é uma função de ordem interna, que tem como atributo calcular um nível de ativação dentro do

próprio neurônio (neurônios dinâmicos) que pode ser dado pelo valor resultante do somatório das entradas ponderadas, ou seja, em modelos mais simples de redes neurais, a função de ativação pode ser a própria função de transferência (neurônios estáticos). Após este valor ter sido processado pela função de ativação é, então, computado pela função de transferência que produzirá o valor de saída no neurônio. Existem quatro tipos principais de funções de transferência: a função linear, a função rampa, a função degrau e a função sigmoidal.

A função de transferência linear é definida pela Equação 3.2.2

$$y = \alpha \cdot x \quad (3.2.2)$$

sendo α uma constante

A função linear pode ser restrita para produzir valores constantes em uma faixa $[-g, +g]$, neste caso a função passa a ser a função rampa definida pela Equação (3.2.3)

$$y = \begin{cases} +g & \text{se } x \geq +g \\ x & \text{se } |x| < +g \\ -g & \text{se } x \leq -g \end{cases} \quad (3.2.3)$$

A função degrau é definida pela Equação 3.2.4

$$y = \begin{cases} +g & \text{se } x > 0 \\ -g & \text{se } x \leq 0 \end{cases} \quad (3.2.4)$$

As funções sigmoidais são encontradas na modelagem de diversos tipos de problemas físicos. Uma das funções sigmoidais mais importantes é a função logística definida pela Equação 3.2.5

$$y = \frac{1}{1 + e^{-\frac{x}{T}}} \quad (3.2.5)$$

em que o parâmetro T determina a suavidade da curva.

3.2.4 – Principais estruturas de RNAs

As redes neurais, segundo DUARTE (2000), podem ser classificadas de acordo com:

Número de camadas:

- Redes de camada única – só existe um nó entre qualquer entrada e qualquer saída da rede (Figura 3.2.3 a, e);
- Redes de múltiplas camadas – existe mais de um neurônio entre alguma entrada e alguma saída da rede (Figura 3.2.3 b, c, d).

Tipo de conexão:

- *Feedforward*, ou acíclica – a saída de um neurônio na i -ésima camada da rede não pode ser usada como entrada de neurônios em camadas de índice menor ou igual a i (Figura 3.2.3 a, b, c);
- *Feedback*, ou cíclica – a saída de algum neurônio na i -ésima camada da rede é usada como entrada de neurônios em camadas de índice menor ou igual a i (Figura 3.2.3 d).

Conectividade:

- Rede fracamente ou parcialmente conectada (Figura 3.2.3 b, c, d);
- Rede completamente conectada (Figura 3.2.3 a, e).

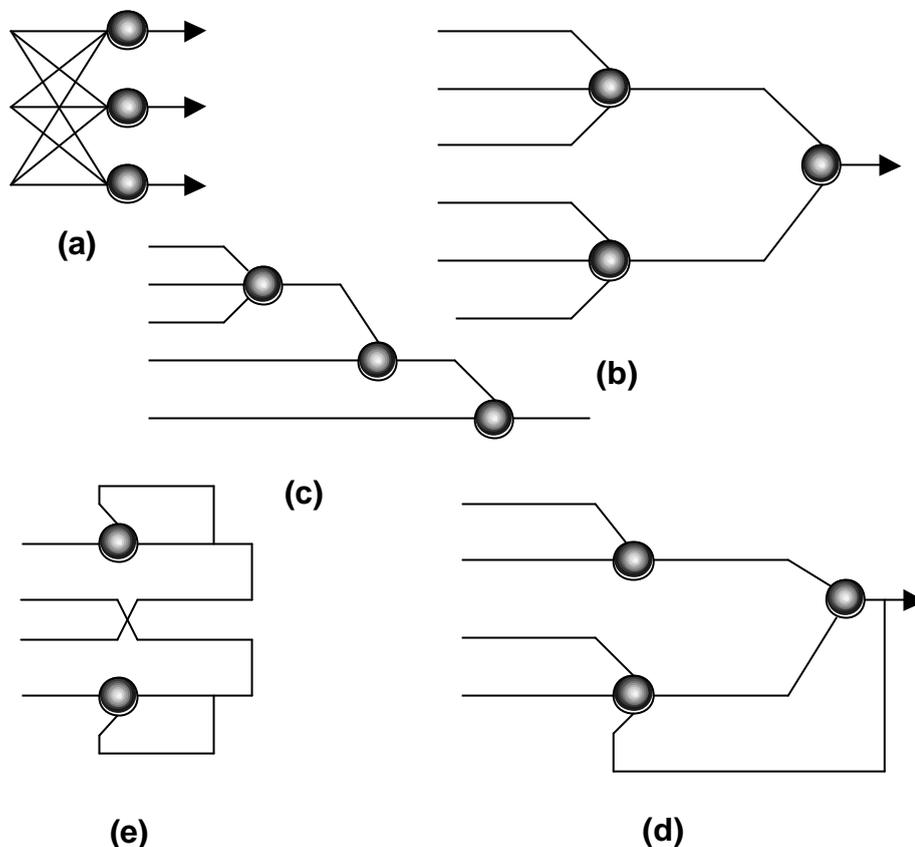


Figura 3.2.3 – Principais estruturas de RNAs

Se todas as ligações são cíclicas, a rede é denominada de auto-associativa. Estas redes associam um padrão de entrada com ele mesmo, e são particularmente úteis para recuperação ou “regeneração” de um padrão de entrada (Figura 3.2.3 e).

3.2.5 – O perceptron

O perceptron foi a primeira rede a surgir. O seu conceito de neurônio artificial é ainda hoje usado. Cada neurônio computa uma soma ponderada das entradas, e esta soma passa por uma função de limiarização, como mostra a Figura 3.2.4.

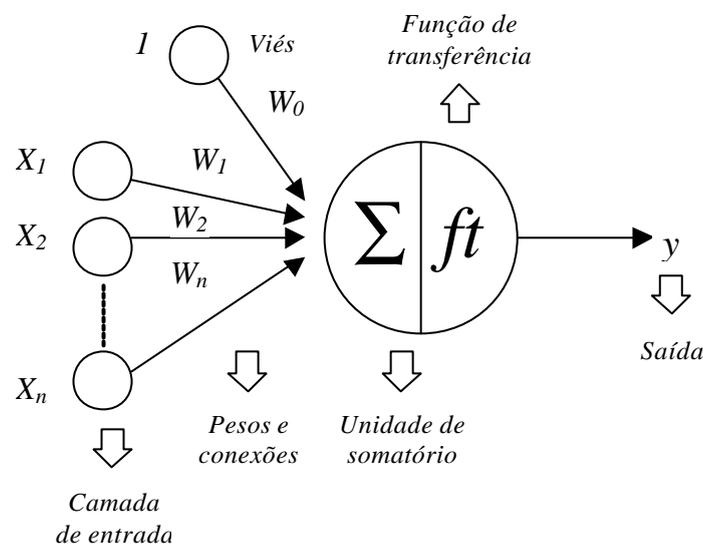


Figura 3.2.4 – Unidade de processamento do perceptron

O viés como visto na Figura 3.2.4, é um elemento especial da camada de entrada, cujo sinal tem sempre valor unitário. A conexão do viés com a unidade de somatório tem peso W_0 , que são ajustados da mesma forma que os demais pesos.

Foi somente com o trabalho de Frank Rosenblatt, em 1957 (Z.L.Kovács, 1996), que o conceito de aprendizado em RNAs foi introduzido. O modelo proposto por Rosenblatt, conhecido como perceptron, era composto por uma estrutura de rede tendo como unidades básicas neurônios MCP e de uma regra de aprendizado.

Apesar do perceptron não resolver problemas muito complexos, foram extensivamente estudados. Mesmo com uma capacidade limitada para resolver problemas e uma estrutura simples, este modelo possuía grande capacidade na classificação de padrões.

Sua teoria apresenta princípios importantes, os quais representam, sem dúvida, a base fundamental para o estudo de redes neurais.

A regra de aprendizado do perceptron permite a adaptação dos seus pesos de forma que a rede execute uma classificação. O conjunto de treinamento deve conter exemplos de cada classe que se deseja que a rede aprenda. É, portanto, um aprendizado supervisionado.

De forma geral, no processo de aprendizado ou adaptação, o que se deseja obter é o valor do incremento ΔW a ser aplicado ao vetor de peso \vec{W} de forma tal que o seu valor atualizado $W(t+1) = W(t) + \Delta W$ esteja mais próximo da solução desejada, comparada à solução calculada no passo anterior $W(t)$.

3.2.6 – Redes MLP

As redes Perceptron possuem apenas uma camada de processamento e resolvem apenas problemas linearmente separáveis, cujas variáveis são dependentes. As redes do tipo perceptron multicamada ou MLP (*Multilayer Perceptron*), que apresentam pelo menos uma camada oculta, resolvem problemas não linearmente separáveis. Uma rede com uma camada intermediária pode implementar qualquer função contínua. A utilização de duas camadas intermediárias permite a aproximação de qualquer função (DUARTE, 2000).

Para o treinamento de redes perceptron multicamada foi proposto um método que se baseia em um gradiente descendente. Para utilizar este método, a função de transferência precisa ser contínua, diferenciável e, de preferência, não decrescente. A função de transferência deve informar os erros cometidos pela rede para as camadas anteriores com a maior precisão possível. A alternativa utilizada para superar os problemas acima citados foi a utilização de funções de transferência sigmoidal, como a definida pela Equação 3.2.5.

As redes MLP apresentam um poder computacional muito maior que aquele apresentado pelas redes sem camadas intermediárias, tratando dados não linearmente separáveis. As unidades intermediárias de uma rede MLP funcionam como detetores de características gerando uma codificação interna dos padrões de entrada, que é, então, utilizada para a definição da saída da rede. A precisão obtida e a implementação da função dependem do número de neurônios utilizados nas camadas intermediárias. A relação do número de neurônios nas camadas intermediárias é geralmente definida empiricamente. Algumas sugestões, no entanto, têm sido apresentadas:

- Definir o número de unidades em função do número de entradas e saídas.
- Utilizar um número de conexões dez vezes menor que o número de exemplos. No entanto, um número muito reduzido pode levar a rede a não convergir durante seu treinamento.

O número adequado de neurônios na camada intermediária depende de vários fatores, como:

- Número de exemplos de treinamento;
- Quantidade de ruído presente nos exemplos;
- Complexidade da função a ser aprendida;
- Distribuição estatística dos dados de treinamento.

Para a solução de problemas práticos de reconhecimento de padrões, deve-se testar um número de unidades intermediárias suficientes para a solução do problema.

3.2.7 – Reconhecimento de padrões

O reconhecimento de padrões pode ser definido como sendo o processo de identificação pelo qual se classificam certas estruturas pelas suas características, através de comparações entre classes distintas. O mapeamento de certos conjuntos de classes de falhas em um espaço N-dimensional qualquer, descreve os atributos deste subespaço por meio de uma representação vetorial das classes.

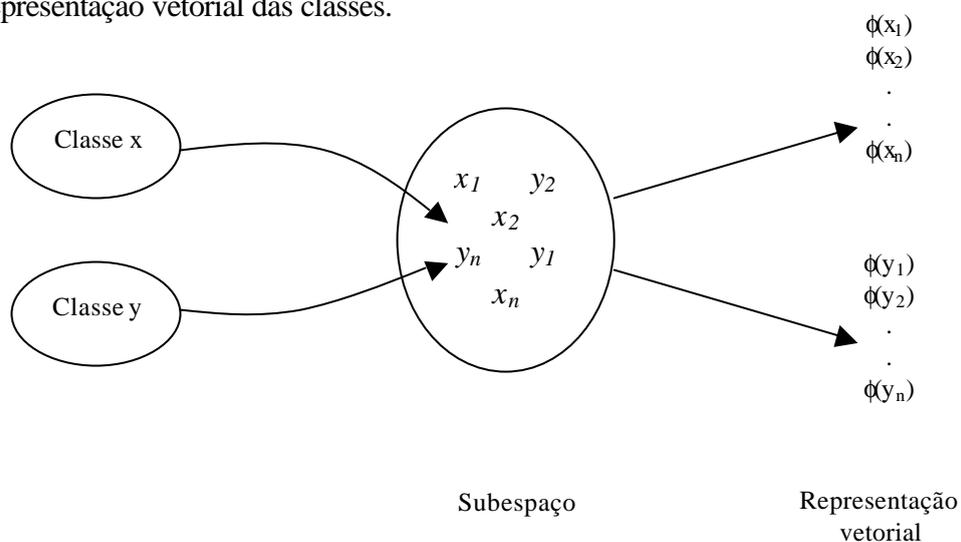


Figura 3.2.5 – Representação vetorial de classes de padrões

A descrição de um padrão retrata as informações contidas em cada categoria envolvida no reconhecimento de falhas em compressores. A Figura 3.2.5 ilustra esta definição. Os vetores de entrada

$$\Phi_m^x = [f(x_1), f(x_2) \dots f(x_n)] \text{ e } \Phi_m^y = [f(y_1), f(y_2) \dots f(y_n)]$$

expressam as classes de falhas do subespaço contendo as variáveis x e y . As variáveis deste subespaço representam os modos de falha presentes na linha de montagem do compressor. E m e n representam o número de padrões contendo o mesmo modo de falha e o número de faixas de frequência, respectivamente.

3.2.8 – Aprendizado

O algoritmo de aprendizado é um conjunto de procedimentos definidos para adaptar os parâmetros de uma RNA para que a mesma possa aprender uma determinada função. A rede, inicialmente, passa por um processo de aprendizado com o intuito de extrair informações sobre as características dos padrões de falha dos compressores a ela apresentada, antes de separá-los em classes de falhas.

O aprendizado propriamente dito é um processo iterativo de ajuste dos parâmetros da rede, ou seja, dos pesos atribuídos às conexões entre os neurônios os quais armazenam todo o conhecimento adquirido pela rede no estágio inicial do aprendizado.

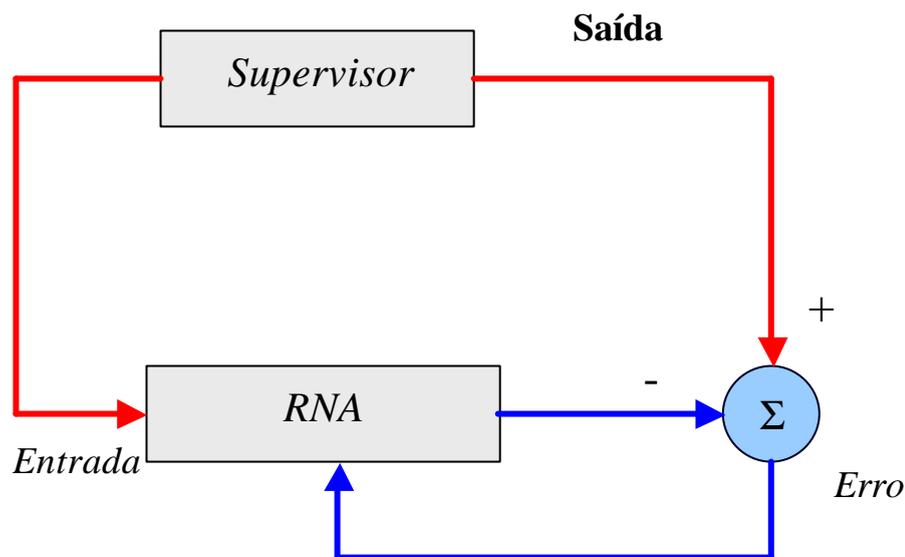


Figura 3.2.6 – Aprendizado supervisionado

A escolha do algoritmo de treinamento fica a cargo do projetista da rede, sendo necessários testes que variam de acordo com o problema que se deseja solucionar e o tempo disponível para a realização do treinamento da RNA. Existem vários tipos de algoritmos de aprendizado, podendo ser agrupados em dois grupos principais: Aprendizado Supervisionado e Aprendizado Não Supervisionado (DUARTE, 2000).

No aprendizado supervisionado os vetores de entrada e saída são fornecidos por um supervisor externo como visto na Figura 3.2.6. Os pesos são ajustados a cada etapa de treinamento a fim de minimizar o erro existente entre a resposta desejada e a calculada pela RNA.

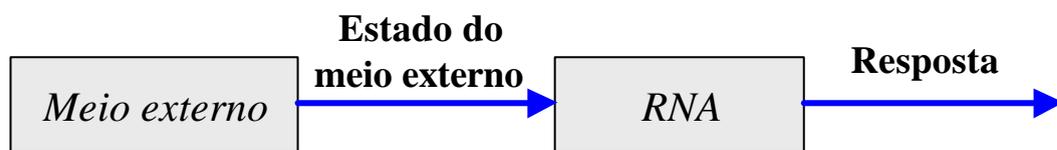


Figura 3.2.7 – Aprendizado não supervisionado

No aprendizado não supervisionado não existe o supervisor acompanhando o processo de aprendizado como visto na Figura 3.2.7. Para este tipo de aprendizado somente padrões de entrada são fornecidos à rede. A partir do momento que a rede estabelece uma certa regularidade na identificação ela adquire uma forma de codificar as características dos padrões de entrada criando assim novas classes automaticamente. O aprendizado não supervisionado possui a desvantagem de não trazer informações diretas dos modos de falha, ou seja, não há um controle mais rigoroso das classes de falhas envolvidas durante o reconhecimento. Uma rede com aprendizado não supervisionado faz *clusterização*, isto é, identifica agrupamentos de dados, que no caso são as falhas envolvidas na fabricação de compressores herméticos.

Embora estas classes existam, não há a possibilidade de identificá-las como no aprendizado supervisionado. Apenas classes de padrões são isoladas automaticamente pela rede de acordo com características extraídas de novos padrões. Este processo de classificação é dado pelo algoritmo, não tendo a influência de um supervisor externo. A RNA deve produzir respostas de tal sorte que se possa relacionar com as falhas de montagem do compressor. Assim sendo, o aprendizado supervisionado será empregado no decorrer do estudo por ser o método ideal para esta aplicação.

3.2.9 – Regra delta generalizada

Na regra delta generalizada, também conhecida como *backpropagation*, os pesos entre as conexões são modificados proporcionalmente ao erro médio quadrático entre o resultado calculado pela rede e o desejado. O algoritmo *backpropagation* utiliza a primeira derivada parcial do erro total referente a cada peso para ajustar cada um destes. Esta é uma técnica de minimização dos erros cujas equações operam sobre funções diferenciais baseadas numa heurística de gradiente descendente. Esta regra de treinamento é a base do aprendizado de uma rede *feedforward* multicamadas, como mostra a Figura 3.2.8.

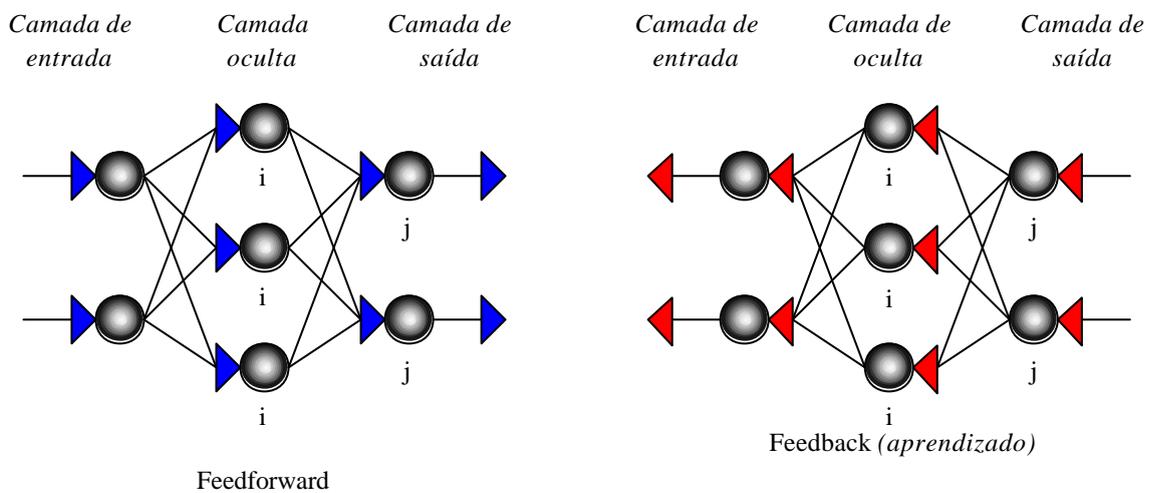


Figura 3.2.8 – Treinamento com algoritmo de retropropagação

A regra delta generalizada usa, em sua essência, a regra da cadeia do cálculo diferencial. O erro quadrático calculado na saída da rede é

$$e^2 = \sum_{j=1}^m (d_j - y_j)^2 \quad (3.2.6)$$

onde m é o número de neurônios na última camada, d a saída desejada e y a saída obtida pela rede.

Considere um neurônio j em uma camada k , tal que $\vec{W}_j^{(k)}$ e $\vec{X}_j^{(k)}$ representam os vetores peso e de entrada, respectivamente, e definidos por

$$\begin{aligned}\vec{W}_j^{(k)} &= [W_{0j}^{(k)}, W_{1j}^{(k)}, \dots, W_{mj}^{(k)}] \\ \vec{X}_j^{(k)} &= [1, X_{1j}^{(k)}, \dots, X_{mj}^{(k)}]\end{aligned}\quad (3.2.7)$$

O gradiente instantâneo para este neurônio é

$$\vec{\nabla}_j^{(k)} = \frac{\partial e^2}{\partial \vec{W}_j^{(k)}} = \left[\frac{\partial e^2}{\partial W_{0j}^{(k)}}, \frac{\partial e^2}{\partial W_{1j}^{(k)}}, \dots, \frac{\partial e^2}{\partial W_{mj}^{(k)}} \right] \quad (3.2.8)$$

Sabe-se que cada neurônio processa uma média ponderada como definido na Equação 3.2.1

$$s_j^{(k)} = \sum_{i=1}^{m_k} x_i^{(k-1)} w_{ij}^{(k)} \quad (3.2.9)$$

onde

$x_i^{(k-1)}$ é a i -ésima entrada do j -ésimo neurônio da camada $k-1$

m_k é o número de neurônios na k -ésima camada

A saída da função de transferência do neurônio é uma função contínua e diferenciável, definida como

$$x_j^{(k)} = f(s_j^{(k)}) \quad (3.2.10)$$

De acordo com a Equação 3.2.9, tem-se

$$\vec{\nabla}_j^{(k)} = \frac{\partial e^2}{\partial \vec{W}_j^{(k)}} = \frac{\partial e^2}{\partial s_j^{(k)}} \frac{\partial s_j^{(k)}}{\partial \vec{W}_j^{(k)}} \quad (3.2.11)$$

$$\frac{\partial s_j^{(k)}}{\partial \vec{W}_j^{(k)}} = \frac{\partial \vec{W}_j^{(k)} \vec{X}_j^{(k)}}{\partial \vec{W}_j^{(k)}} = \vec{X}_j^{(k)} \quad (3.2.12)$$

então,

$$\vec{\nabla}_j^{(k)} = \frac{\partial e^2}{\partial s_j^{(k)}} = \frac{\partial e^2}{\partial s_j^{(k)}} \vec{X}_j^{(k)} \quad (3.2.13)$$

A derivação do erro quadrático associado ao j -ésimo neurônio na k -ésima camada é

$$\mathbf{d}_j^{(k)} = -\frac{1}{2} \frac{\partial \mathbf{e}^2}{\partial s_j^{(k)}} \quad (3.2.14)$$

Desta forma, pode-se escrever

$$\bar{\mathbf{V}}_j^{(k)} = -2\mathbf{d}_j^{(k)} \bar{\mathbf{X}}_j^{(k)} \quad (3.2.15)$$

Para uma camada de saída, o erro quadrático é calculado substituindo-se as Equações 3.2.6 e 3.2.10 em 3.2.14. Assim, obtém-se

$$\mathbf{d}_j^{(k)} = -\frac{1}{2} \frac{\partial \sum_{i=1}^{m_k} (d_i - y_i)^2}{\partial s_j^{(k)}} = -\frac{1}{2} \frac{\partial \sum_{i=1}^{m_k} (d_i - f(s_i^{(k)}))^2}{\partial s_j^{(k)}} \quad (3.2.16)$$

quando i é diferente de j as derivadas se anulam, tal que

$$\mathbf{d}_j^{(k)} = -\frac{1}{2} \frac{\partial (d_j - f(s_j^{(k)}))^2}{\partial s_j^{(k)}} = -(d_j - f(s_j^{(k)})) \frac{\partial (d_j - f(s_j^{(k)}))}{\partial s_j^{(k)}} = (d_j - x_j^{(k)}) f'(s_j^{(k)}) \quad (3.2.17)$$

Denotando que o erro na saída do neurônio na última camada seja

$$\mathbf{e}_j^{(k)} = d_j - x_j^{(k)} = d_j - y_j \quad (3.2.18)$$

então

$$\mathbf{d}_j^{(k)} = \mathbf{e}_j^{(k)} f'(s_j^{(k)}) \quad (3.2.19)$$

Portanto, o erro na camada de saída é dado através do produto do erro da saída associado ao neurônio pela derivada da função de transferência. A derivação do erro quadrático da Equação 3.2.14 associado a uma camada oculta k é expandido através da regra da cadeia:

$$\mathbf{d}_j^{(k)} = -\frac{1}{2} \frac{\partial \mathbf{e}^2}{\partial s_j^{(k)}} = -\frac{1}{2} \sum_{i=1}^{m_{k+1}} \left(\frac{\partial \mathbf{e}^2}{\partial s_i^{(k+1)}} \frac{\partial s_i^{(k+1)}}{\partial s_j^{(k)}} \right) = \sum_{i=1}^{m_{k+1}} \left(\left(-\frac{1}{2} \frac{\partial \mathbf{e}^2}{\partial s_i^{(k+1)}} \right) \frac{\partial s_i^{(k+1)}}{\partial s_j^{(k)}} \right) \quad (3.2.20)$$

substituindo e Equação 3.2.14 em 3.2.20, tem-se

$$\mathbf{d}_j^{(k)} = \sum_{i=1}^{m_{k+1}} \left(\mathbf{d}_i^{(k+1)} \frac{\partial s_i^{(k+1)}}{\partial s_j^{(k)}} \right) \quad (3.2.21)$$

Substituindo $s_i^{(k+1)}$ pelas Equações 3.2.9 e 3.2.10

$$\mathbf{d}_j^{(k)} = \sum_{i=1}^{m_{k+1}} \left(\mathbf{d}_i^{(k+1)} \frac{\partial}{\partial s_j^{(k)}} \left(\sum_{l=1}^{m_k} f(s_l^{(k)}) w_{li}^{(k+1)} \right) \right) \quad (3.2.22)$$

$$\mathbf{d}_j^{(k)} = \sum_{i=1}^{m_{k+1}} \left(\mathbf{d}_i^{(k+1)} \sum_{l=1}^{m_k} w_{li}^{(k+1)} \frac{\partial}{\partial s_j^{(k)}} f(s_l^{(k)}) \right) \quad (3.2.23)$$

Note que $\frac{\partial}{\partial s_j^{(k)}} f(s_l^{(k)}) = 0$ se $l \neq j$, sendo $\frac{\partial}{\partial s_j^{(k)}} f(s_j^{(k)}) = f'(s_j^{(k)})$. Então

$$\mathbf{d}_j^{(k)} = \sum_{i=1}^{m_{k+1}} \left(\mathbf{d}_i^{(k+1)} w_{ji}^{(k+1)} f'(s_j^{(k)}) \right)$$

ou, ainda:

$$\mathbf{d}_j^{(k)} = \left(\sum_{i=1}^{m_{k+1}} \left(\mathbf{d}_i^{(k+1)} w_{ji}^{(k+1)} \right) \right) f'(s_j^{(k)})$$

Definindo

$$\mathbf{e}_j^{(k)} = \sum_{i=1}^{m_{k+1}} \left(\mathbf{d}_i^{(k+1)} w_{ji}^{(k+1)} \right) \quad (3.2.24)$$

a equação do erro quadrático é definido como na expressão 3.2.19

$$\mathbf{d}_j^{(k)} = \mathbf{e}_j^{(k)} f'(s_j^{(k)})$$

O processo iterativo de mudança dos pesos é feito através da retropropagação do erro quadrático de acordo com

$$\overline{W}_j^{(k)}(t+1) = \overline{W}_j^{(k)}(t) + \mathbf{h} \left(-\overline{\nabla} \overline{W}_j^{(k)}(t) \right) \quad (3.2.25)$$

onde \mathbf{h} é a taxa de aprendizado da rede e o índice t significa a iteração atual. Agora, substituindo a Equação 3.2.15 em 3.2.25, obtém-se

$$\overline{W}_j^{(k)}(t+1) = \overline{W}_j^{(k)}(t) + 2\mathbf{h} \mathbf{d}_j^{(k)}(t) \overline{X}_j^{(k)}(t) \quad (3.2.26)$$

Portanto, a expressão acima recalcula os pesos entre as conexões, onde todo o conhecimento é armazenado. A rede depende deste algoritmo para extrair as características dos padrões de entrada para posterior classificação das falhas não apresentadas à rede.

3.3 – Treinamento

O processo de aprendizado apresentado no item anterior através do algoritmo de retropropagação é aqui representado de forma resumida (SARI et al, 1996).

1 – Inicie a rede com pesos aleatórios* entre $-0,1$ e $0,1$;

2 – Apresente um par de treinamento e calcule o erro quadrático e^2 . Se o erro for inferior ao valor de tolerância, pare o treinamento. Senão, continue no passo 3;

3 – Faça $k =$ última camada;

4 – Para todo neurônio j da camada k , faça:

- Calcule $e_j^{(k)}$ denotando

Se k for a última camada $e_j^{(k)} = d_j - y_j$

Se for uma camada oculta $e_j^{(k)} = \sum_{i=1}^{m_{k+1}} (d_i^{(k+1)} w_{ji}^{(k+1)})$

- Calcule o erro quadrático $d_j^{(k)}$

5 – Se $k > 0$, vá para o passo 4; senão continue no passo 6;

6 – Recalcula todos os pesos da conexão empregando

$\vec{W}_j^{(k)}(t+1) = \vec{W}_j^{(k)}(t) + 2hd_j^{(k)}(t)\vec{X}_j^{(k)}(t)$. Retorne ao passo 2 com outro par de treinamento.

O processo de treinamento pode ser acelerado através da técnica dos momentos, do qual consiste na inclusão de um termo a na Equação 3.2.26. Sendo assim, a expressão original fica

$$\Delta \vec{W}_j^{(k)}(t) = 2h(1-a)d_j^{(k)}(t)\vec{X}_j^{(k)}(t) + a\Delta \vec{W}_j^{(k)}(t+1)$$

sendo

$$\vec{W}_j^{(k)}(t+1) = \vec{W}_j^{(k)}(t) + \Delta \vec{W}_j^{(k)}(t)$$

sendo a uma constante de momento, que varia entre 0 e 1.

* Estes valores são práticos, no entanto estará se assegurando a não saturação e a convergência da rede ao aprendizado. Entende-se por saturação valores altos dos elementos da matriz de peso.

3.4 – Análise da Árvore de Falha - FTA

A árvore de falha tem a função de facilitar o relacionamento entre causas e efeito, também chamado de evento. Esta sistemática mostra qual é a melhor configuração que o sistema poderá assumir e como as falhas se inter-relacionam entre os diversos itens requeridos para desempenhar a função. Uma árvore de falha pode ser desdobrada em vários níveis hierárquicos, dependendo da complexidade do sistema a ser analisado. Esta técnica é freqüentemente usada tanto para avaliação qualitativa como quantitativa (SAKURADA, 2001, BILLINTON e ALLAN, 1993). Na avaliação qualitativa a ferramenta reflete uma compreensão de como o sistema pode falhar e quais serão as medidas cabíveis a serem abordadas. Já na avaliação quantitativa as falhas do sistema são gradualmente divididas em níveis hierárquicos, até alcançar um nível padrão, no qual os dados de confiabilidade são suficientes para uma avaliação quantitativa.

CONTINI (1995) afirma que o FTA é uma técnica dedutiva formalizada que permite a investigação das possíveis causas da ocorrência de estados pré-identificados indesejados do sistema. Esse estado, referido como evento de topo, está associado com o comportamento anormal do sistema, causado por uma falha do equipamento, ou erros humanos e/ou perturbações externas.

A Associação Brasileira de Normas Técnicas ABNT, na norma NBR 5462 (1994) define FTA (Fault Tree Analysis) como sendo “uma análise, apresentada na forma de árvore de panes, para determinar quais modos de pane de sub-itens, quais eventos externos ou quais combinações destes modos e eventos podem resultar em um dado modo de pane de um item”. A mesma norma define como árvore de pane um diagrama lógico mostrando quais modos de pane de sub-itens, quais eventos externos ou quais combinações desses modos e eventos resultam em um dado modo de pane do item. Uma ilustração dos diagramas ou blocos básicos pode ser visto no Apêndice 1.

A Figura 3.4.1 mostra um exemplo de um diagrama FTA. O evento inicial, chamado de evento de topo representa o efeito indesejado resultante de falha ou falhas nos itens colocados em níveis, hierarquicamente, inferiores. A análise é *Top-Down*, ou seja, vai do evento percebido no sistema até encontrar os itens portadores das causas originais. Os eventos básicos são assim chamados porque estão relacionados com o último nível da análise. As falhas neste nível são denominadas de causas básicas.

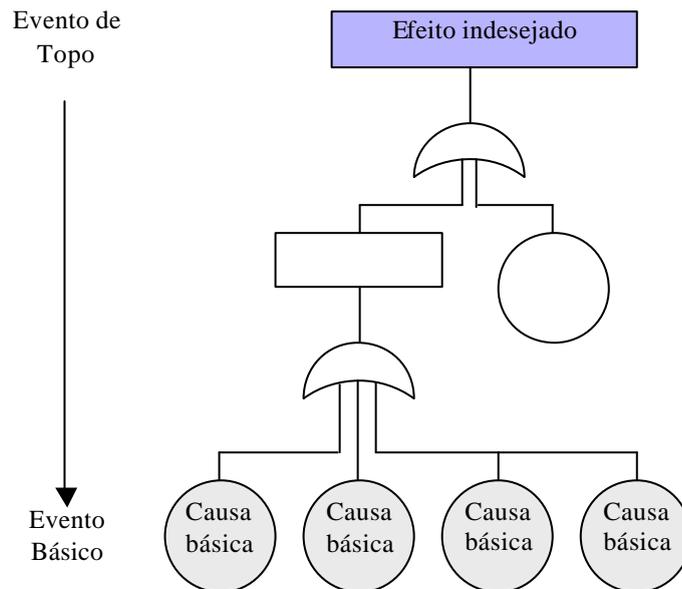


Figura 3.4.1 – Diagrama típico de uma árvore de falha (SAKURADA, 2001)

Ramakumar (1993) apresenta os seguintes procedimentos para a construção da árvore de falhas.

- 1) Para o sistema em análise, identificar o evento indesejado ou condição de falha denominada evento de topo;
- 2) Estudar e entender o sistema analisado, bem como a aplicação para o qual foi projetado;
- 3) Determinar os eventos funcionais de ordem mais elevada que podem causar uma falha indesejada, assim como, as relações lógicas de eventos de ordem inferior que podem resultar em eventos funcionais de ordem superior;
- 4) Construir a árvore de falhas utilizando o conjunto de blocos básicos de estruturas. Esta árvore deve ilustrar graficamente as diferentes combinações e seqüências dos eventos que conduzem ao evento de topo. Todas as entradas de falhas de eventos devem ser caracterizadas em termos de falhas básicas ou funcionais, independentes ou secundárias e identificáveis ou de comando;
- 5) Avaliar a árvore de falhas qualitativamente ou quantitativamente, dependendo dos dados disponíveis.

3.5 – Análise dos Modos de Falha e Efeitos – FMEA

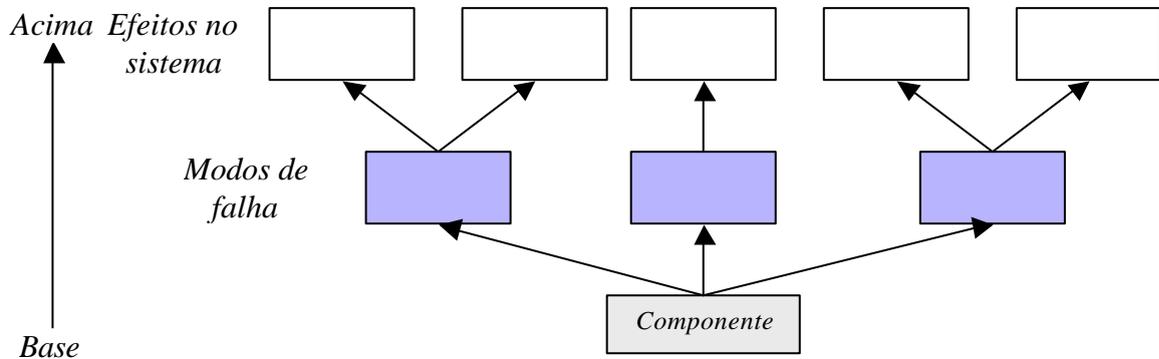


Figura 3.5.1 – Diagrama de blocos de FMEA (SAKURADA, 2001)

O FMEA, diferente do FTA, é uma ferramenta que analisa o modo de falha e o efeito da falha sobre o sistema. A técnica parte do particular para o geral. Cada componente tem um ou mais modos de falha, que pode gerar efeitos no sistema semelhantes ao de outros componentes. Se o efeito for bem caracterizado então pode-se utilizar técnicas de detecção do modo de falha, através do rastreamento do efeito.

A Associação Brasileira de Normas Técnicas ABNT, na norma NBR 5462 (1994), define FMEA (Failure Mode and Effect Analysis) como sendo “um método qualitativo de análise de confiabilidade que envolve o estudo dos modos de pane que podem existir em cada sub-item, e a determinação dos efeitos de cada modo de pane sobre os outros sub-itens e sobre a função requerida do item”.

A Análise dos Modos de Falha e Efeitos oferece em sua aplicabilidade três funções distintas:

- 1) O FMEA é uma ferramenta para prognóstico de problemas.
- 2) O FMEA é um procedimento para desenvolvimento e execução de projetos, processos ou serviços.
- 3) O FMEA é o diário do projeto, processo ou serviço.

Essa técnica, quando aplicada em equipe, é mais eficaz. As chances de melhor identificação e prevenção dos modos de falha potenciais são maiores do que quando feita individualmente. A questão mais comum é: Como se pode resolver um problema sem tê-lo

visto ou experimentado? O FMEA é altamente subjetivo e requer um trabalho considerável de suposição em relação às possibilidades e à sua prevenção. Essa suposição é feita pelos especialistas no assunto que acumularam experiência prática no projeto, processo ou serviço. Geralmente, a equipe pode usar como base de dados os históricos de desempenho de gerações anteriores do projeto, a fim de contribuir para identificação de alguns modos de falha potenciais e suas conseqüências podendo identificar também causas atribuídas a esses modos de falha (PALADY, 1997).

Etapas para a construção do FMEA:

- 1) Definir o sistema;
- 2) Identificar os componentes do sistema;
- 3) Identificar as funções dos componentes;
- 4) Identificar quais os modos de falha dos componentes;
- 5) Abordagem funcional;
- 6) Abordagem estrutural;
- 7) Identificar os efeitos no sistema em análise;
- 8) Selecionar os efeitos mais críticos;
- 9) Levantar a causa dos modos de falhas;
- 10) Apresentar possíveis soluções com base nos efeitos, modos e causas.

STAMATIS (1995) classifica o FMEA em quatro tipos, sendo eles:

FMEA de sistema – É usado para a análise de sistemas e subsistemas na fase inicial de concepção e projeto. FMEA de sistema enfoca os modos potenciais de falha entre as funções do sistema, causados por deficiências do sistema, e incluem a interação entre o sistema e os elementos do mesmo.

FMEA de projeto – É usado para analisar um produto antes de ser liberado para a manufatura. Um FMEA de projeto enfoca os modos de falha causados por deficiências do projeto.

FMEA de processo^{*} – É usado para analisar os processos de manufatura e montagem. Um FMEA de processo enfoca os modos de falha causados por deficiências do processo ou montagem.

* As falhas geradas nos compressores na fase de fabricação são provenientes da linha de montagem, então, a FMEA de processo é o tipo utilizado para a análise dos modos de falha a serem identificados pela rede neural.

FMEA de serviço – É usado para analisar serviços antes de alcançarem o cliente. Um FMEA de serviço enfoca os modos de falha (tarefa, erros, enganos) causados por deficiências do sistema ou processo.

O FMEA como ferramenta pode agilizar os mecanismos de registro auxiliando na melhoria da qualidade, evitando que falhas, antes identificadas, venham a ocorrer novamente.

3.5.1 – Modo de falha, efeito e causa

O termo *modo de falha* é usado para representar: “a forma do defeito”, “a maneira pela qual o defeito se apresenta”, “a maneira com que o item falha ou deixa de apresentar o resultado esperado”, “é um estado anormal de trabalho, a maneira que o componente em estudo deixa de executar a sua função ou desobedece as especificações” (SAKURADA, 2001).

O *efeito* é a forma ou maneira de como o modo de falha se manifesta, ou como é percebido em nível de sistema. São as conseqüências dos modos de falha. As causas do modo de falha estão associadas aos motivos que levaram a ocorrência deste modo de falha, que podem estar ligadas aos componentes da vizinhança, fatores ambientais, erros humanos, ou ao próprio componente (SAKURADA, 2001).

Existem duas abordagens para o levantamento dos modos de falha: estrutural e funcional. A abordagem funcional é genérica, não necessita de especificações de projeto ou de engenharia. Pode ser tratada como uma não-função. Desta forma, considere como exemplo um compressor hermético.

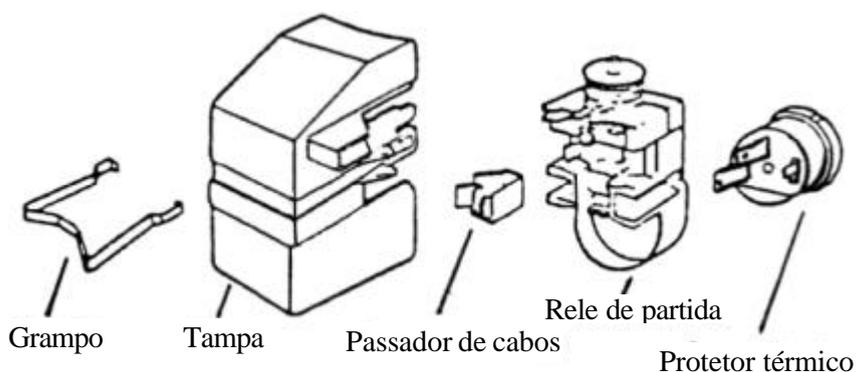


Figura 3.5.2 – Dispositivo de partida de um compressor hermético

Se a função de um protetor térmico do dispositivo de partida visto na Figura 3.5.2, é interromper o circuito elétrico do compressor hermético, então o modo de falha funcional seria: não interromper o circuito. A abordagem estrutural exige certas informações mais

específicas e detalhadas. No caso do protetor térmico os modos de falha seriam: excesso de corrente passando através da bobina do compressor e excesso de temperatura na carcaça do compressor. Ambas as abordagens exigem que a função do componente seja bem definida.

3.6 – Relação entre FMEA e FTA

A FTA é uma ferramenta gráfica que permite identificar o caminho da falha entre um nível mais baixo e um mais alto no sistema. Apesar da semelhança entre as duas técnicas, no que se refere à finalidade, existem várias diferenças entre elas quanto à aplicação e ao procedimento de análise. Modos de falha identificados na FMEA poderão ser usados como evento de topo na FTA (Figura 3.6.1).

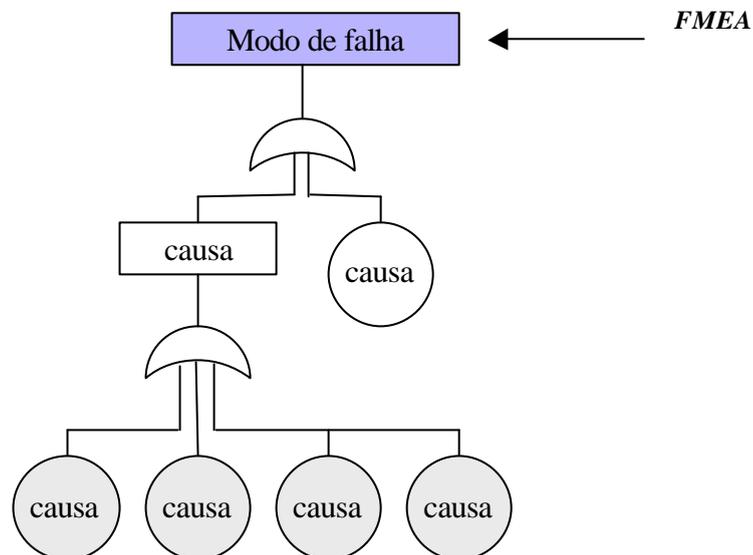


Figura 3.6.1 – Árvore de falha e FMEA

3.7 – Teste de Desempenho Estatístico (TDE) aplicado a detecção de falhas

A obtenção de dados com um certo nível de exatidão e a necessidade de quantificar as decisões tomadas pela rede nos conduz a um diagnóstico mais eficiente e seguro.

As informações através do teste da rede nos induzem a valores probabilísticos que descrevem as incertezas presentes nos valores obtidos, confirmando ou refutando a presença de uma falha em potencial.

A eficácia em identificar quão bom é um teste em determinar a presença ou ausência de uma falha no compressor é dada através dos resultados produzidos pelo sistema avaliado que não depende somente da sensibilidade e especificidade, mas também da presença de uma falha real no teste.

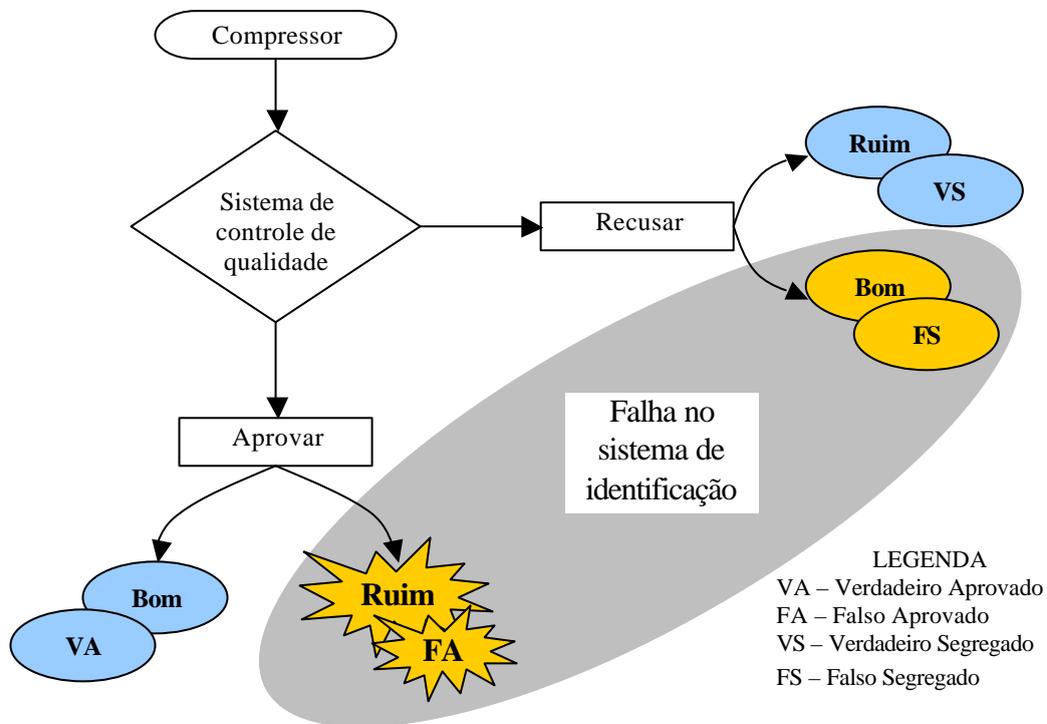


Figura 3.7.1 – Decisões do sistema de qualidade

3.7.1 – Sensibilidade e Especificidade

As características de um teste são duas: sensibilidade e especificidade. Na avaliação dos testes como mostrado na Figura 3.7.1, quatro situações são possíveis:

1. O resultado da RNA é aprovar e o compressor não está em falha – **Verdadeiro Aprovado (VA)**
2. O resultado da RNA é aprovar e o compressor está em falha – **Falso Aprovado (FA)***
3. O resultado da RNA é segregado e o compressor está em falha – **Verdadeiro Segregado (VS)**

* É a situação mais crítica apresentada pelo sistema de qualidade. Compressores ruins passarão como se estivessem em funcionamento normal. O custo para este caso é centenas de vezes o custo unitário do compressor.

4. O resultado da RNA é segregado e o compressor não está em falha – **Falso Segregado (FS)***

Os melhores resultados são aqueles que apresentam um mínimo de falsos- aprovados e falsos-segregados. Espectros considerados de compressores bons ou ruins devem ser vistos como *padrões de referência (PRef)* que são a expressão da condição de existência ou ausência de uma falha. O desempenho do teste de detecção é avaliado pela estimativa da sensibilidade e especificidade.

A *sensibilidade* é definida pela capacidade de um teste detectar compressores com defeito. A Equação 3.7.1 dá um indicativo de quão bom é o teste em indicar um compressor ruim.

$$Sens = \frac{VS}{VS + FA} \quad (3.7.1)$$

A *especificidade* é definida pela capacidade de um teste detectar compressores sem defeito. A Equação 3.7.2 dá um indicativo de quão bom é o teste em indicar um compressor bom.

$$Espec = \frac{VA}{VA + FS} \quad (3.7.2)$$

O fato mais relevante é estimar se o resultado é verdadeiro.

O *Valor Preditivo Segregado (VLPS)* é a probabilidade de um compressor com um resultado segregado ter a falha, definida na Equação 3.7.3.

$$VLPS = \frac{VS}{VS + FS} \quad (3.7.3)$$

O *Valor Preditivo Aprovado (VLPA)* é a probabilidade de um compressor com resultado aprovado não ter a falha, definida na equação 3.7.4.

$$VLPA = \frac{VA}{VA + FA} \quad (3.7.4)$$

A validade criteriosa de uma falha é estimada estatisticamente, e é expressa através de sua sensibilidade (proporção de casos segregados identificados corretamente), especificidade (proporção de casos aprovados identificados corretamente), o valor preditivo aprovado (VLPA), que indica a probabilidade com que casos detectados aprovados sejam realmente aprovados, o valor preditivo segregado (VLPS), que se refere à probabilidade de

* Caracteriza uma falha do sistema de qualidade. Compressores bons são segregados como se estivessem com defeito. Fazem-se novos testes. Eles são recolocados na linha ou rejeitados.

que casos detectados como segregados sejam realmente segregados (MENEZES, 1998). Acompanhar um grupo de compressores na linha de produção atentando para as características fornecidas é o alicerce para esta análise.

3.8 – Comentário

Neste capítulo foram contempladas as ferramentas básicas para análise dos principais modos de falha e efeitos por eles produzidos no compressor. Com essas informações e com o relacionamento entre causa e efeito proporcionado pela árvore de falha, pode-se estabelecer algumas rotinas de falhas que ocorrem na linha de montagem. É este aprendizado que será captado para instruir a rede neural no processo de segregação dos compressores com falha. Baseado nestes fundamentos será proposto no capítulo 4 o modelo para a detecção de compressores portadores de falhas ou defeitos.

CAPÍTULO 4 – MODELO PROPOSTO

4.1 – Introdução

Este capítulo apresenta o modelo que será utilizado para a análise e detecção das falhas em compressores. Apresenta-se também uma descrição geral do modelo, a topologia da rede utilizada e a metodologia para a coleta de informações.

4.2 – Escolha da Rede Neural

Apesar da grande quantidade de material sobre RNAs, a bibliografia relata a dificuldade da escolha de uma rede neural ideal para um determinado problema, que depende da tentativa e erro e da experiência do projetista. A escolha de uma arquitetura neural ideal está muito dispersa entre as atuais aplicações existentes. A relação entre o número de parâmetros livres e o poder computacional das RNAs é fundamental na definição da topologia de rede para a solução de um determinado problema de mapeamento. Para este estudo adotou-se uma rede *feedforward* multicamadas. Um resumo dos tipos de redes bem como suas vantagens e desvantagens se encontram no Apêndice 2. Entre os tipos de redes, a *feedforward* foi a escolhida, porque sua teoria esta bem definida e suas aplicações comprovam seu sucesso.

Redes neurais contendo um número muito reduzido de parâmetros não possui a flexibilidade necessária para a determinação da solução desejada. Por outro lado, uma rede super-dimensionada com grande número de parâmetros pode ser excessivamente flexível, levando a resultados indesejáveis fora do conjunto de treinamento. O equilíbrio entre o desenvolvimento de um modelo que não resulte em generalização pobre devido ao super-dimensionamento e que, por outro lado, seja flexível o suficiente para resolver da melhor maneira possível o problema de mapeamento, é conhecido como o dilema entre polarização e a variância.

4.2.1 – Configurações de redes

Em primeira análise buscou-se na literatura de RNAs algumas regras para a determinação do número de neurônios na camada intermediária. Estas regras são baseadas em testes realizados na prática e foram relatadas na Seção 3.2.6. Antes da utilização destas regras, foi analisado o número ideal de redes visando a identificação de falhas na montagem de compressores.

Antes do projeto de uma rede verificou-se que a rede neural fornece informações aprendidas de um conjunto de treinamento e fornece respostas relacionadas às características extraídas através do processo de aprendizado. A rede recebe um padrão de entrada e calcula uma saída. Neste ponto o problema seria a identificação automática de uma falha. Isto seria possível com a adição de mais uma rede contendo informações sobre os modos de falha.

Como um grande número de falhas poderiam ser geradas durante a montagem de um compressor hermético, procurou-se classificar e identificar essas falhas por número de ocorrências. Esta classificação foi utilizada para estruturar e treinar a rede neural. Antes, porém, fez-se um extensivo estudo para identificar entre os vários modelos e proposições de rede, a que mais se adequaria ao problema proposto. A Tabela 4.2.1 mostra um estudo da influência do número de redes e dos parâmetros da rede para o problema proposto. Cada rede foi treinada aproximadamente seis vezes.

Tabela 4.2.1 – Análise de tipos de arquiteturas de redes neurais

<i>RNA</i>	<i>Número de redes</i>	<i>Número de camadas</i>	<i>Taxa de acerto máxima</i>	<i>Características da rede</i>
RNA 1	Uma de classificação	RNA de classificação com 3 camadas (10\12\1)	74 %	Estudar a influência de apenas uma rede neural e do número de saídas. Esta foi projetada sem a camada de identificação e com apenas uma saída.
RNA 2	Uma de classificação e uma de identificação	4 camadas na RNA de classificação (10\12\10\8) e 3 camadas de identificação (8\6\1)	90 %	Estudar a influência de uma segunda camada intermediária. Esta foi projetada alterando-se os parâmetros: ganho = 0.2; momento = 0.4; mudança dos pesos para o quikprop = 1.50.
RNA 3	Uma de classificação e uma de identificação	3 camadas na RNA de classificação (10\12\8) e 3 camadas de identificação (8\6\1)	92 %	Estudar a influência de uma camada intermediária. Esta foi projetada com os parâmetros: momento = 0.3; Taxa de aprendizado = 0.1.
RNA 4	Uma de classificação e uma de identificação	4 camadas na RNA de classificação (10\12\10\8) e 3 camadas de identificação (8\6\1)	92 %	Estudar a influência de uma segunda camada intermediária. Esta foi projetada com os parâmetros: momento = 0.3; Taxa de aprendizado = 0.1; mudança dos pesos para o quikprop = 1.75.
RNA 5	Uma de classificação e uma de identificação	3 camadas na RNA de classificação (10\12\8) e 3 camadas de identificação (8\6\1)	98 %	Estudar a influência de uma camada intermediária. Esta foi projetada com os parâmetros: ganho = 0.2; momento = 0.4; mudança dos pesos para o quikprop = 1.50.
RNA 6	Uma de classificação e uma de identificação	3 camadas na RNA de classificação (10\9\8) e 3 camadas de identificação (8\6\1)	98 %	Estudar a influência do número de neurônios na camada intermediária. Esta foi projetada alterando o número de neurônios da rede de classificação baseado em uma média aritmética entre a entrada e a saída.
RNA 7	Uma de classificação e uma de identificação	3 camadas na RNA de classificação (10\9\8) e 3 camadas de identificação (8\5\1)	100 %	Estudar a influência do número de neurônios na camada intermediária. Esta foi projetada alterando o número de neurônios da rede de classificação e de identificação baseado em uma média aritmética entre a entrada e a saída de ambas as redes.

Na tabela 4.2.1, os mesmos arquivos de treinamento e teste foram utilizados para a escolha do número de neurônios na camada intermediária e do número de redes neurais. A regra de maior potencialidade demonstrada foi a regra da média aritmética entre o número de neurônios da camada de entrada e de saída, apresentada na RNA 7. Outra técnica seria aumentar gradativamente o número de neurônios na camada intermediária até que o conjunto de treinamento possa convergir a uma porcentagem de acerto de 100%, ou a qualquer outro critério de parada. Para os testes descritos na Tabela 4.2.1 foram utilizados 70 exemplos de padrões de treinamento. Estas duas técnicas serão adotadas daqui para frente.

4.3 – Arquitetura e Topologia da rede neural

A topologia para o trabalho em questão é uma rede *Perceptron* multicamadas ou MLP (*Multilayer Perceptron*), também denominada de *feedforward*. O treinamento adotado é do tipo supervisionado* com o algoritmo de treinamento *Quickpropagation***.

A topologia geral em nível macro-estrutural mostrada na Figura 4.3.1 trata-se de uma rede fortemente acoplada, composta por uma bloco funcional, uma camada de classificação, uma camada de identificação e uma camada de base de regras. Esta foi a topologia utilizada no teste inicial da Tabela 4.2.1.

O bloco funcional tem por objetivo preparar os dados coletados do sistema, ou seja, de simplificá-los através da Transformada de Fourier. A camada de classificação contém todas as características das falhas envolvidas a serem discriminadas. Uma vez classificada a falha, uma camada de identificação descreve os modos de falha onde são apresentados por uma base de regras. Um detalhamento do projeto das camadas pode ser visto nas seções seguintes deste capítulo.

* O treinamento supervisionado foi adotado porque os padrões a serem reconhecidos pela rede eram conhecidos. A uma dada entrada adote-se uma saída desejada.

** O algoritmo quickpropagation é um método de segunda ordem, que utiliza uma heurística baseada no método de Newton. Este otimiza o treinamento.

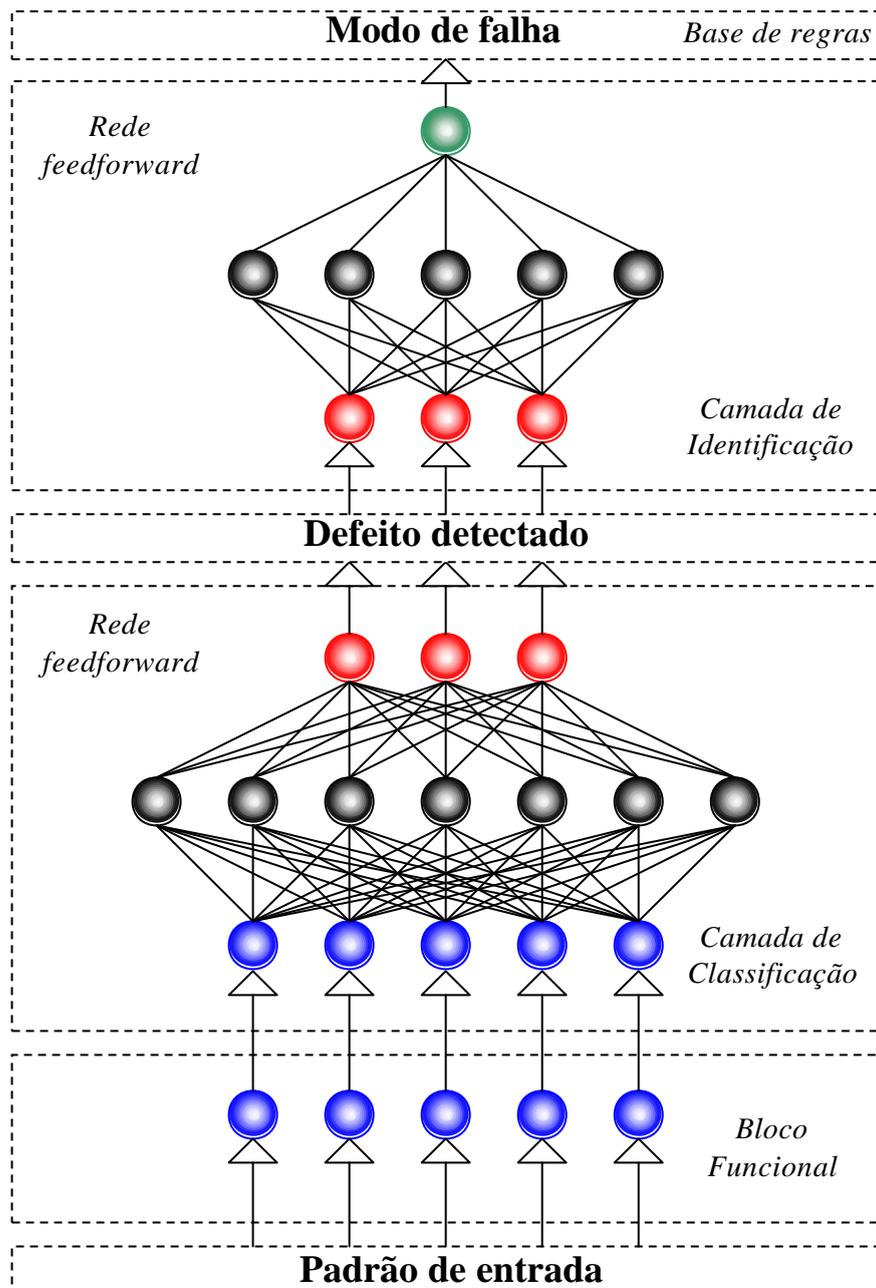


Figura 4.3.1 – Topologia da rede proposta

4.4 – Bloco funcional

4.4.1 – Modelo proposto para o padrão de entrada da RNA

O modelo proposto neste trabalho tem como objetivo expressar as informações das falhas identificadas através das ferramentas FMEA e FTA. Esta nova associação tem se mostrado válida no sentido metodológico e científico, pois visa agregar informações

contextualizáveis em classes. Estas classes contém informações peculiares sobre os tipos possíveis de falhas detectáveis por níveis de ruído e vibrações. Não obstante estas classes são sem dúvida a base de sustentação dos padrões de entrada como visto na Figura 4.4.1.

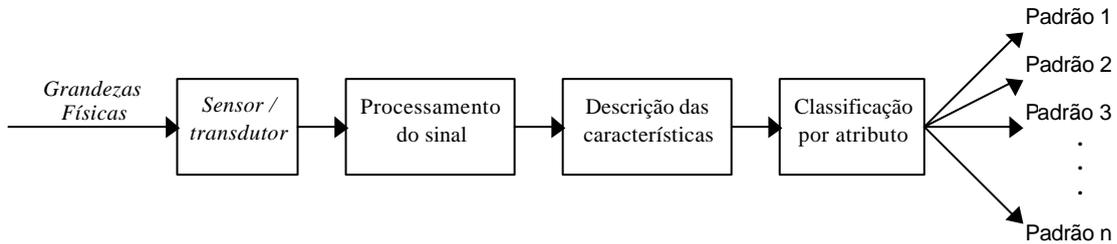


Figura 4.4.1 – Estruturação do padrão de entrada da RNA

Como exposto na Seção 3.2.7, o padrão de entrada é um vetor gerado a partir das características informacionais do defeito. Este vetor por sua vez contém as categorias de falhas, e formam um conjunto de treinamento, que é então apresentado à RNA. Note que um aumento destas classes não acarretaria em um grande aumento nos custos envolvidos do projeto da RNA, o que caracteriza uma grande vantagem desta ferramenta.

Sendo assim, um conjunto contendo um número considerável de exemplos por classe é desejável para aumentar a capacidade do modelo proposto. Entende-se por capacidade a capacidade de generalização da rede neural. O número de exemplos de treinamento deverá ser suficiente para que a RNA aprenda e não memorize os padrões a fim de reconhecer uma nova classe de exemplos. No entanto, ainda não existe um referencial quanto ao número ideal de exemplos a ser apresentado à rede na fase de aprendizado.

4.4.2 – Dinâmica do reconhecimento de padrões

O sinal medido em função do tempo, como o mostrado na Figura 4.4.2, passa por um bloco funcional onde é transformado para o domínio da frequência através da Transformada Rápida de Fourier e dividido por faixa de frequência, como visto na Figura 4.4.3. Este procedimento reduz um conjunto de dados complexos em subconjuntos de padrões mais simples gerados a partir de dados primitivos do sistema.

Um padrão de entrada pode ser representado na forma estática ou temporal. Para o padrão estático todas as variáveis são constantes no tempo. Já um padrão temporal é formado por uma seqüência ordenada no tempo. Na forma estática, o padrão de entrada é representado como um vetor contendo valores fixos; na forma temporal, os valores são gradativamente apresentados até que todo o vetor de entrada se complete.

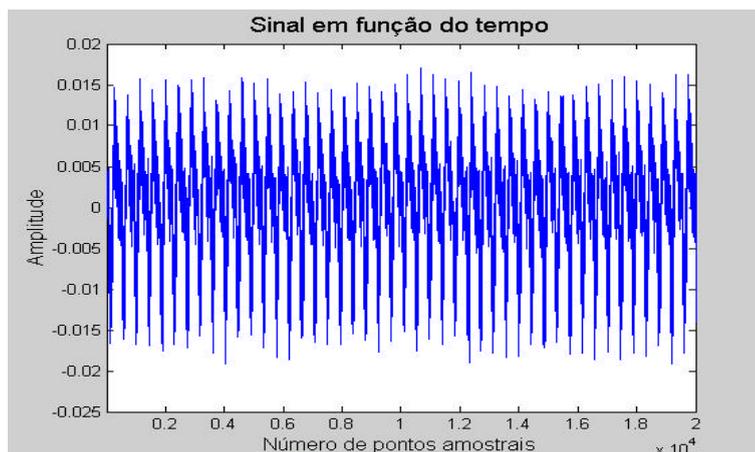


Figura 4.4.2 – Exemplo de sinal em função do tempo

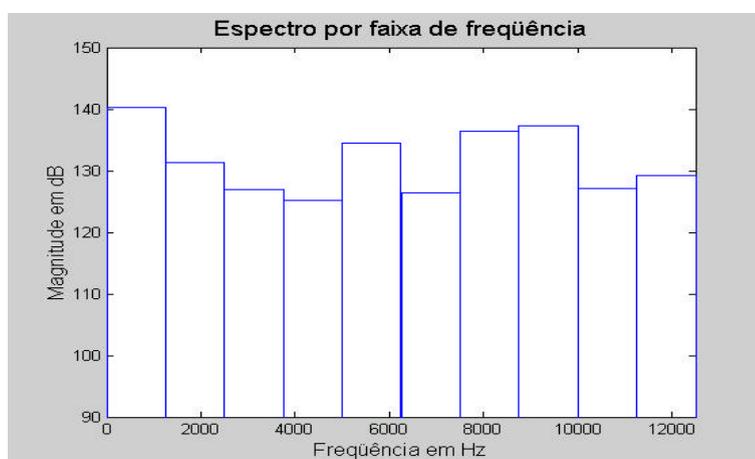


Figura 4.4.3 – Exemplo do sinal por faixa de frequência

Entre estes dois tipos de padrão adotou-se, para este estudo, um padrão estático. Isto porque o tempo para a análise é muito reduzido e os valores calculados pela Transformada de Fourier são instantaneamente processados dentro de um espaço temporal limitado pelo bloco funcional. Por conveniência, adotou-se um padrão de entrada com dez valores, correspondentes a dez faixas de frequência. Isto deverá facilitar a implementação na prática do modelo proposto neste estudo.

4.5 – Camada de classificação

A definição do modelo proposto na sua fase inicial se traduz em uma concepção realista do problema, buscando uma solução arquitetônica que possa traduzir o fenômeno físico.

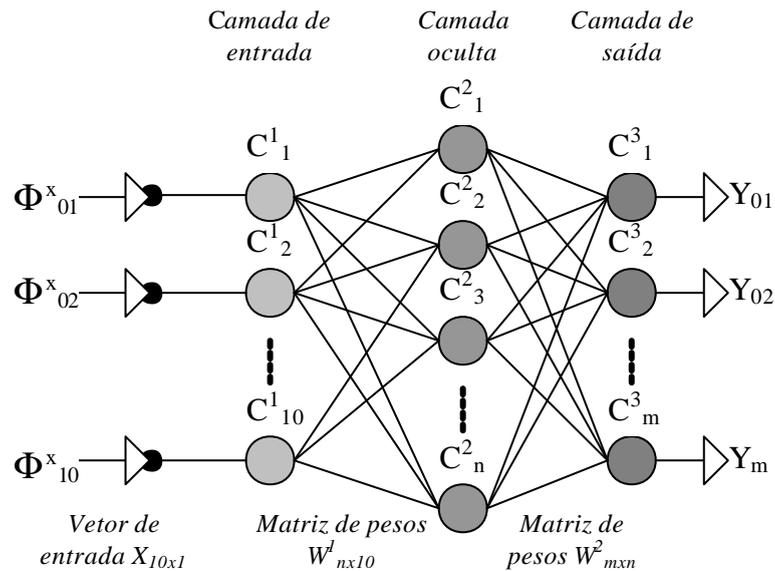


Figura 4.5.1 – Rede neural de classificação de múltiplas camadas feedforward

Uma proposta à seleção do paradigma neural teve início no tamanho do vetor de entrada que, de uma forma geral, representa o número de neurônios da primeira camada da rede. Num segundo momento teve início no estudo da arquitetura a ser utilizada tomando como base a experiência em trabalhos passados. Levando em consideração que a rede deve ser capaz de generalizar os resultados da saída e não de memorizá-los, o número n de neurônios na camada oculta segue as regras adotadas na Seção 4.2.1. O modelo proposto para o trabalho se baseia no *perceptron* criado por Frank Rosenblatt, em 1957 (Z.L.Kovács, 1996), no qual o modelo possui múltiplos neurônios dispostos em múltiplas camadas com conexões *feedforward*, como ilustrado na Figura 4.5.1.

4.5.1 – Padrão de entrada e saída da RNA de classificação

O padrão de entrada $\Phi^x_{10 \times 1}$ é uma matriz 10×1 , onde cada elemento da matriz representa o nível global, em dB, por banda de frequência, até 12500 Hz. Esta representação do padrão foi adotada porque se verificou que classes de falhas são facilmente detectadas por se manifestarem somente em determinadas frequências. Esta análise das frequências de ressonâncias levou a um padrão de entrada mais personalizado onde os valores são calculados variando as faixas na frequência. Sendo assim, o critério de decisão utilizado pela rede para a classificação das falhas é tão somente a manifestação destes níveis, em dB.

O sucesso na classificação correta de uma falha depende do projeto do padrão de entrada apresentado à rede. O padrão de entrada pode conter informações adicionais do tipo corrente elétrica, número de identificação do modelo do compressor, resultados de outras ferramentas como JTFA (*Join Time Frequency Analysis*), *wavelet*, *kurtose*, entre outras. Os padrões de entrada podem assumir diversas formas dependendo da aplicação. Neste trabalho, apenas foi citado o possível uso de ferramentas mais elaboradas para a construção do padrão de entrada. Por outro lado, um estudo mais detalhado sobre a aplicabilidade destas ferramentas e a verificação do tempo de processamento computacional tornam-se necessários, ficando como sugestão para trabalhos futuros.

Já o padrão de saída adotado baseia-se nas falhas do processo de montagem que se deseja identificar durante a medição. A representação na camada de saída depende do número de modos de falha identificados na FMEA. Neste caso optou-se por representar e treinar uma rede neural com os principais modos de falhas.

4.5.2 – Dinâmica da rede neural de classificação

A RNA foi submetida aos estágios de treinamento e teste. No estágio de treinamento, os padrões normalizados por faixa de frequência foram apresentados à rede como vetores de entrada. Estas informações são processadas pelas camadas da rede obtendo um vetor de saída o qual é comparado com o desejado. Estes vetores de entrada e saída constituem os pares de treinamento da RNA. Este processo gera o erro médio quadrático – EMS. Quando a margem de erro for maior que o valor especificado, diz-se que a rede não aprendeu este conjunto de vetores ou um vetor em específico. Este erro é, então, retropropagado de modo que os elementos da matriz de peso sejam atualizados.

Para a atualização dos pesos durante o treinamento utilizou-se o algoritmo *quickprop*. Este algoritmo, que foi desenvolvido por Scott Fahlman, é um método de segunda ordem, que utiliza uma heurística baseada no método de Newton. A principal diferença para o *backpropagation* padrão é que, para cada peso, independentemente, são utilizadas as inclinações anterior e atual do erro. O *quickprop* assume que a superfície do erro é localmente quadrática (formando uma parábola) e procura saltar da posição atual na superfície para o ponto de mínimo da parábola (DUARTE, 2000). O ajuste dos pesos é definido pela Equação 4.5.1

$$\Delta w(t) = \frac{S(t)}{S(t) - S(t-1)} \Delta w(t-1) - \mathbf{h}S(t) \quad (4.5.1)$$

Onde h é a taxa de aprendizado, $S(t)$ e $S(t-1)$ são os valores atuais e passados de $\frac{\partial e}{\partial w}(t)$, respectivamente. Um fator *momentum* α foi introduzido para fornecer certa inércia aos treinamentos e diminuir a sensibilidade das redes a pequenos detalhes na superfície do erro impedindo que o treinamento permaneça estacionado em um mínimo local, como ilustra a Figura 4.5.2.

Os mínimos locais são pontos na superfície de erro que apresentam uma solução estável, embora não sejam a saída correta. A inclusão do termo *momentum* na equação de ajuste dos pesos aumenta a velocidade de aprendizado, reduzindo o perigo de instabilidade. O *momentum* acelera o treinamento em regiões planas da superfície de erro e suprime oscilações dos pesos em vales (DUARTE, 2000). A Figura 4.5.2 mostra o efeito da utilização do *momentum* no caminho seguido pela rede durante o aprendizado.

Cada neurônio processa uma média ponderada dos pesos como visto na Seção 3.2.2 (Equação 3.2.1).

$$s_j^{(k)} = \sum_i x_i^{(k-1)} w_{ij}^{(k)}$$

Onde $x_i^{(k-1)}$ é a i -ésima entrada do j -ésimo neurônio da camada $k-1$

Para a RNA proposta a ativação do neurônio é dada por uma função de transferência logística definida na Equação 4.5.2.

$$f(s_j) = \frac{1}{1 + e^{-I s_j}} \quad (4.5.2)$$

onde I é um parâmetro de suavidade da curva.

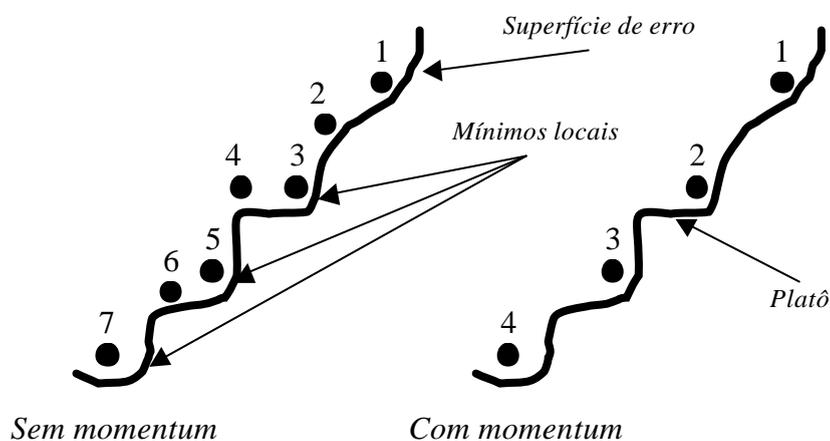


Figura 4.5.2 – Influência do momentum no aprendizado

Quando o erro retropropagado for menor ou igual à tolerância estipulada, considera-se que a rede neural aprendeu, e a matriz de pesos é, então, armazenada para a seção de testes. No estágio de teste é apresentado à RNA um novo conjunto de pares de vetores. A resposta calculada, comparada com a desejada, define a taxa de acerto.

4.5.3 – Treinamento da RNA de classificação

O treinamento da rede segue o procedimento descrito na Seção 3.3. Para o treinamento da rede foi utilizado um algoritmo do tipo *backpropagation* (Seção 3.2.9). Esse algoritmo foi implementado em linguagem MATLAB®. A escolha deste programa deu-se devido aos recursos disponíveis nesse ambiente de programação e à eficiência nas operações com matrizes. Os conjuntos de aprendizado foram dispostos por tipo de falha. Antes, porém, foram fabricados compressores com modos de falhas conhecidos. Isto gerou um banco de dados de falhas do qual a rede neural foi treinada. Cada modo de falha é representado por um vetor de saída desejado.

O treinamento, neste caso correspondeu às características de 100000 ciclos, um momento de 0,3 e uma taxa de aprendizado de 0,1. Na Tabela 4.5.3 estão listadas as saídas desejadas.

Tabela 4.5.3 – Exemplo das saídas desejadas para RNA de classificação

Descrição da falha	Saída desejada RNA Classificação
Compressor bom	[1 1 1 1 1 1 1 1 ... 1]
Modo de falha 1	[1 0 0 0 0 0 0 0 ... 0]
Modo de falha 2	[0 1 0 0 0 0 0 0 ... 0]
Modo de falha 3	[0 0 1 0 0 0 0 0 ... 0]
Modo de falha n	[0 0 0 0 0 0 0 0 ... 1]

4.6 – Camada de identificação

Esta rede possui as mesmas características da camada de classificação, exceto pelo número de neurônios na sua arquitetura. Diferentemente da camada de classificação, os padrões de entradas são obtidos pelas saídas produzidas pela RNA de classificação. Portanto, um vetor de entrada $\Phi_{n \times 1}^x$ deverá produzir uma única saída Y. Quanto à dinâmica de

treinamento, parâmetros de treinamento e ao tipo de algoritmo usado seguem o mesmo procedimento.

O modelo proposto para esta camada também se baseia no *perceptron* criado por Frank Rosenblatt em 1957 (Z.L.Kovács, 1996). O modelo possui múltiplos neurônios dispostos em múltiplas camadas com conexões *feedforward*, como ilustra a Figura 4.6.1.

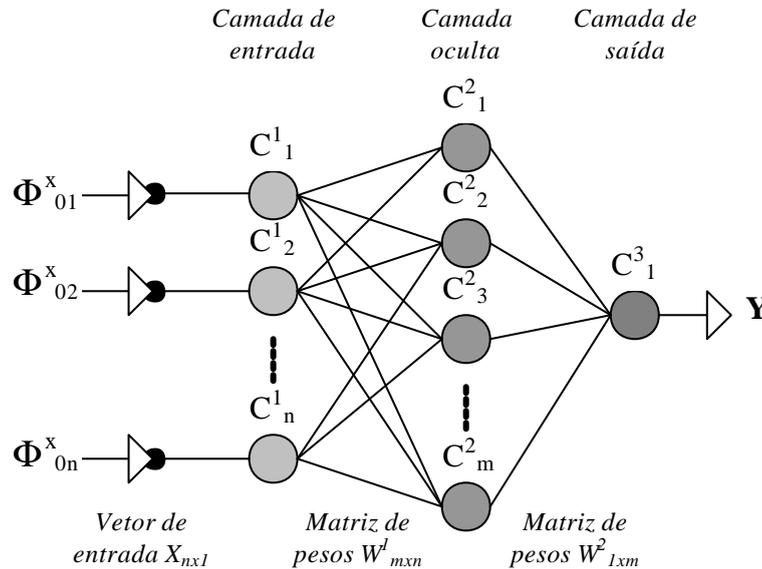


Figura 4.6.1 – Rede neural de identificação de múltiplas camadas feedforward

4.6.1 – Treinamento da RNA de identificação

O treinamento da rede segue o procedimento descrito na Seção 3.3. Para o treinamento da rede foi utilizado um algoritmo do tipo *backpropagation* (Seção 3.2.9). Os conjuntos de aprendizado são as saídas desejadas* pela rede neural de classificação. Cada modo de falha dado pelo vetor de saída da rede de classificação é representado por uma única saída desejada.

O treinamento, neste caso correspondeu às características de 100000 ciclos, um momento de 0,3 e com taxa de aprendizado de 0,1. Na Tabela 4.6.1 estão listadas as saídas desejadas.

* Os padrões a serem reconhecidos pela rede de identificação são normalizados para valores zero e um. Isto porque a função de transferência é sigmoideal, dando apenas valores próximos de zero e um.

Tabela 4.6.1 – Exemplo das saídas desejadas para RNA de identificação

Saída RNA Classificação	Saída desejada RNA Identificação
[1 1 1 1 1 1 1 1 ... 1]	0
[1 0 0 0 0 0 0 0 ... 0]	1
[0 1 0 0 0 0 0 0 ... 0]	2
[0 0 1 0 0 0 0 0 ... 0]	3
[0 0 0 0 0 0 0 0 ... 1]	n

4.7 – Base de regras

O padrão de entrada processado nas camadas funcional, de classificação e de identificação, é finalmente processado pela camada aqui denominada Base de regras. Esta camada contém os resultados desejados na saída da rede de identificação. A função desta fase é associar a resposta fornecida pela RNA com um pequeno banco de dados comparativos.

O resultado inquirido pela base de regras é auto-associativo, em termos lógicos preestabelecidos pelas informações dos modos de falha e das respectivas falhas de montagem (causas). Esta ação é baseada na experiência do especialista e na seqüência de montagem do compressor na linha de produção. Sendo assim, uma ação corretiva no posto de montagem pode ser aplicada quase em tempo real, corrigindo falhas de processo de montagem de compressores. A estrutura da base de regras estabelece uma decisão segundo o procedimento computacional abaixo:

se SAIDA<=0

escreva('compressor em funcionamento normal')

então se SAIDA<=1

escreva('compressor com modo de falha 1')

escreva('falha na montagem do setor F')

então se SAIDA ...

então

escreva('compressor com falha desconhecida')

escreva('investigar a origem da falha')

fim

A riqueza de detalhes vai depender das necessidades impostas pela linha de produção, ficando a cargo do gerente de produção especificar as falhas em um histórico de ocorrências de falhas da linha.

4.8 – Fluxograma funcional da detecção e análise de falhas

O estudo da aplicação teve início com a verificação da adaptabilidade do modelo ao problema proposto. Um fluxograma operacional foi desenvolvido com o objetivo de organizar esse estudo e incorporar as técnicas de FMEA e FTA sobre os compressores, no contexto da análise fundamentada em redes neurais. (Figura 4.8.1). No início do fluxograma tem-se o compressor, aqui denominado como sistema para a análise da FMEA.

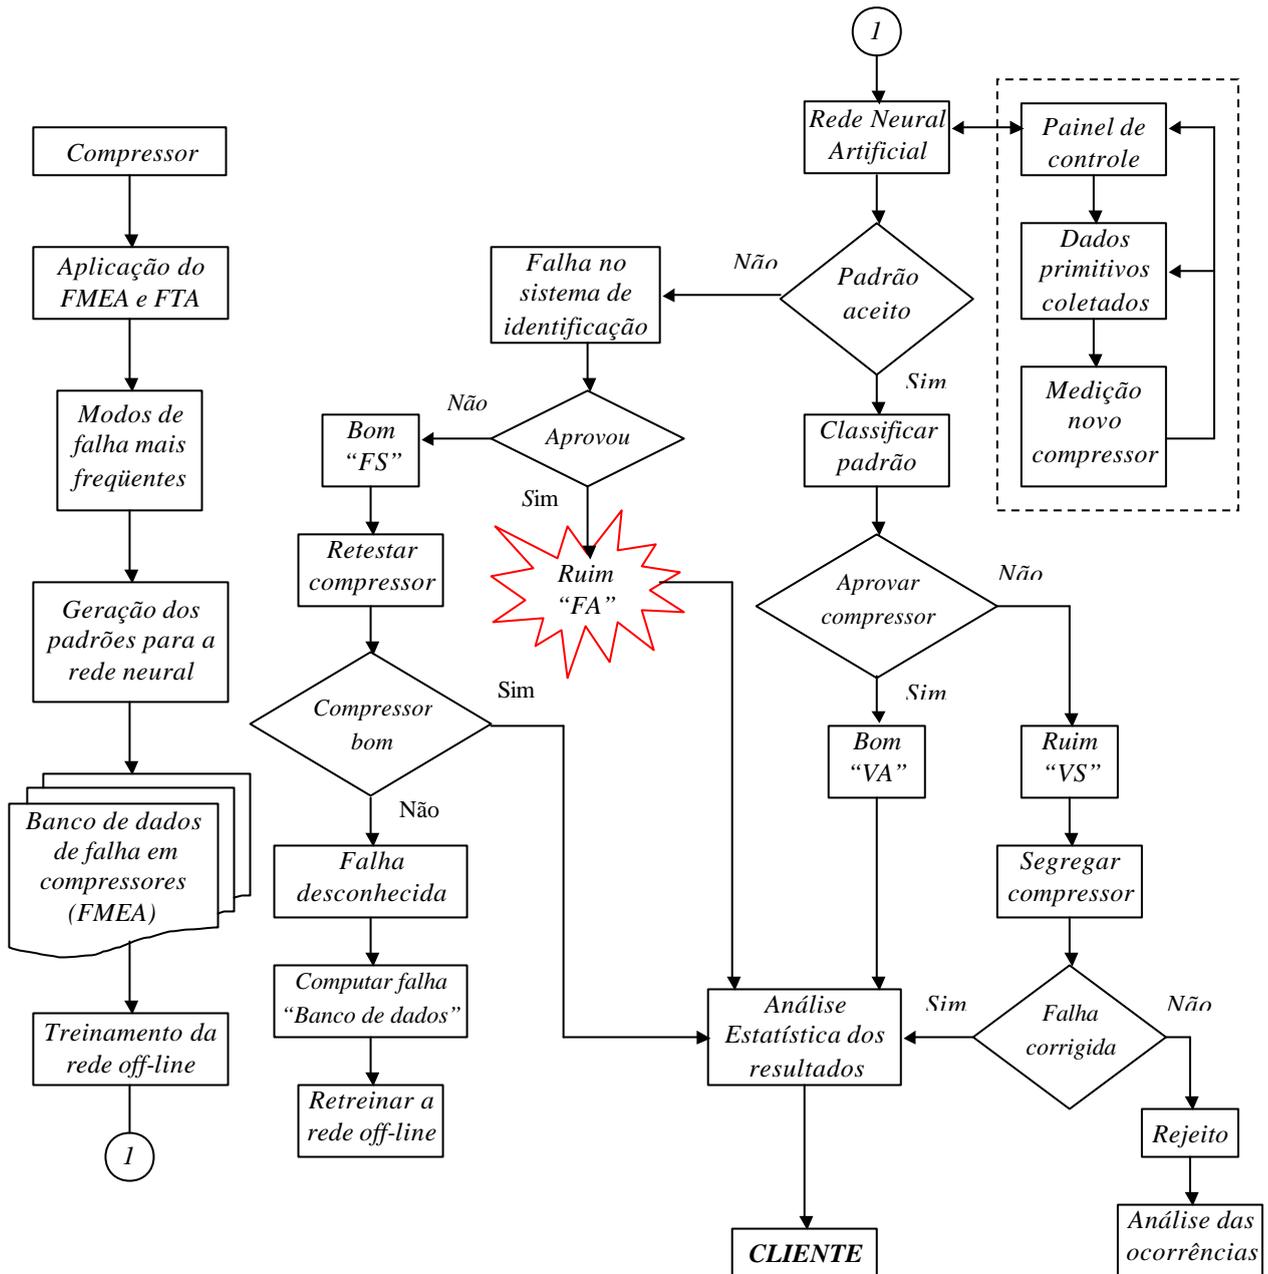


Figura 4.8.1 - Procedimento de detecção de falhas em compressores herméticos

O estudo segue com o enfoque voltado à análise de falhas. Antes da aplicação da rede neural ao modelo, um conjunto de exemplos de modos de falha foi escolhido para treinar uma RNA, de forma a representar todos os padrões de falha existentes que se queira classificar posteriormente. Após a rede neural ter sido treinada *off-line*, o painel passa a obter novos dados primitivos do sistema. Estes padrões são processados pelo modelo, cujo resultado define a qualidade do sistema medido (compressor). A qualidade é definida pelas condições de funcionamento do compressor.

Se o novo padrão de entrada for aceito como sendo de uma das classes envolvidas durante o treinamento da rede, o compressor poderá ser aceito como “bom” ou seja, aprovado, ou como “ruim” onde é segregado por estar em falha. A falha, se possível, é corrigida; caso contrário, o compressor será rejeitado. Mas, se o padrão de entrada não for aceito, um compressor poderá ser aprovado contendo uma falha. Por outro lado, a rede poderá rejeitar um compressor bom. Este é novamente testado; se for um novo padrão, ter-se-á que retreinar a rede neural com esta nova classe de falha. Caso contrário, será realmente aprovado como bom. O restante do fluxograma descreve um procedimento até o produto alcançar o mercado consumidor.

4.9 – Procedimento construtivo do módulo de qualidade via programação

O modelo desenvolvido, chamado de Sistema Neuro Acústico e Vibracional de Controle de Qualidade – SISNAV, visa facilitar a análise dos modos de falha via programação em MATLAB[®]. A Figura 4.9.1 mostra um procedimento seqüencial de análise.

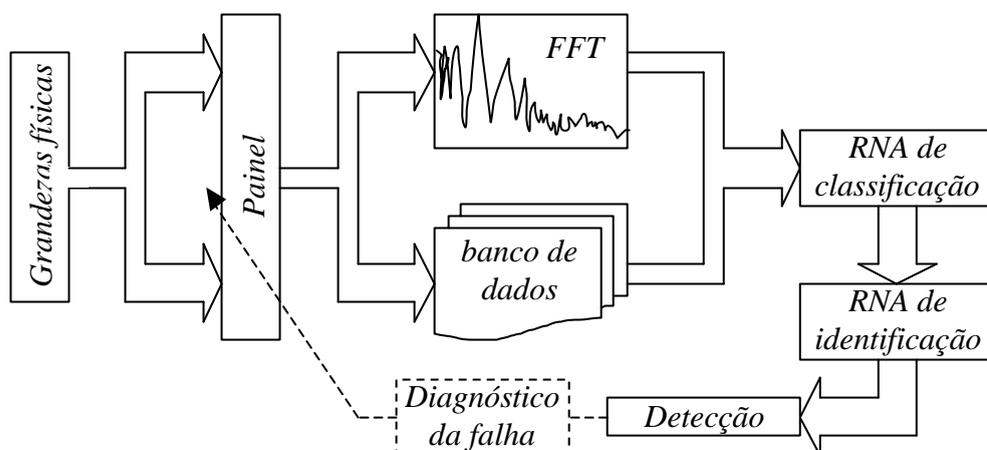


Figura 4.9.1 – Procedimento seqüencial de análise da interface SISNAV

O módulo deverá analisar dados de pressão sonora da cavidade e de vibrações na carcaça. Estes arquivos são processados em um bloco funcional, onde são formados os padrões de entrada que serão apresentados às redes neurais de classificação e de identificação e pela base de regras. Um tratamento inicial adequado dos dados é um dos fatores mais relevantes à eficiência final no processo de classificação. Os padrões de entrada formam uma base de conhecimento que deve ser continuamente alimentada dado que, quanto mais elaborados forem estes padrões, mais informações a rede extrairá.

Como visto na Figura 4.9.1, os sinais são coletados no atual painel de medição na linha de produção de compressores. A FFT do sinal é armazenada em um banco de dados onde estes padrões são usados para o treinamento *off-line* da rede neural. Após todas as redes estarem treinadas, novos compressores são medidos e analisados. Quando uma falha é detectada o SISNAV retornará um relatório ao painel, descrevendo a qualidade do compressor.

4.10 – FMEA e FTA em compressores herméticos

O principal interesse para esta aplicação é a análise em nível de sistema (compressor), na última operação da linha de montagem que representa a última análise, quando o produto final está pronto para operar. Um FMEA de processo deve ser realizado com o intuito de encontrar as falhas e as causas das falhas passíveis de ocorrer em um compressor hermético.

Modo de falha para esta aplicação significa compressor segregado ou rejeitado pelo painel de medições. Os efeitos entre os modos de falha são diferenciados pelos níveis de ruído e vibração, segundo os padrões de compressores considerados normais. Os modos de falha analisados são aqueles cujos efeitos poderão ser percebidos pelos testes, medições que avaliam a qualidade dos compressores. Muitos modos de falha presentes nesta análise, também geram efeitos relacionados com outros testes como o de consumo e vazamento. Entretanto, é interessante que análises distintas de modos de falha sejam feitas de acordo com a classe do efeito. Isto porque comparações entre padrões de compressores bons e com algum tipo de defeito são relacionados durante o teste, rejeitando ou aprovando o compressor que tiver uma ou outra condição. Dessa forma apenas os possíveis modos de falha relacionados e suas causas correspondentes estarão entre as potenciais fontes de falha, reduzindo o tempo e as chances de erro na correção das falhas.

Esses modos de falhas foram escolhidos através das principais ocorrências internas e externas à fábrica. Dentro das ocorrências externas, pretende-se segregar os compressores defeituosos que passaram pelo painel, fato indesejável devido aos custos envolvidos na troca em campo do compressor. Este ciclo de qualidade permite aumentar as variáveis do painel, tornando-o mais sensível à detecção de falhas antes que o compressor venha a deixar a fábrica, de preferência antes mesmo da montagem final, ou seja, de soldagem da tampa. Espera-se com esta prática também reduzir o número de compressores segregados indevidamente e que venham a prejudicar o desempenho direta ou indiretamente da empresa.

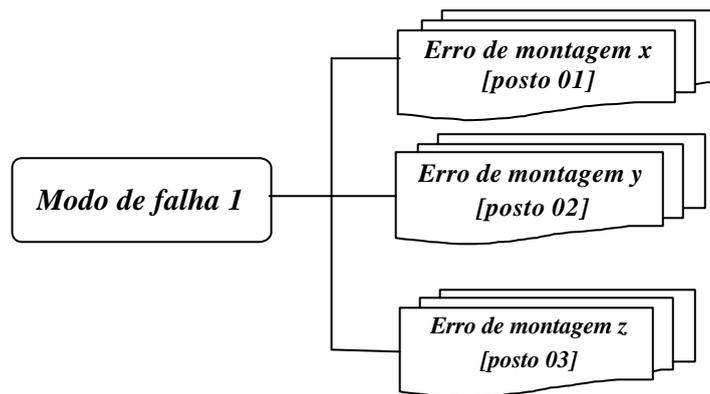


Figura 4.10.1 – Exemplo de árvore de falha

A árvore de falha para modos de falha relacionados com falhas na montagem consiste simplesmente de um evento de topo e seus possíveis causadores (Figura 4.10.1). Isso porque uma falha na montagem não possui outra causa senão erro de um operador, de uma máquina ao executar a operação de montagem ou no processo de fabricação de algum componente, que foge do escopo desta análise. Diferente de uma árvore de falha gerada para os modos de falha de um sistema em uso, em que o desgaste de determinado componente do sistema provoca desgaste nos demais e falha no sistema. Neste caso, tem-se modos de falha propagando outros modos de falha.

4.11 – Comentário

Neste capítulo foi apresentado o modelo de análise dos principais modos de falha da linha de montagem. As informações contidas na árvore de falha proporcionarão um diagnóstico dos compressores produzidos e auxiliarão a prevenir um certo número de problemas. Neste sentido serão apresentados no capítulo 5 os resultados do modelo proposto aplicado à linha de montagem de compressores herméticos.

CAPÍTULO 5 – RESULTADOS

5.1 - Introdução

O objetivo deste capítulo é verificar a potencialidade das ferramentas abordadas no capítulo 3 aplicadas à segregação de compressores herméticos. Neste trabalho, especificamente, deseja-se reduzir o número de compressores Falso Segregado e Falso Aprovado, ou seja, detectar falhas durante a montagem do compressor. Serão apresentadas as árvores de falhas, as tabelas de FMEA e simulações referente a três aplicações práticas, sendo uma em laboratório e as demais na linha de montagem da empresa. A primeira aplicação teve como objetivo testar a potencialidade da rede neural em classificar padrões de falhas conhecidos em compressores herméticos. A segunda refere-se à classificação automática de falhas na linha de montagem. E a terceira, teve como objetivo fazer uma comparação com o sistema atual de medição. Desta forma, um banco de dados de falhas foi obtido através de históricos de ocorrências de falhas provocadas involuntariamente pela linha de produção. Assim, uma rede neural foi treinada com este banco de dados simulando uma aplicação real das técnicas empregadas neste estudo. Desta aplicação originou o SISNAV (Sistema Neuro Acústico e Vibracional de Controle de Qualidade).

5.2 – Implementação do sistema proposto

A interface SISNAV foi desenvolvida com o intuito de organizar os testes do modelo simulando um painel de testes. A Figura 5.2.1 mostra a tela principal da interface. Foi utilizada a linguagem MATLAB[®], versão 6.1, na programação do mesmo. Na tela da Figura 5.2.1 há vários botões de edição. Antes de executar o programa alguns parâmetros devem ser definidos. *Arquivo* indica um nome de arquivo em particular que se deseja fazer a análise. Este arquivo é necessário toda vez que o programa for executado na opção *manual*. Após, é necessário definir o modelo de compressor para a análise. Depois de escolhido o modelo, o programa manterá este modelo como padrão. O botão *Lista de modelos* executará esta função. O botão *Modo de falha* contém apenas uma lista dos modos de falha já implementados no banco de dados. Para uma execução automática o botão *Cálculo automático* deve ser ativado. Esta função carrega todos os arquivos existentes previamente gravados pelo painel de medição. O botão *Gravar relatório* executa a gravação de um relatório com extensão *.txt* contendo o nome do arquivo, o padrão de entrada da rede neural de classificação e o código

do modo de falha. Este relatório poderá ser gerado tanto no modo manual quanto no automático. O botão *Iniciar* executa o programa. Quando este é habilitado no modo manual um *menu* principal aparece (Figura 5.2.2).

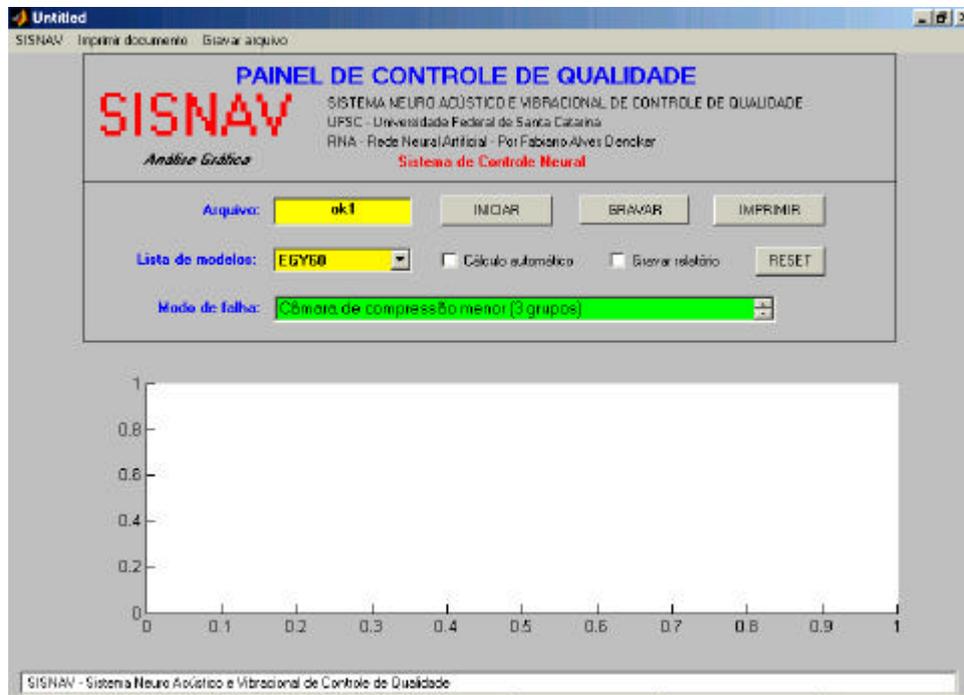


Figura 5.2.1 – Tela principal do programa

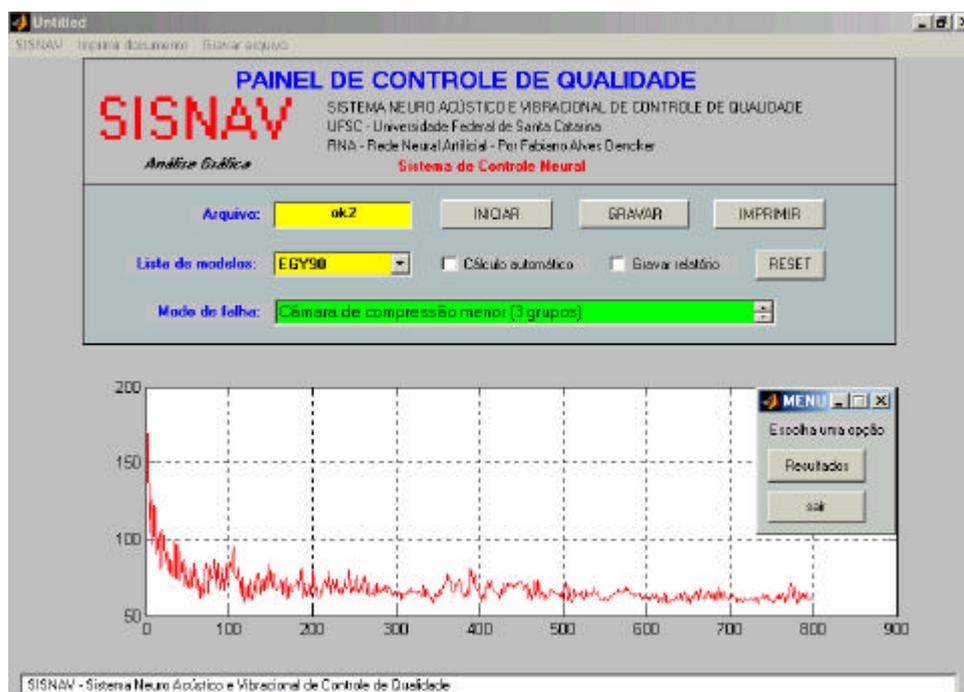


Figura 5.2.2 – Tela do SISNAV: menu principal

Este *menu* principal é composto por: visualização do cálculo (*Resultados*) e Abortar análise (*Sair*). Dentro do *menu* principal há um *submenu* de visualização composto por: Visualização do sinal na frequência (*Gráfico na frequência*), visualização por faixa de frequência (*Gráfico por faixa de frequência*), Identificação da existência ou não de uma falha (*submenu Rede neural*), carregar um novo arquivo (*carregar outro arquivo*) e sair do programa (*Sair*). O *submenu Rede neural* é composto por: verificação da qualidade do compressor medido (*Modo de falha*), voltar ao *submenu* de visualização (*Voltar*) e sair do programa (*Sair*).

Quando o botão *Modo de falha* é ativado uma mensagem contendo o modo de falha e um apontamento dos possíveis postos de montagem causadores deste modo de falha são mostrados. As informações desta caixa de mensagem foram baseadas em sua maioria na tabela de FMEA e na experiência dos montadores em prever as possíveis causas que levaram à ocorrência de determinada falha. Nas Figura 5.2.3 a 6 está ilustrado o restante dos detalhes da interface desenvolvida.

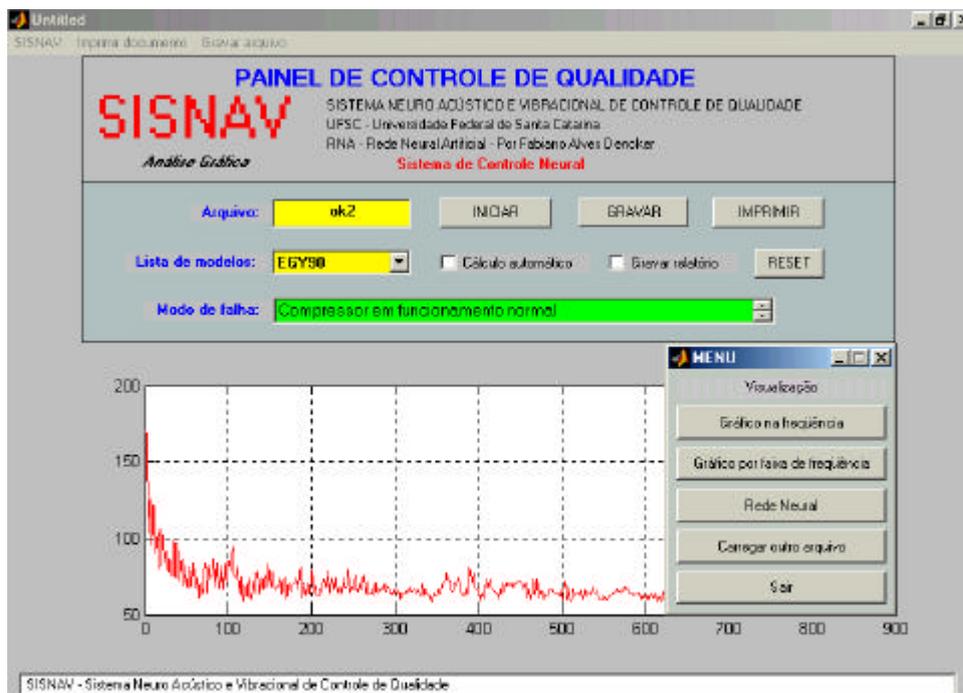


Figura 5.2.3 – Tela do SISNAV (*submenu* de visualização): Exemplo de um sinal na frequência

A Figura 5.2.3 apresenta a tela correspondente ao *submenu* de visualização. Esta tela aparece quando o programa já efetuou os cálculos. O resultado fica disponível na tela do *command windows* do MATLAB®.

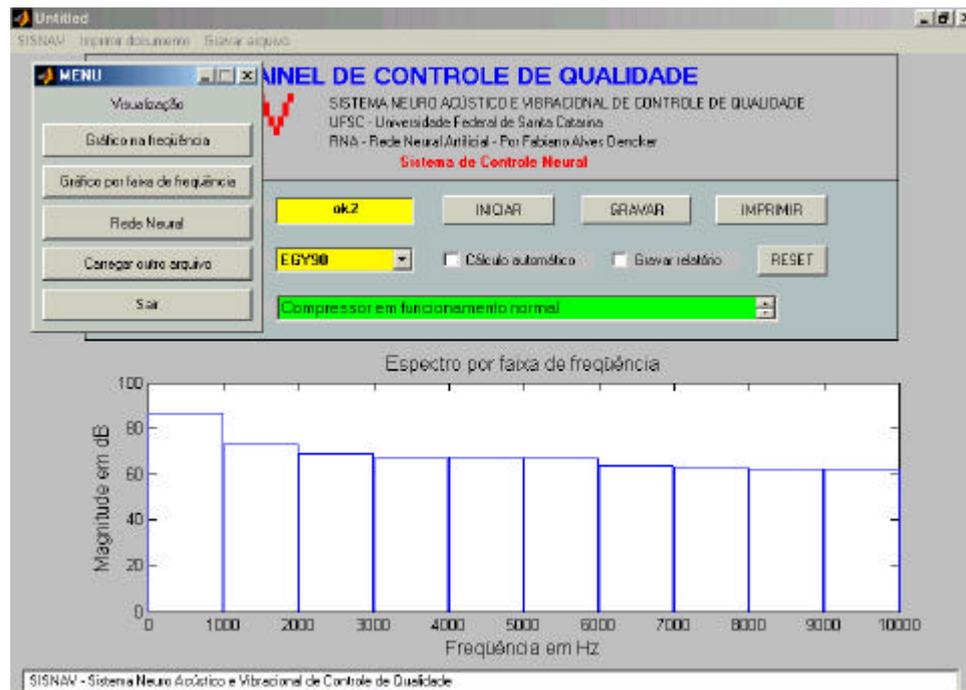


Figura 5.2.4 – Tela do SISNAV: Exemplo de um sinal por faixa de frequência

A Figura 5.2.4 apresenta um exemplo de sinal por faixa de frequência. Os valores em dB desta figura são os padrões de entrada apresentados à rede neural.

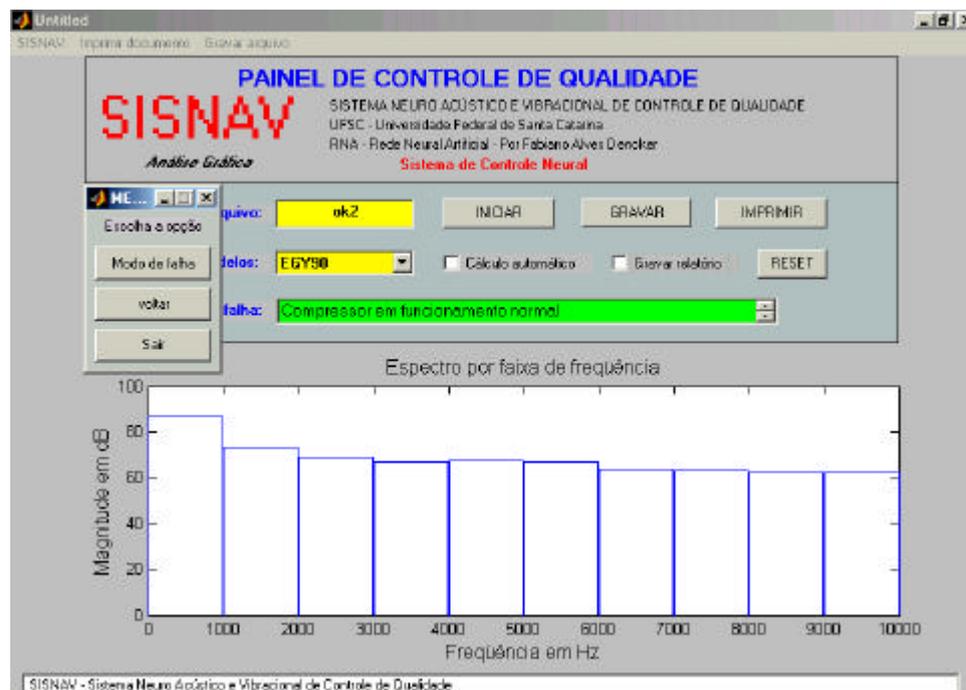


Figura 5.2.5 – Tela do SISNAV (submenu rede neural): Exemplo de sinal por faixa de frequência

A Figura 5.2.5 apresenta a tela correspondente ao *submenu rede neural*. Para se verificar a presença de uma falha basta ativar o botão *Modo de falha*.

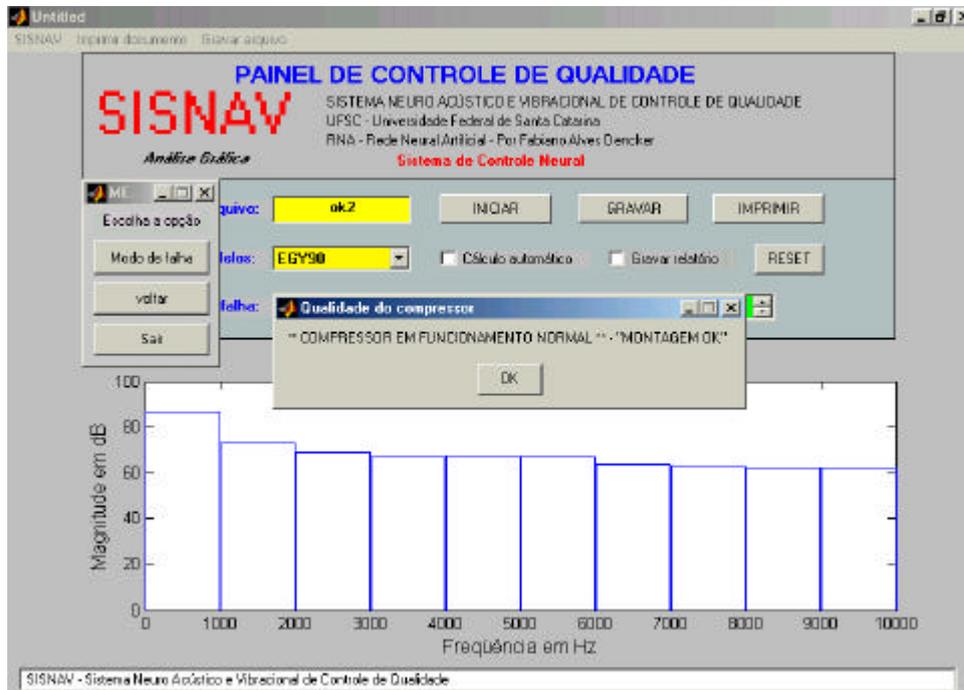


Figura 5.2.6 – Tela do SISNAV: Modo de falha e suas causas

Por fim, a Figura 5.2.6 apresenta a qualidade do compressor medido emitindo uma mensagem de aviso. Esta mensagem contém informações necessárias que podem ser computadas em um histórico de ocorrências. Esta mensagem é avaliada pelo montador que verifica se a mensagem dada pelo programa é autêntica. Uma vez confirmado o modo de falha, as informações contidas são gravadas em um banco de dados de ocorrência em forma de lista de verificação (*check list*).

Após o cálculo pode-se optar por imprimir a tela mostrando a mensagem ou os sinais. O botão *Imprimir* executa esta função. O botão *Gravar* salva as informações em um diretório previamente escolhido. Quando o programa é executado e o nome de um determinado arquivo não existir, e o programa venha a travar, recomenda-se reiniciar o programa ativando o botão *Reset* e entrar com um novo arquivo.

5.3 – Aplicação da FMEA e FTA: Banco de dados de falhas

Antes de efetuar o treinamento de uma rede neural para a segregação automática de compressores defeituosos, foram analisados os principais modos de falha. A aplicação deste procedimento tem por objetivo otimizar o processo de classificação de falhas e restringir a detecção das principais ocorrências registradas nos últimos dois anos (Figura 5.3.1). Espera-se, com isso, reduzir o aparecimento de falhas atuando diretamente no controle da fabricação. É importante salientar que erros de montagem não são somente provenientes de falhas humanas, porém também de falhas mecânicas, já que a linha em sua maioria é automatizada. A atuação direta na linha implicaria em um rigoroso treinamento de pessoal e de manutenção dos equipamentos.

Um estudo detalhado de uma das linhas de produção deu início à análise que se estendeu até o procedimento de montagem das peças. Uma vez conhecida a etapa de montagem, uma relação cruzando estas informações com as falhas determina a qualidade dos produtos a serem fabricados. Organizou-se um banco de dados de falha através de informações diretas dos postos de montagem e da influência que estes têm na fabricação, juntamente com a experiência dos especialistas da linha.

A aplicação conjunta das ferramentas FMEA e FTA determinou de forma precisa as possíveis causas dos principais modos de falha, contribuindo, assim, ao desenvolvimento do banco de dados. Em seguida, foram identificados através das ocorrências internas e externas à empresa, os modos de falha com maior grau de ocorrência (Tabela 5.3) e montadas árvores de falhas (Figura 5.3.2) para os principais modos de falha identificados no FMEA. O restante das árvores de falhas estão disponíveis no Apêndice 3.

Tabela 5.3 – Principais modos de falha

Descrição	Principais modos de falhas	Nº ocorrências
mf1	Defeito número 1 detectado	300
mf2	Defeito número 2 detectado	228
mf3	Defeito número 3 detectado	145
mf4	Defeito número 4 detectado	92
mf5	Defeito número 5 detectado	81
mf6	Defeito número 6 detectado	71
mf7	Defeito número 7 detectado	20
mf8	Defeito número 8 detectado	14
mf9	Defeito número 9 detectado	9

Dentre os modos de falhas ocorridos nos últimos dois anos, 9 deles foram adotados como sendo os principais modos de falha.

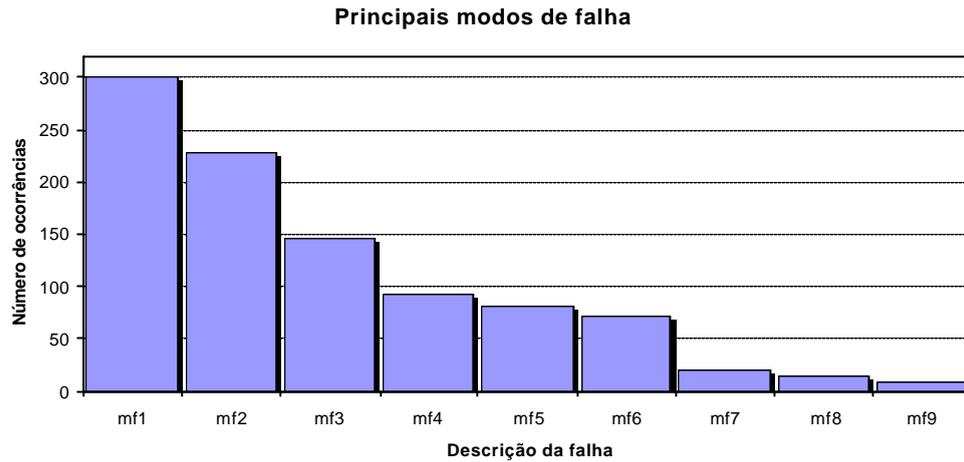


Figura 5.3.1 – Gráfico de Pareto dos principais modos de falha

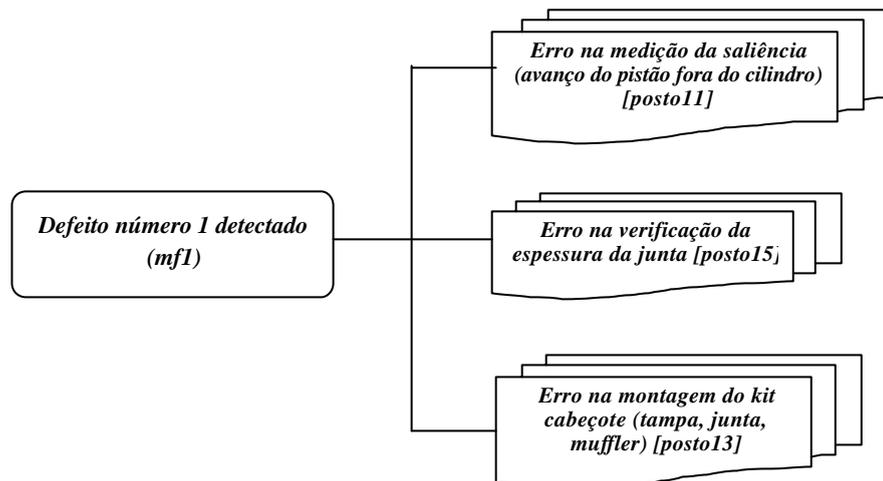


Figura 5.3.2 – Exemplo de árvore de falha para um modo de falha

5.3.1 – Análise dos modos de falha e efeito em compressores herméticos

Este tipo de FMEA tem como objetivo analisar os modos de falha causados por deficiências no processo de montagem e evitar que um compressor defeituoso seja analisado incorretamente. A importância desta análise consiste em facilitar a identificação de uma falha, acusada pelo painel de medição, que provocaria o descarte do compressor, e o erro na montagem que o provocou. A Tabela 5.3.1 apresenta os modos de falha dos principais componentes do sistema, suas funções, efeito e causas.

Tabela 5.3.1 – FMEA dos principais modos de falha aplicado em compressores

Sub-sistema	Função	Componente	Função	Modo de falha	Efeito	Causa
Sistema de Válvulas	Promover a transferência do gás do lado da sucção para o interior do cilindro e daí para o lado da descarga	Junta do cilindro (conjunto)	Proporcionar a vedação e estabelecer a distância entre o topo do pistão e a superfície da placa	Espessura errada (incompatível com o modelo)	Ruído / vibrações fora do padrão normal	Erro na medição da saliência (avanço do pistão fora do cilindro) (posto11)
					Ruído / vibrações fora do padrão normal	Erro na verificação da espessura da junta (posto15)
					Ruído / vibrações fora do padrão normal	Erro na montagem do kit cabeçote (tampa, junta, muffler) (posto13)
Sistema de Descarga	Conduzir o refrigerante, a alta pressão e temperatura, do interior do cilindro para o sistema a refrigerar em direção ao condensador	Tubo de descarga	Transportar o refrigerante da câmara de descarga para o passador do compressor	Mal posicionado	Ruído / vibrações fora do padrão normal	Erro na montagem da tampa e junta da tampa da câmara de descarga (posto26)
			Acumula a função de evitar a transmissão de vibração para a carcaça do compressor e atenuação de pulsação do gás no interior do sistema de descarga (para isso é dotado de certa flexibilidade)	Mal soldado	Ruído / vibrações fora do padrão normal	Erro no ajuste do tubo de descarga (posto29)
					Ruído / vibrações fora do padrão normal	Erro na soldagem do tubo de descarga (posto27)

Sub-sistema	Função	Componente	Função	Modo de falha	Efeito	Causa	
Sistema de Acionamento (Biela-Manivela)	Transformar energia elétrica em energia mecânica	Motor (rotor / estator)	Produzir torque	Montado com folga radial inadequada	Ruído / vibrações fora do padrão normal	Erro na montagem do estator (posto3)	
					Ruído / vibrações fora do padrão normal	Erro na parafusação do estator no bloco (posto4)	
					Ruído / vibrações fora do padrão normal	Erro na montagem (posicionamento/aquecimento/resfriamento) o rotor (postos17,18,19)	
					Ruído / vibrações fora do padrão normal	Erro na verificação da folga radial rotor/bobina (posto20)	
		Pistão	Promover a compressão do gás refrigerante	Montado com folga radial inadequada (no cilindro)	Ruído / vibrações fora do padrão normal	Erro na verificação da tolerância do pistão (posto7)	
					Montado sem o lubrificante	Ruído / vibrações fora do padrão normal	Erro na montagem da bucha no eixo (posto10)
					Montado não concêntrico ao cilindro	Ruído / vibrações fora do padrão normal	Erro na montagem do conjunto eixo/pino/biela/pistão no bloco (posto9)
					Corpo estranho no topo do pistão	Ruído / vibrações fora do padrão normal	Erro na montagem da câmara plástica (posto7,8,9,12)

Sub-sistema	Função	Componente	Função	Modo de falha	Efeito	Causa
Sistema de suspensão e limitador de oscilações	Minimizar a transmissão de vibração e ruído do kit para a carcaça do compressor e ao sistema de refrigeração	Molas helicoidais	Suspender o kit mecânico no interior da carcaça do compressor	Mal fixada	Ruído / vibrações fora do padrão normal	Erro na montagem do suporte de mola (posto3)
				Falta mola		
				Mola errada (tamanho, diâmetro, etc. não compatível com o modelo)	Ruído / vibrações fora do padrão normal	Erro na montagem das molas no suporte (posto21)
				Mola quebrada		
Posicionada fora do batente plástico						
Sistema de Sucção (indireta)	Conduzir o refrigerante do sistema a refrigerar, a baixa pressão e temperatura, ao interior do cilindro	Mola do muffler de sucção	Pressionar o muffler na placa de válvulas e evitar vazamento	Mal posicionada	Ruído / vibrações fora do padrão normal	Erro na montagem do kit cabeçote (tampa, junta, muffler) (posto21)
				Ausência da mola		

A partir deste processo, uma rede neural foi treinada com as informações contidas nestas tabelas através do sinal medido de ruído e/ou vibrações. Os resultados podem ser encontrados na Aplicação 2.

5.4 – Primeira aplicação: Teste em laboratório

Este primeiro experimento tem por base a arquitetura apresentada na Seção 4.3. Diferentemente do uso ou não dos principais modos de falha, deseja-se saber a potencialidade dessa ferramenta em detectar falhas em compressores herméticos. Sabe-se que a rede neural possui a característica de extrair informações de um grupo de treinamento e otimizá-las produzindo resultados através de um critério de classificação.

Para este teste, foram disponibilizados pela empresa sinais em função do tempo de compressores defeituosos. Estes defeitos foram criados pela empresa com base nas falhas que ocorrem na linha de produção. Foram disponibilizados 100 sinais contendo 4 classes de falhas com 25 amostras cada, para um determinado modelo de compressor, além de 25 amostras do mesmo modelo de compressor em funcionamento normal.

Para esta aplicação foram treinadas várias redes neurais. As taxas de acerto variaram entre 74% e 100%. As redes neurais de classificação e de identificação foram testadas em conjunto. Portanto, os resultados considerados são os calculados pela rede de identificação. Optou-se por esta metodologia porque os resultados calculados representariam a

qualidade na montagem do compressor, ou seja, uma mensagem contendo não só o modo de falha como também os possíveis postos de montagem que levaram à ocorrência da mesma. Sendo assim, as redes foram sendo treinadas em paralelo.

Os testes demonstraram que, mesmo a rede de classificação produzindo um vetor de saída com um ou dois *bits* de diferença do vetor desejado, a rede de identificação mostrou boa capacidade de generalização, apresentando resultados corretos. A melhor configuração entre elas foi a adotada para este problema.

A regra para o número de neurônios na camada intermediária foi a média aritmética entre o número de neurônios da camada de entrada e o número de neurônio na camada de saída. A arquitetura da rede de classificação possui 10 neurônios na camada de entrada, 7 neurônios na camada intermediária e 4 neurônios na camada de saída. Já a rede de identificação possui 4 neurônios na camada de entrada, 3 neurônios na camada intermediária e 1 neurônio na camada de saída (Figura 5.4.1).

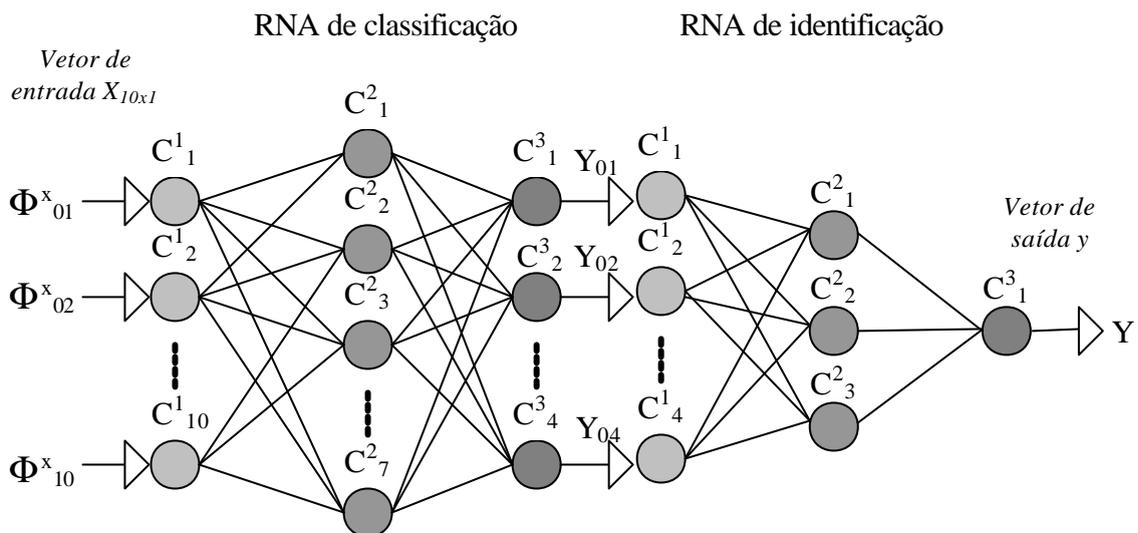


Figura 5.4.1 – Configuração da rede neural utilizada na primeira aplicação

5.4.1 – Padrões de treinamento: Primeira aplicação

Para o treinamento da rede foram utilizados 15 arquivos de cada classe de defeito e 15 arquivos de compressores bons dos dados fornecidos pela empresa. Os padrões de entrada Φ consistem nos valores em dB das faixas de frequência como mencionado anteriormente. Exemplos de padrões de treinamento podem ser vistos na figura 5.4.2.

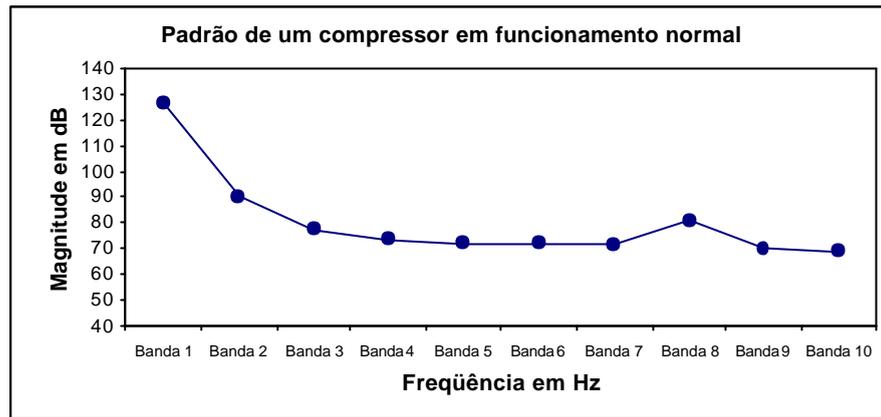


Figura 5.4.2 a – Exemplo de padrão de treinamento de um compressor em funcionamento normal

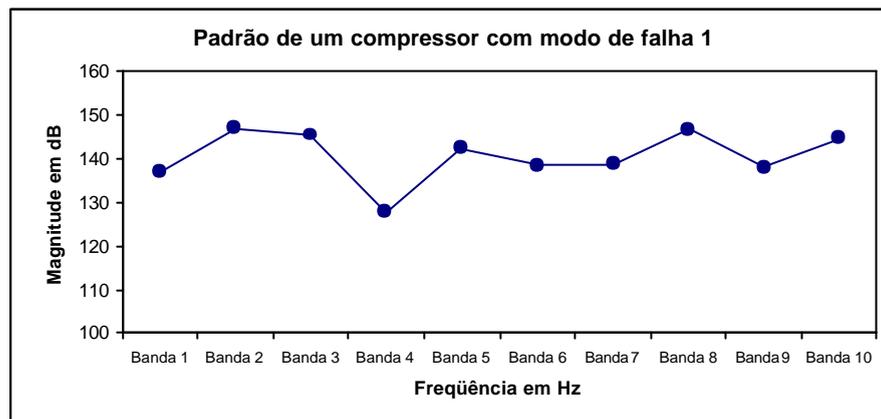


Figura 5.4.2 b – Exemplo de padrão de treinamento de um compressor com modo de falha 1

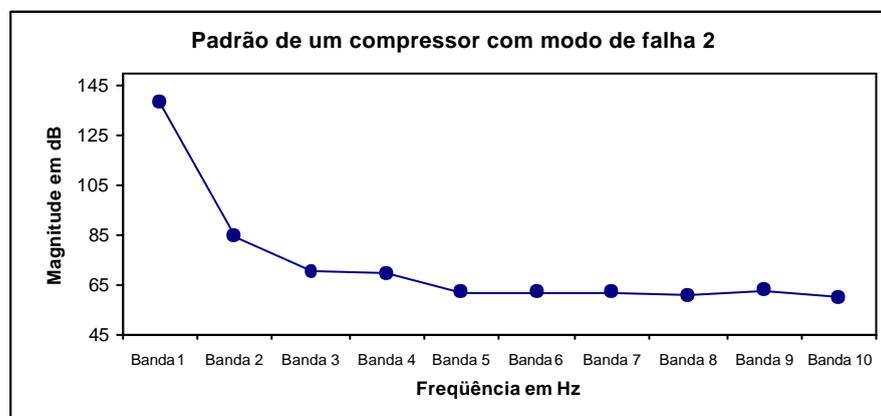


Figura 5.4.2 c – Exemplo de padrão de treinamento de um compressor com modo de falha 2

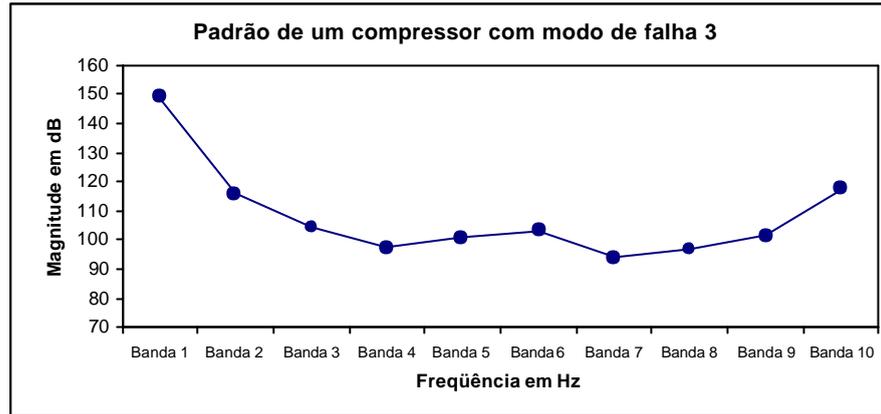


Figura 5.4.2 d – Exemplo de padrão de treinamento de um compressor com modo de falha 3

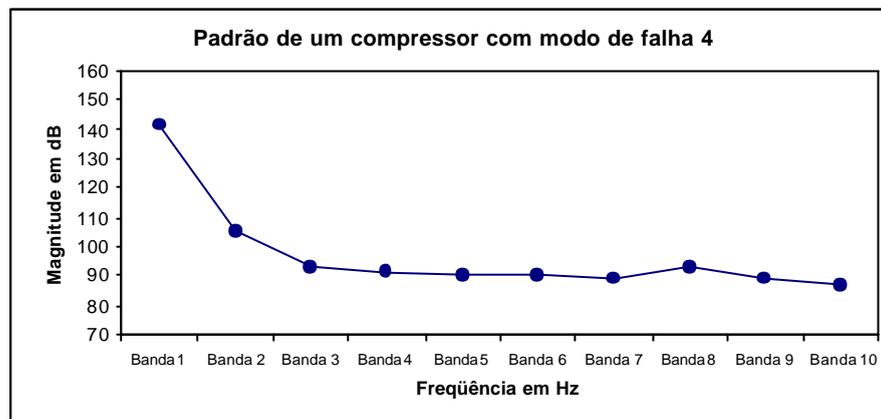


Figura 5.4.2 e – Exemplo de padrão de treinamento de um compressor com modo de falha 4

5.4.2 – Treinamento

O treinamento da rede segue o procedimento descrito na Seção 3.3. Para o treinamento da rede foi utilizado um algoritmo do tipo *backpropagation* (Seção 3.2.9). Esse algoritmo foi implementado em linguagem MATLAB[®]. O treinamento, neste caso, correspondeu às características de 100000 ciclos, um momento de 0,3 e uma taxa de aprendizado de 0,1.

5.4.3 – Resultados da primeira aplicação

Utilizando a estrutura descrita na Seção 5.4 foram realizados sete treinamentos sendo sempre iniciados com pesos aleatórios entre $-0,1$ e $0,1$. O erro médio quadrático calculado para a RNA de classificação foi de 0,0014 para o conjunto de treinamento (Figura

5.4.3 – curva inferior) e de 0,13 para o conjunto de teste (Figura 5.4.3 – curva superior). Verificam-se ainda, uma especialização nos dados de treinamento após 3041 ciclos, a partir do que o erro do conjunto de testes começa a aumentar. Já para a RNA de identificação, o erro médio quadrático foi de 0,006 em 682 ciclos (Figura 5.4.4).

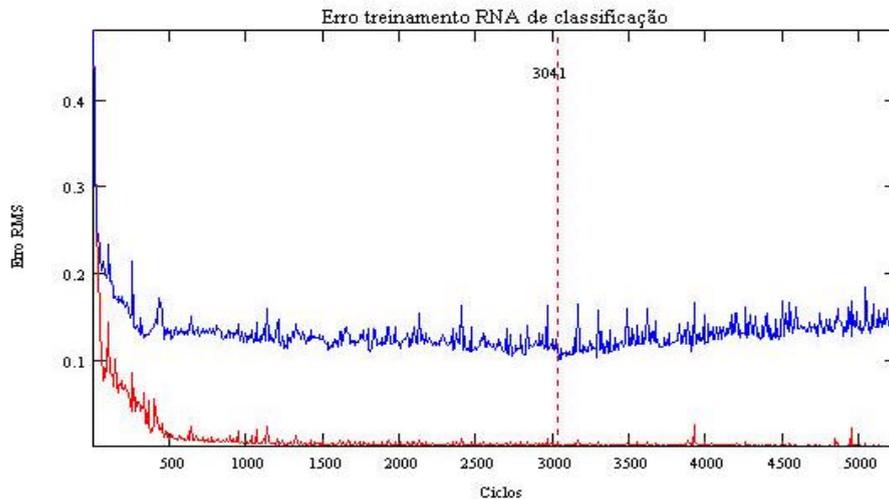


Figura 5.4.3 – Erro médio quadrático para rede neural de classificação do conjunto de treinamento (curva inferior) e do conjunto de teste (curva superior)

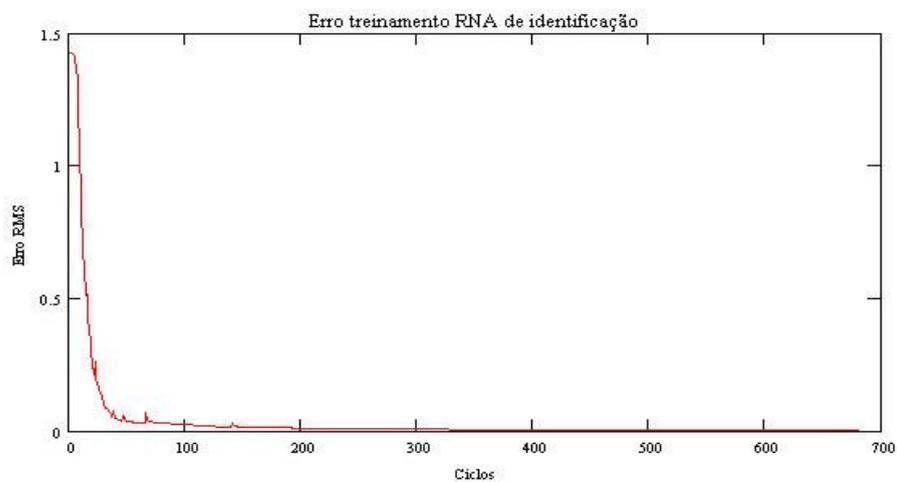


Figura 5.4.4 – Erro médio quadrático para rede neural de identificação do conjunto de treinamento

Procedimento para a avaliação dos resultados:

- 1) Selecionar um grupo de novos compressores;
- 2) Realizar as n medições de ruído e/ou vibrações para o teste;
- 3) Distribuir aleatoriamente as n medições;

- 4) Testar as n medições com a rede neural;
- 5) Verificar todas as respostas dadas e avaliar estatisticamente os resultados de acordo com a taxa de acerto, sensibilidade, especificidade, valor preditivo aprovado e valor preditivo segregado.

Foram realizadas 50 novas medições*, distribuídas em 10 medições de cada modo de falha e 10 medições de compressores em funcionamento normal. Os resultados se mostraram promissores, muito embora feito sobre pequeno número de compressores. A rede apresentou uma performance além do esperado, generalizando os resultados dos novos padrões de entrada.

Através do TDE (Teste de Desempenho Estatístico) chegou-se a valores de sensibilidade de 100% demonstrando a capacidade que a rede neural possui em detectar uma falha de montagem. Mesmo errando um modo de falha, a sensibilidade seria de 100% pois nem um compressor ruim passou como sendo bom. Como a rede neste caso não errou nem um modo de falha, a probabilidade de detectar corretamente uma falha de um lote de compressores é alta. Com o aumento do número de compressores para a ordem de milhares, espera-se que este valor reduza um pouco. A especificidade de 100% descreve a capacidade da rede em detectar compressores bons. Neste caso, dez dos 50 novos compressores apresentados a RNA, foram tidos como estando em funcionamento normal.

O Valor Preditivo Aprovado estima a probabilidade de um compressor não estar em falha, ou seja, verifica se realmente o compressor está em funcionamento normal. O VLPA calculado é de 100%, provando assim de que todos os dez compressores realmente estavam funcionando perfeitamente. O Valor Preditivo Segregado estima a probabilidade de um compressor estar em falha, ou seja, verifica se o compressor foi segregado corretamente. O VLPS calculado é de 100%. Este valor indica que todos os compressores foram segregados corretamente e que suas falhas realmente estavam presentes, não errando na especificação do modo de falha. A taxa de acerto média é de 100%. Cada modo de falha possui suas peculiaridades, o que contribuiu para extração de características através do treinamento da rede neural. Quanto mais distintos forem os padrões de entrada maior será a capacidade de generalização e, conseqüentemente, a probabilidade de uma resposta estar correta.

* Estes arquivos fazem parte dos 125 sinais fornecidos pela empresa.

5.5 – Segunda aplicação: Implementação na pré montagem de compressores

Esta segunda aplicação foi realizada em uma das linhas de pré montagem da Embraco S/A. A arquitetura utilizada é a mesma apresentada na Seção 4.3. Esta aplicação teve o objetivo de testar a rede trabalhando com dados reais coletados diretamente do painel de medições. Os sinais coletados para esta aplicação são de ruído na cavidade do compressor. Neste teste, a tampa ainda está aberta e o operador pode corrigir as falhas de montagem. Diferentemente da primeira aplicação, os sinais já estão no domínio da frequência, ou seja, o painel grava a FFT do sinal de ruído do compressor medido.

Na construção do banco de dados para o treinamento e teste da rede neural foram induzidos modos de falha nos compressores da linha de produção com base na Tabela 5.3.1 de FMEA. Foram realizadas aproximadamente 18 medições para cada um dos nove modos de falha. Para isto, seis compressores por modo de falha foram fabricados e medidos de três a quatro vezes cada um.

Como estes compressores eram fabricados com a linha em funcionamento, precisava-se verificar a manifestação do modo de falha. Um especialista realizou uma investigação dos modos de falha através de uma inspeção auditiva. Além deste procedimento, todos os modos de falha foram transformados em padrões de entrada e comparados em classes para a verificação de padrões espúrios (Figura 5.5.1). Aqueles cujos níveis estavam aquém ou além de uma distribuição média, foram desconsiderados para as fases de treinamento e teste.

Como pode ser visto na Figura 5.5.1, alguns padrões estão fora de suas respectivas classes de falhas. Isto se deve à fabricação do compressor com o modo de falha não ser homogênea. Como exemplo, veja a Figura 5.5.1 e. Nesta figura, percebe-se que, dentro das elipses, dois exemplos de padrões estão fora de uma distribuição. O padrão superior (elipse com linha cheia) teve seus níveis além de uma distribuição média, sendo assim eliminado do banco de dados. Da mesma forma, o padrão inferior (elipse com linha pontilhada) foi eliminado por não manifestar esta classe de falha. O objetivo desta análise visual é de aproveitar ao máximo os padrões mais próximos reduzindo uma indução a erros na classificação dos modos de falha. Outros exemplos podem ser vistos na Figura 5.5.1 c, f e g.

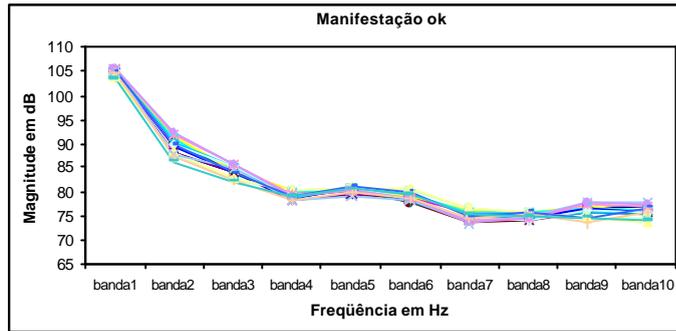


Figura 5.5.1 a – Compressores em funcionamento normal

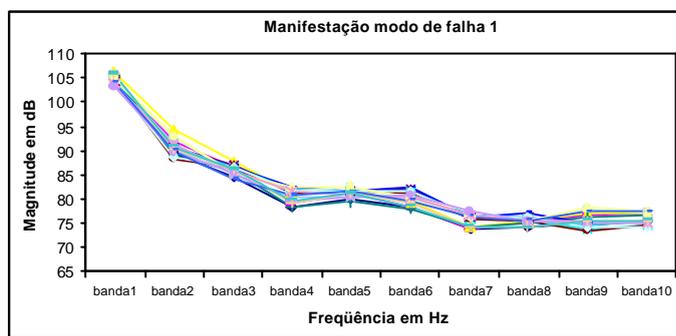


Figura 5.5.1 b – Manifestação do modo de falha 1

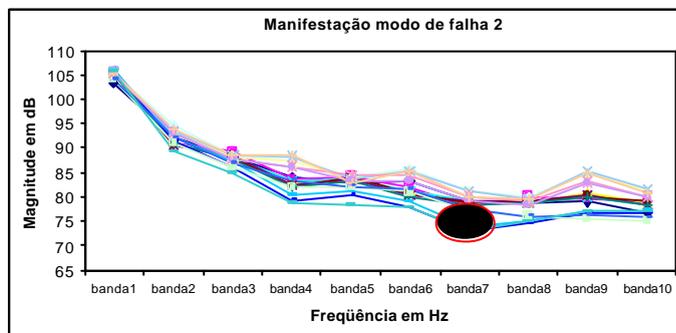


Figura 5.5.1 c – Manifestação do modo de falha 2

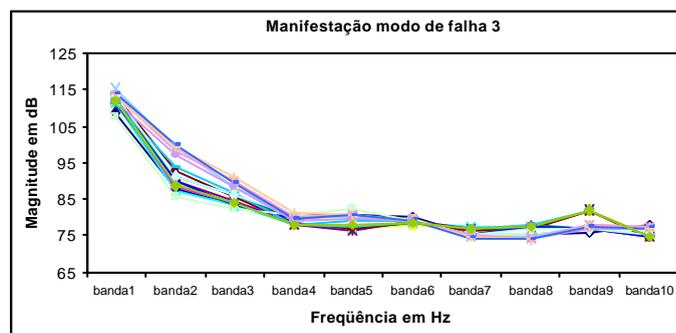


Figura 5.5.1 d – Manifestação do modo de falha 3

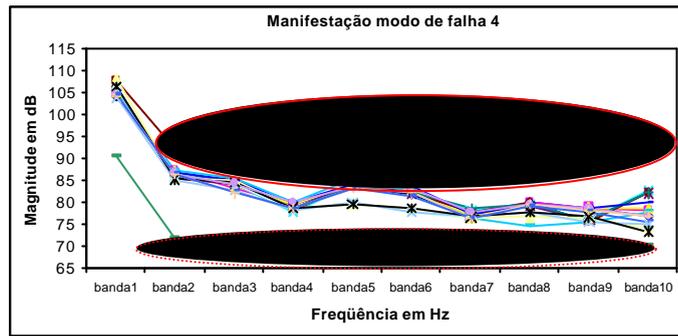


Figura 5.5.1 e – Manifestação do modo de falha 4

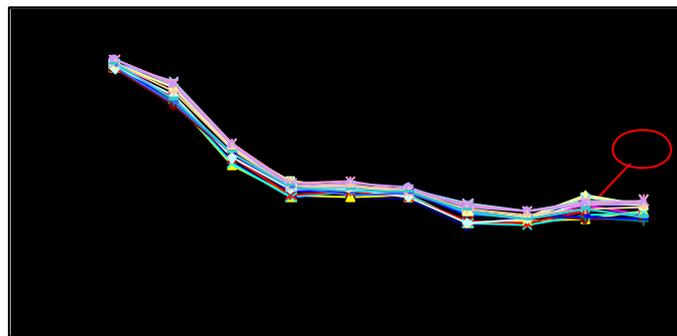


Figura 5.5.1 f – Manifestação do modo de falha 5

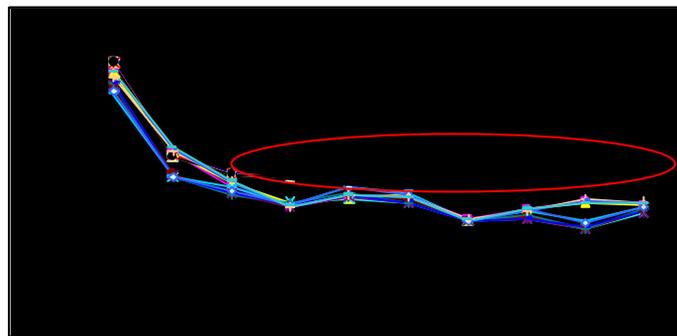


Figura 5.5.1 g – Manifestação do modo de falha 6

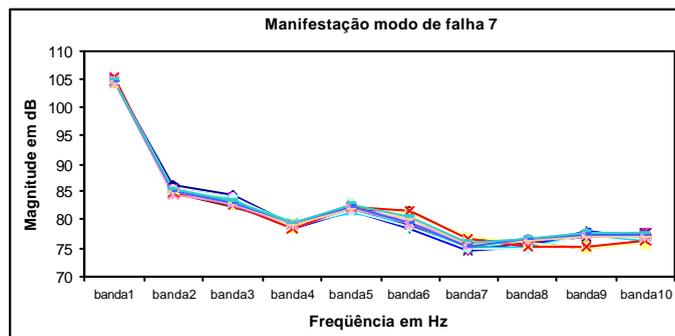


Figura 5.5.1 h – Manifestação do modo de falha 7

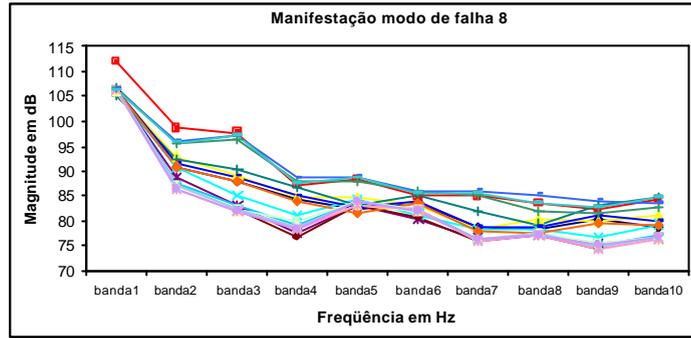


Figura 5.5.1 i – Manifestação do modo de falha 8

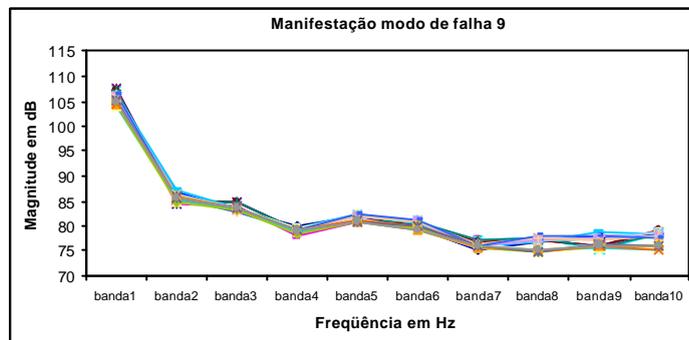


Figura 5.5.1 j – Manifestação do modo de falha 9

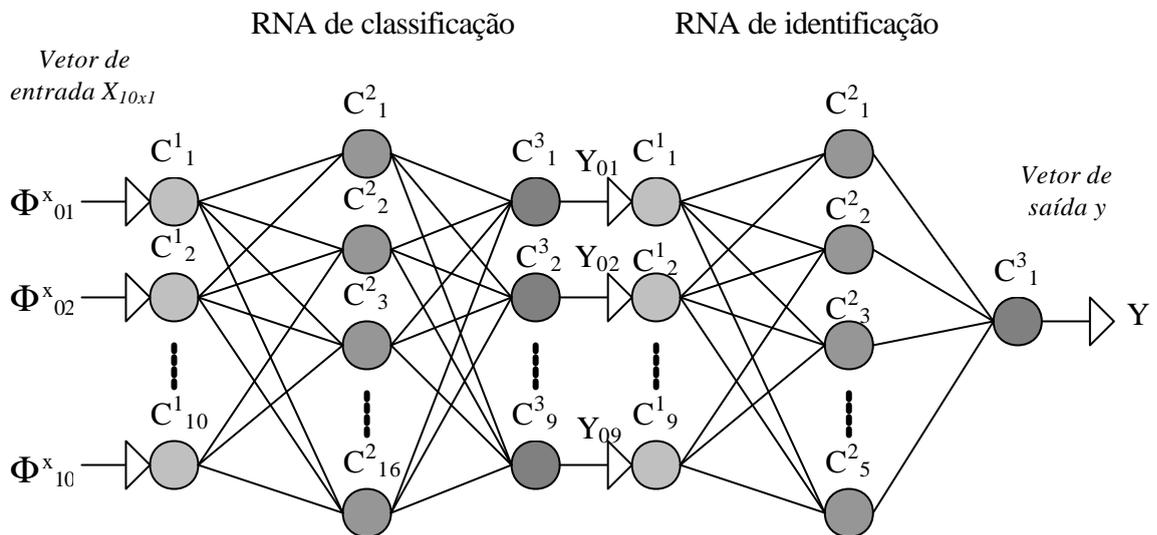


Figura 5.5.2 - Configuração da rede neural utilizada na segunda aplicação

Foram treinadas várias redes, sendo que a arquitetura da rede de classificação com melhor desempenho possui 10 neurônios na camada de entrada, 16 neurônios na camada intermediária e 9 neurônios na camada de saída. Já a rede de identificação possui 9 neurônios

na camada de entrada, 5 neurônios na camada intermediária e 1 neurônio na camada de saída. A rede de melhor desempenho mostrada na Figura 5.5.2 foi utilizada nos testes.

5.5.1 – Padrões de treinamento: Segunda aplicação

Para o treinamento da rede foram utilizados de 7 a 9 arquivos por modo de falha e 9 arquivos de compressores bons. Os padrões de entrada são os mesmos apresentados na Figura 5.5.1. Uma comparação entre os padrões de entrada apresentados à rede neural durante a fase de treinamento pode ser visto na Figura 5.5.3. Os parâmetros de treinamento são os mesmos da Seção 5.4.2.

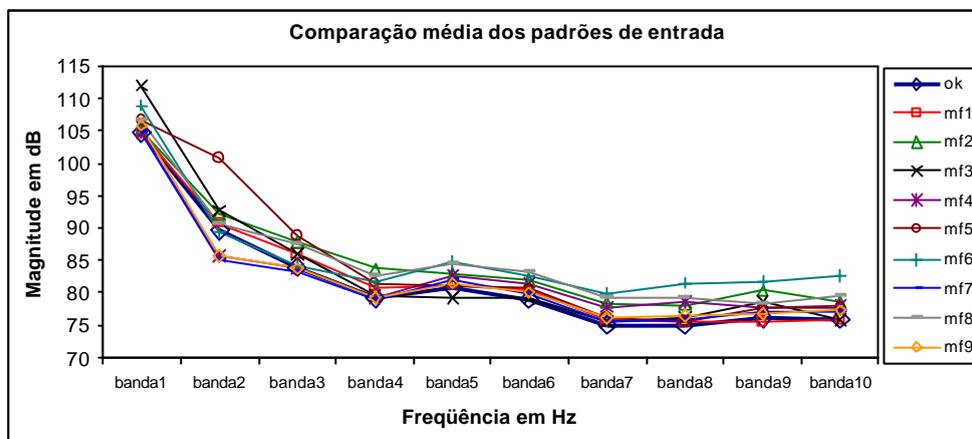


Figura 5.5.3 – Comparação média dos padrões de treinamento

Embora os padrões de entrada estejam muito próximos, a rede neural conseguiu extrair características na fase de treinamento para uma classificação das classes de falhas envolvidas.

5.5.2 – Resultados da segunda aplicação

Utilizando a estrutura descrita na Seção 5.5 foram realizados seis treinamentos. Os pesos sinápticos foram iniciados aleatoriamente entre $-0,1$ e $0,1$. O erro médio quadrático calculado para a RNA de classificação foi de $0,00329$ para o conjunto de treinamento (Figura 5.5.4 – curva inferior) e de $0,11$ para o conjunto de teste (Figura 5.5.4 – curva superior) em 819 ciclos. Verifica-se, ainda, uma especialização nos dados de treinamento após 850 ciclos onde o erro do conjunto de testes começa a aumentar. Já para a RNA de identificação o erro médio quadrático foi de $0,0034$ em 36712 ciclos (Figura 5.5.5).

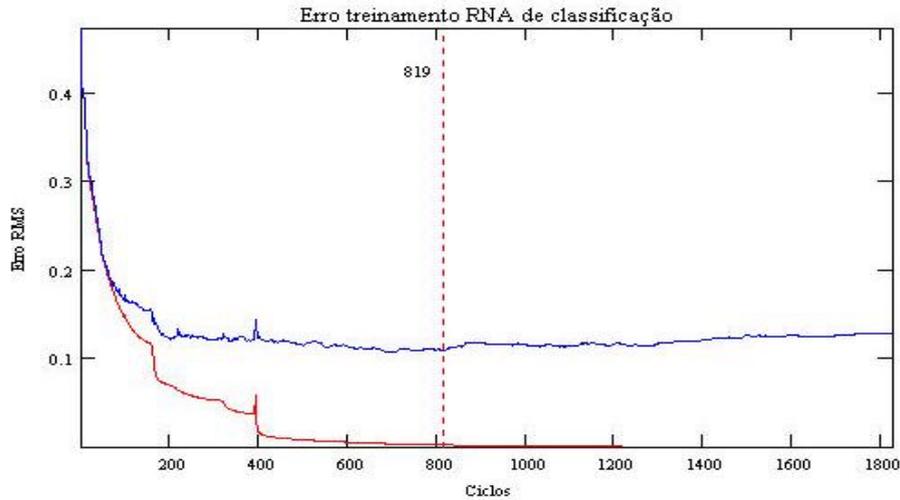


Figura 5.5.4 – Erro médio quadrático para rede neural de classificação do conjunto de treinamento (curva inferior) e do conjunto de teste (curva superior)

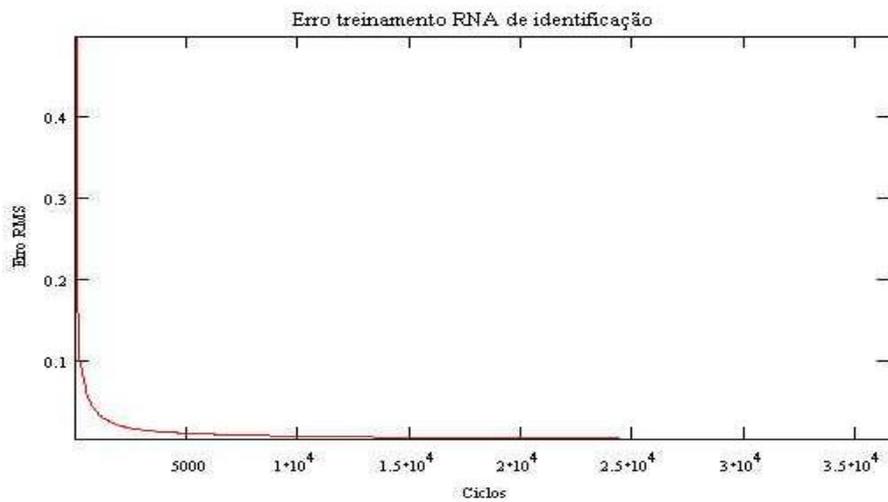


Figura 5.5.5 – Erro médio quadrático para rede neural de identificação do conjunto de treinamento

Foram realizadas 84 novas medições. Entre elas, 9 medições para cada modo de falha exceto para os modos 2 e 6 dos quais foram feitos 6 novas medições e 9 medições de compressores em funcionamento normal. Estes arquivos foram apresentados à rede e os testes demonstraram bons resultados.

Durante os testes ocorreram duas segregações do tipo FS, ou seja, a rede errou a identificação dos modos de falhas 4 e 8, de dois compressores. Este resultado não comprometeu a análise, pois a rede acertou em especificar que existe uma falha, embora tenha errado o modo de falha.

O TDE atingiu valores de sensibilidade de 100%. Este valor demonstrou a capacidade da rede em identificar uma falha de montagem. Já a proporção de casos em que o compressor não está com defeito, ou seja, a capacidade em detectar um compressor em funcionamento normal é medido pela especificidade, que para este caso é de 81,82%. Este valor se deve ao erro na identificação dos dois modos de falha.

O Valor Preditivo Aprovado estima a probabilidade dos casos detectados de compressores normais estarem realmente sem falha. Como todos os nove compressores bons foram identificados corretamente, o VLPA é de 100%. O Valor Preditivo Segregado refere-se à probabilidade de um compressor estar realmente com a falha, ou seja, verifica se o compressor foi segregado corretamente. O VLPS calculado é de 97,53%. Este valor descreve que compressores foram segregados por algum tipo de falha, mas que não há certeza de que a falha realmente é aquela presente no compressor. Então, a probabilidade de ocorrer um erro na indicação da falha é dado pela diferença $(1 - \text{VLPS}) \times 100$, ou seja, 2,43%. A taxa de acerto média nesta aplicação foi de 97,78%.

5.6 – Terceira aplicação: Validação do modelo proposto

Esta terceira aplicação foi realizada em uma das linhas de montagem final da Embraco S/A. A arquitetura utilizada é a mesma apresentada na Seção 4.3. Esta aplicação tem o objetivo de validar o modelo proposto em função de um breve comparativo entre a metodologia proposta e a atual. A análise comparativa será dada construindo uma rede com as mesmas características de teste do critério atual. Os dados são coletados no domínio da frequência diretamente do painel de medições. O sinal de vibração medido na carcaça do compressor é dividido em 20 valores. Estes 20 valores proporcionarão o padrão de entrada para esta aplicação. Nesta fase, o compressor está hermeticamente fechado.

Para o treinamento e teste da rede neural, modos de falha foram induzidos nos compressores. Um lote reduzido de compressores foi construído, pois uma vez fechados não se pode abri-los novamente, sendo, então, sucateados após o teste. Para construção do banco de dados, seis compressores foram montados contendo três diferentes modos de falha com base na Tabela 5.3.1 de FMEA. Estas falhas foram agrupadas em duas classes como sendo de compressores com defeito, ou seja, para esta análise final optou-se por simplesmente considerar estes modos de falha como sendo de apenas duas classes de falha, permitindo à rede neural produzir respostas objetivas simulando o resultado do painel passa/não-passa. Um exemplo das classes de falhas pode ser visto na Figura 5.6.1.

Os compressores foram medidos quatro vezes na linha de montagem final juntamente com compressores em funcionamento normal. Os sinais foram armazenados em um banco de dados. Ao todo foram medidos 82 compressores, sendo 24 compressores com defeito e 58 sem defeito.

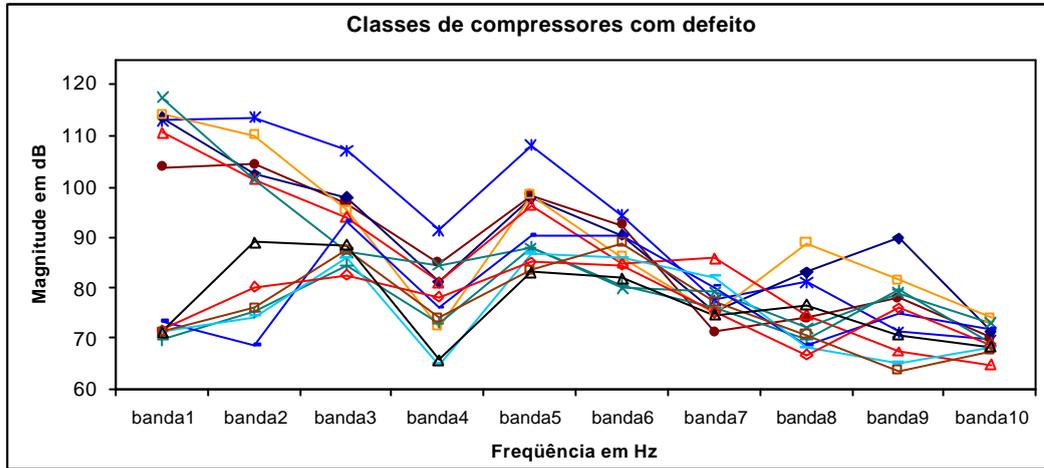


Figura 5.6.1 – Exemplos de classes de compressores com defeito

Várias foram as redes treinadas. A arquitetura da rede de classificação com melhor desempenho possui 20 neurônios na camada de entrada, 6 neurônios na camada intermediária e 3 neurônios na camada de saída. Já a rede de identificação possui 3 neurônios na camada de entrada, 2 neurônios na camada intermediária e 1 neurônio na camada de saída. A Figura 5.6.2 mostra a rede neural utilizada nos testes.

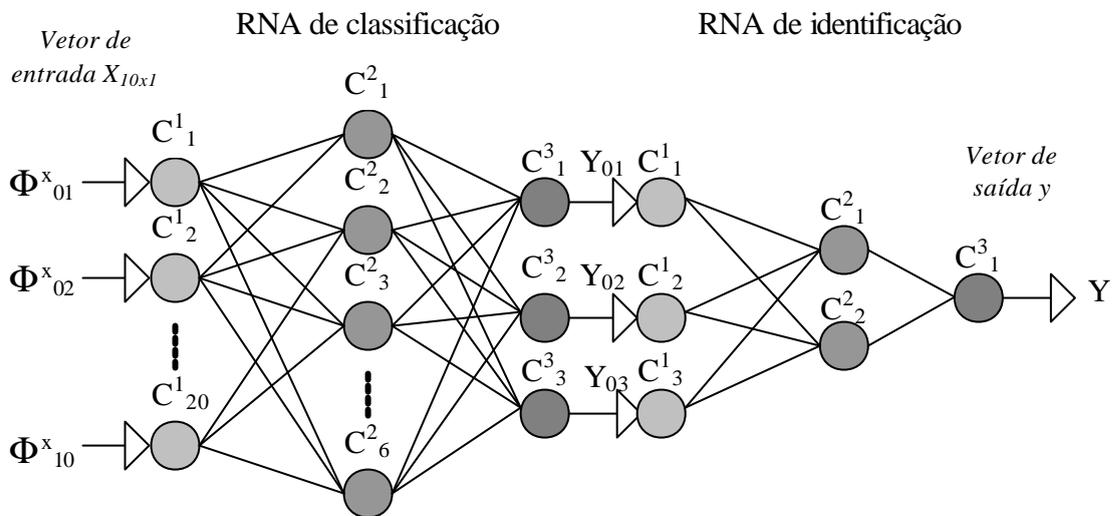


Figura 5.6.2 – Configuração da rede neural utilizada na terceira aplicação

5.6.1 – Padrões de treinamento: Terceira aplicação

Para o treinamento da rede foram utilizados 10 arquivos contendo as duas classes de falhas e 9 arquivos de compressores bons. Uma comparação entre os padrões de entrada apresentados à rede neural durante a fase de treinamento pode ser vista na Figura 5.6.3. Os parâmetros de treinamento são os mesmos da Seção 5.4.2.

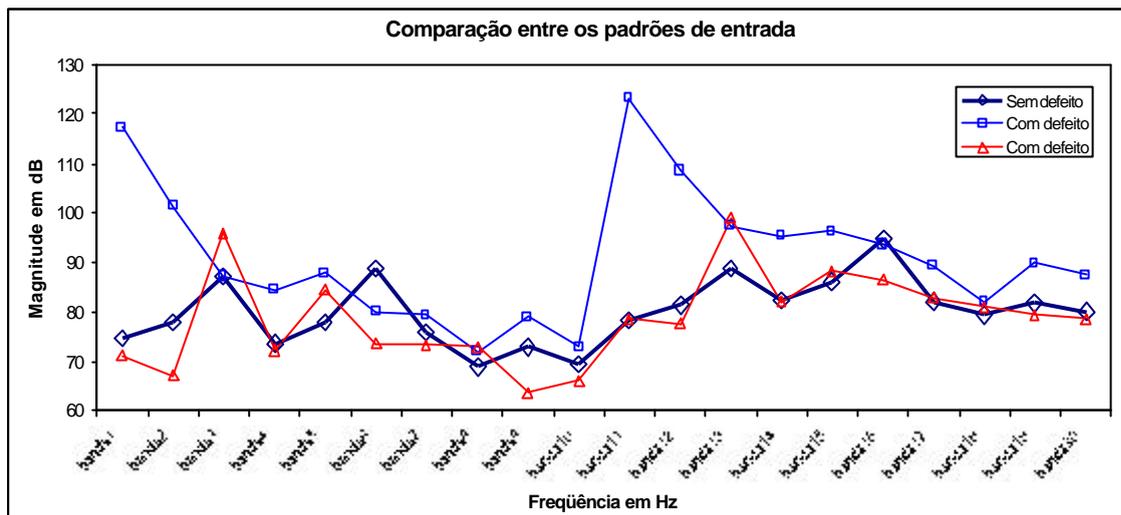


Figura 5.6.3 – Comparação entre os padrões de treinamento

Note que os padrões da Figura 5.6.3 são mais personalizados, o que facilita a extração de características na fase de treinamento da rede.

5.6.2 – Resultados da terceira aplicação

Foram realizados 3 treinamentos utilizando a estrutura descrita na Seção 5.6. Os pesos sinápticos foram iniciados aleatoriamente entre $-0,1$ e $0,1$. O erro médio quadrático calculado para a RNA de classificação foi de $0,0064$ para o conjunto de treinamento (Figura 5.6.4 – curva inferior) e de $0,20$ para o conjunto de teste (Figura 5.6.4 – curva superior) em 41 ciclos. Verifica-se, ainda, uma especialização nos dados de treinamento após 41 ciclos onde o erro do conjunto de testes começa a aumentar. Já para a RNA de identificação o erro médio quadrático foi de $0,0058$ em 222 ciclos (Figura 5.6.5).

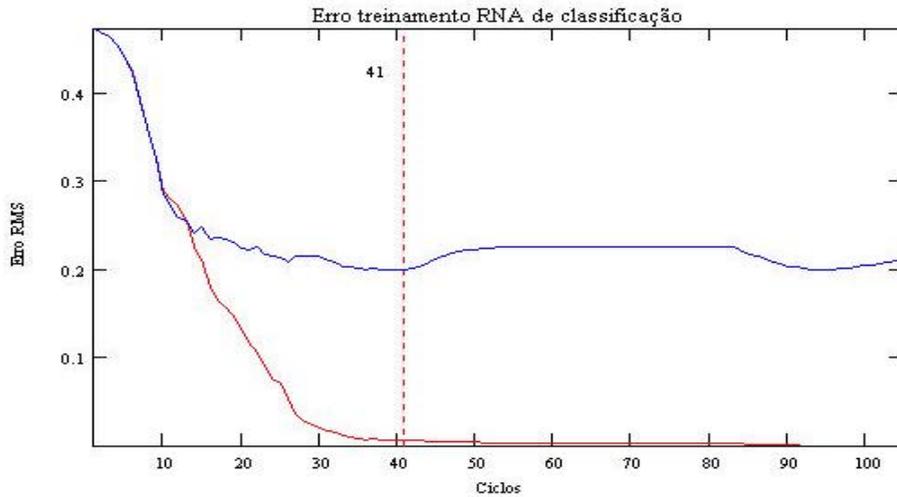


Figura 5.6.4 – Erro médio quadrático para a rede neural de classificação do conjunto de treinamento (curva inferior) e do conjunto de teste (curva superior)

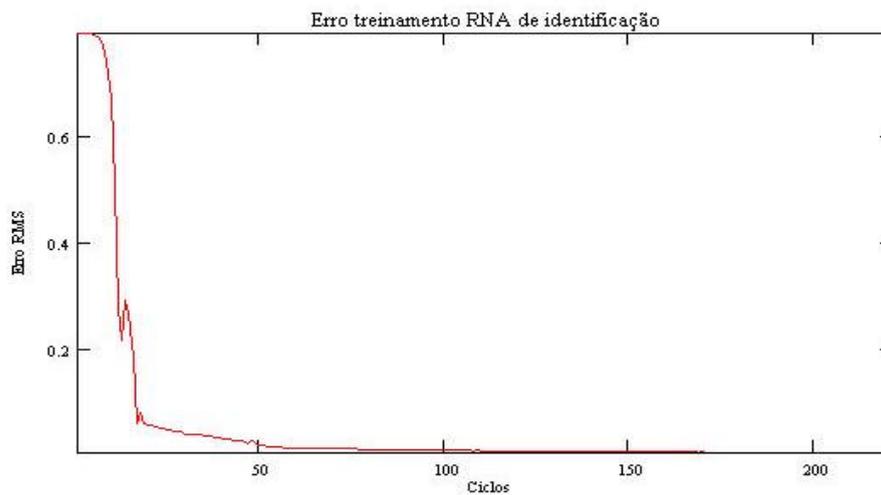


Figura 5.6.5 – Erro médio quadrático para rede neural de identificação do conjunto de treinamento

O número de arquivos testados somam 82. Dentro destes estão os 19 padrões de falha treinados. Isto porque na análise comparativa com o sistema atual adotou-se o mesmo critério.

O procedimento de medição do painel segue a descrição da Seção 2.3. O critério de avaliação do sistema atual é uma comparação do valor lido com um padrão-referência previamente calculado. O sistema compara o padrão medido com o limite determinado para cada modelo. Atingido este limite, o compressor é tido como defeituoso sendo necessário uma avaliação mais detalhada.

Para uma avaliação de TDE foram estipuladas as seguintes definições:

Definição 1 – Todo resultado errado será tido como Falso Aprovado (FA), ou seja, toda falha é prejudicial à avaliação já que o critério de qualidade é apenas “sim” ou “não”.

Definição 2 – Todo compressor bom será um Verdadeiro aprovado (VA).

Definição 3 – Um compressor bom sendo recusado será um Falso Segregado (FS).

As definições acima foram aplicadas em ambos os sistemas de qualidade. Os resultados são apresentados na Tabela 5.6.2.

Tabela 5.6.2 – Resultados da terceira aplicação

Tipo de teste	Taxa de acerto			Sensibilidade	Especificidade	VLPA	VLPS
Critério atual	Compressores bons	98,3%	82,5%	66,7%	98,3%	87,6%	94%
	Compressores ruins	66,7%					
Sistema proposto	100 %			100%	100%	100%	100%

Durante os testes o painel atual rejeitou um compressor bom, justificando o valor de 98,3% para especificidade. A sensibilidade de 66,7% indica a capacidade de um teste detectar compressores com defeito. Isto porque 8 compressores com defeito foram aprovados*. Estes 8 compressores FA são indesejáveis pois irão para o mercado consumidor (Figura 4.8.1). O Valor Preditivo Aprovado (VLPA) calculado é de 87,6%, ou seja, é a probabilidade de um compressor com resultado aprovado não ter a falha. Já a probabilidade de um compressor com um resultado segregado ter a falha é definido pelo Valor Preditivo Segregado que é de 94%.

Por outro lado o sistema proposto para este número de compressores obteve 100% nos índices do TDE, demonstrando sua potencialidade na segregação de falhas em compressores herméticos.

* Estes compressores fazem parte de um lote especialmente construído para os testes, onde sabe-se que existe a presença de uma falha. Durante a produção normal este percentual é bem menor.

5.7 – Análise final dos resultados

De um modo geral a implementação de uma rede neural na identificação de falhas em compressores herméticos é muito satisfatória tendo em vista as aproximações dos padrões de entrada. O uso de uma rede neural de classificação e uma rede de identificação contendo valores binários (0 e 1) nos padrões de entrada aumentou a capacidade de generalização dos resultados. Mesmo que a rede neural de classificação apresente um vetor de saída com uma certa quantidade de incertezas, a rede neural de identificação mostrou sua capacidade em representar os resultados corretamente. Alguns erros cometidos pela rede durante o reconhecimento em sua maioria se deve à pequena confusão entre a identificação dos modos de falha. Estes erros são provenientes da falta de generalização, mas também devido ao uso de padrões muito marginais, confundindo os resultados. Os resultados comparativos entre as três aplicações são apresentados de acordo com a Tabela 5.7.

Tabela 5.7 – Comparação dos resultados

Tipo de teste		Taxa de acerto		Sensibilidade	Especificidade	VLPA	VLPS	
Aplicação 1	Laboratório	100%		100%	100%	100%	100%	
Aplicação 2 (Compressor aberto)	Sistema proposto	97,8%		100%	81,8%	100%	97,5%	
Aplicação 3 (Compressor fechado)	Critério atual	Compressores bons	98,3%	82,5%	66,7%	98,3%	87,6%	94%
		Compressores ruins	66,7%					
	Sistema proposto	100%		100%				
Média do sistema proposto		99,3%		100%	93,9%	100%	99,2%	
Média do critério atual		82,5%		66,7%	98,3%	87,6%	94%	

Embora o valor obtido de 82,5% para a taxa de acerto do critério atual é importante frisar que os compressores fabricados com defeito conhecido para este caso, passariam para o mercado consumidor. Este fato leva a uma perda de qualidade em relação ao sistema proposto, com reflexos nos custos para a empresa e confiança do consumidor. Nota-se ainda, que o número de compressores segregados indevidamente pelo critério atual, na prática é bem inferior. Pois entre os 35.000 compressores produzidos por dia, espera-se apenas 6

ocorrências de falhas. Já para o sistema proposto, entre os 216 compressores testados nas três aplicações, nenhum compressor ruim foi considerado aprovado demonstrando sua capacidade de segregação.

CAPÍTULO VI – CONCLUSÕES

6.1 – Introdução

Neste capítulo serão apresentadas as conclusões referentes ao estudo do reconhecimento de padrões de falhas em compressores herméticos. Para isso, este capítulo está dividido em três seções: A primeira, refere-se às considerações gerais; a segunda trata de algumas observações em relação ao modelo proposto e na terceira, e última, são recomendados estudos futuros dando continuidade a este trabalho.

6.2 – Considerações gerais

A busca pela qualidade dos produtos a um custo reduzido demanda das empresas pesquisas que permitem avaliar um processo produtivo qualitativamente e quantitativamente. O modelo proposto avalia a qualidade centrada no produto, embora este sistema integre também junto à avaliação o processo de fabricação. Espera-se, com isso, que novos fatores como: erros no processo de montagem, equipamentos com excesso de folgas mecânicas e outros, surjam com a otimização do controle de qualidade.

Este sistema integra uma avaliação que atenta para a redução do nível de ocorrências, atuando de forma indireta em toda a linha de produção. Nessa atuação o sistema tende a correlacionar uma falha aos setores de montagem da linha, formando uma espécie de ciclo de qualidade. Relatórios a cada medição são apresentados apontando as possíveis causas que levaram à ocorrência da falha. A ocorrência dentro de qualquer sistema descreve um indicativo do caminho onde demanda-se maiores esforços. Como a ocorrência do defeito reflete, na maioria das vezes, a realidade do processo, a atuação conjunta de processo – falha – operador é indispensável para se assegurar um produto de boa qualidade.

6.3 – Considerações sobre o modelo

O modelo de reconhecimento de padrões apresentou-se apto para detectar e diagnosticar as falhas na montagem de compressores. O desempenho pode diminuir com a inclusão de novos padrões de falha ou com o aumento do número de compressores medidos. Estima-se, um valor próximo de 96 %. Durante este estudo um banco de falhas foi construído com o intuito de abranger o maior número possível de falhas durante a montagem do

compressor. No entanto, se faz necessário um levantamento mais detalhado das falhas. A importância de um melhor mapeamento das variáveis de entrada e saída através do uso de novas técnicas deverá aumentar a detecção através de padrões de entrada mais personalizados e, conseqüentemente, aumentar o desempenho do sistema.

Como descrito no Capítulo 5, os padrões de entrada estão muito marginais podendo confundir os resultados. Mesmo assim, o modelo mostrou-se adequado e poucos erros foram computados. Embora a rede tenha errado alguns modos de falha, conseguiu prever a existência da falha. Nesse ponto do teste é importante a presença de um especialista pois é ele quem dará a palavra final no diagnóstico relativo ao modo de falha. A rede neural é apenas uma ferramenta que deve auxiliar agilmente nas decisões dos resultados, porém não substituir o operador pois espera-se que em algum momento os resultados generalizados por ela venham a ser errôneos. O homem também tende a falhar nas tomadas de decisões, produzindo diagnósticos errados. Modelos como o proposto neste trabalho tendem a auxiliar o operador, deixando-o mais seguro ao dar um diagnóstico.

A utilização de técnicas mais adequadas evidencia estabelecer características mais representativas das falhas pois espera-se que novas classes de falhas surjam no decorrer do tempo, sendo assim necessário um novo treinamento da rede neural. A rede neural com um aprendizado supervisionado não permite a inclusão de novas classes de falhas sem um novo treinamento. Esta é uma limitação do aprendizado supervisionado. Um outro fator a ser considerado é a ocorrência de dois modos de falha consecutivos, embora a probabilidade de ocorrência seja menor, não se pode refutar esta situação. Isto aumentaria a sensibilidade de detecção da rede.

Embora os resultados apresentados sejam promissores, deve-se levar em consideração o número de compressores utilizados para o treinamento e teste que é muito reduzido para uma aplicação comercial. Então, maiores esforços devem ser considerados para se obter um banco de dados mais significativo para um modelo de alta confiabilidade.

6.4 – Trabalhos futuros

Fazer um estudo mais detalhado da linha de montagem, bem como dos equipamentos instalados, verificando suas limitações. Estas informações deverão fazer parte do banco de dados, juntamente com os padrões de falhas gerados pelas deficiências.

Personalizar os padrões de entrada, de modo a diferenciá-los através do uso de novas transformadas, como por exemplo o uso conjunto da FFT com *wavelet*, reduzindo sensivelmente a porcentagem de erros.

Expandir a análise através de redes neurais artificiais para outras etapas do processo como: testes de consumo, pressão, etc.

Estudar o uso de novos tipos de redes e técnicas híbridas que possam traduzir melhor o problema de identificação de padrões e facilitar a interpretação das falhas.

Aprofundar o uso das ferramentas FTA e FMEA na avaliação da confiabilidade do painel de medições, bem como da linha de produção.

REFERÊNCIAS BIBLIOGRÁFICAS

1. ARGOUD, Fernanda Isabel Marques, **Contribuição à automação da detecção e análise de eventos epileptiformes em eletroencefalograma**. 2001. 185 f. Tese de Doutorado – Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis.
2. BILLINTON, Roy, ALLAN, Ronald N., **Reliability evaluation of engineering systems: Concepts and techniques**. 2.ed., Longman Scientific & Technical, 1987, 348 p.
3. BLANCHARD, Benjamin S., VERNA, Dinesh, PETERSON, Elmer L., **Maintainability: A Key to Effective Serviceability and Maintenance Management**. JOHN WILEY & SONS, INC., 1995, 537 p.
4. BRIGHAM, E. Oran, **The Fast Fourier Transform**. New Jersey, Prentice-Hall Inc., 1974, 448 p.
5. BRASIL, Lourdes Mattos, **Proposta de arquitetura para sistema especialista híbrido e a correspondente metodologia de aquisição do conhecimento**. 1999. 256 f. Tese de Doutorado – Engenharia Elétrica, área de concentração em sistemas de informação, Universidade Federal de Santa Catarina, Florianópolis.
6. CONDRA, Lloyd W., **Reliability Improvement with Design of Experiments**. 1.ed., United States of America: Marcel Dekker, Inc, 1993, 370 p.
7. CONTINI, S., **A new hybrid method for Fault Tree Analysis**. Reliability Engineering and System Safety 49, 1995.
8. CRISTALLI, Cristina, Conference at Purdue University, 15, International Compressor Engineering, **A New Automatic System for Quality Control of Compressors on Production Lines**, West Lafayette, USA, AEAs.r.l Italy, 2000, 6 p.
9. DUARTE, Marcos Antônio, curso de pós-graduação, **Redes Neurais**, notas de aula da disciplina redes neurais, Universidade Federal de Uberlândia, Uberlândia, 2000, 224 p.
10. ELLIOTT, Douglas F., RAO, K. Ramamohan, **Fast Transform: Algorithms, Analyses, Applications**. Department of Electrical Engineering the University of Texas at Arlington, Texas, Academic Press, Inc., 1982, 488 p.
11. FILHO, Bráulio Luna, **Utilização Racional dos Testes Diagnósticos em Cardiologia**. 7 f. Escola Paulista de Medicina, área de concentração em Cardiopatia Hipertensiva, Universidade Federal de São Paulo, São Paulo.
12. FILHO, Celso F. Ramos, MARTINS, Fernando S. V., **Solicitação e Interpretação de testes confirmatórios**. 1992, 4 f. Centro de Ciências da Saúde, Disciplina de Doenças Infecciosas e Parasitárias, Universidade Federal de Rio de Janeiro, Rio de Janeiro.
13. IYODA, Eduardo Masato, **Inteligência computacional no Projeto Automático de Redes Neurais Híbridas e Redes Neurofuzzy Heterogêneas**. 2000. Dissertação de Mestrado – Engenharia Elétrica e de Computação (FEEC), Universidade Estadual de Campinas, São Paulo.

14. LOESCH, Cláudio, SARI, Solange Terezinha **Redes Neurais Artificiais Fundamentos e Modelos**. 1.ed., Editora da FURB, Blumenau, 1996, 166 p.
15. M., Oleskovicz, D., Coury V., R., Aggarwal K., **Redes Neurais Artificiais Aplicadas à Classificação Rápida de Falhas em Sistemas Elétricos de Potência**. 2000, 9 f. SBA Controle & Automação Vol. 11 no. 03, Engenharia Elétrica, Universidade de São Paulo, São Carlos.
16. MANCUZO, Mechelangelo Viana, RIBEIRO, Carlos Roberto, DUARTE, Marcos Antônio Viana, Congresso Brasileiro de Engenharia Mecânica, COBEM-XV, **Utilização de Redes Neurais na Identificação de Falhas em Motores de Explosão**, São Paulo 1999, 10 p.
17. MENEZES, Paulo Rossi, **Validade e confiabilidade das Escalas de Avaliação em Psiquiatria**. 1998, 4 f. Faculdade de Medicina, Universidade Federal de São Paulo, São Paulo.
18. ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **Confiabilidade e Manutenibilidade**: NBR 5462. Novembro de 1994, Rio de Janeiro, 1994, 37 p.
19. NETO, Miguel Fiod., **Taguchi e a melhoria da qualidade – Uma releitura crítica**. 1.ed., Florianópolis: Editora da UFSC, 1997, 92 p.
20. NUMA, Conhecimentos Sistematizados pelo NUMA, Disponível em: <http://www.numa.org.br/index.htm>, abril de 2001.
21. PALADY, Paul, **FMEA – Análise dos Modos de Falha e Efeitos – Prevendo e Prevenindo Problemas antes que ocorram**. 1.ed., Ed. IMAM, São Paulo, 1997, 270 p.
22. RAMAKUMAR, R., **Engineering Reliability: Fundaments and Applications**. 1.ed., Rio de Janeiro: Prentice – Hall do Brasil, Ltda, 1993, 482 p.
23. ROSENBLATT, Frank, **The Perceptron: A probabilistic model for information a storage and organization in the brain**. Psychological review, 1958.
24. RITA, Dalva Janine, **Controle de processo usando redes neurais artificiais: Uma aplicação experimental**. 1995. 86 f. Dissertação de Mestrado – Engenharia Química, Universidade Federal de Santa Catarina, Florianópolis.
25. HAYKIN, Simon, **Neural Networks: A Comprehensive foundation**. 2.ed., Prentice-Hall, University Hamilton, Ontario, Canada, 1999, 842 p.
26. SANTOS, Marcelo. , Centro Tecnológico. **Relatório de estágio profissional**. Engenharia Mecânica, LVA – Laboratório de Vibrações e Acústica, Universidade de Santa Catarina Florianópolis, 1999, 42 p.
27. SARI, Solange Terezinha, **Protótipo de um Sistema de Reconhecimento de Padrões Conexionista Híbrido**. 1994. 94 f. Dissertação de Mestrado – Engenharia de Produção Mecânica, Universidade Federal de Santa Catarina, Florianópolis.

28. SAKURADA, Eduardo Yuji, **As técnicas de Análise dos Modos de Falhas e seus Efeitos e Análise da Árvore de Falhas no desenvolvimento e na Avaliação de produtos**. 2001. 124 f. Dissertação de Mestrado – Engenharia Mecânica, Centro Tecnológico, NEDIP – Núcleo de Desenvolvimento Integrado de Produtos, Universidade de Santa Catarina, Florianópolis.
29. STAMATIS, D. H., **Failure Mode and Effect Analysis: FMEA from Theory to Execution**. ASQC Quality Press Milwaukee, Wisconsin, 1995, 494 p.
30. TAFNER, Malcon A., XEREZ, Marcos de, RODRIGUES, Ilson W. filho, **Redes Neurais Artificiais: Introdução e princípios de Neuro Computação**. 1.ed., Blumenau: EKO, Editora da FURB, 1995, 199 p.
31. THOMSON, Willian T., **Theory of Vibration with Applications**. 5.ed., Prentice-Hall Inc., Engle wood cliffs, New Jersey, USA, 1973, 523 p.
32. VAZ, Jerusa Marchi, FARIAS, Terezinha de Fátima, **Algoritmo Rápido de Treinamento para redes Neurais Artificiais**. 1999, 7 f. DAS LCMI, Universidade Federal de Santa Catarina, Florianópolis.
33. VINADÉ, César A. C., Congresso Brasileiro de Gestão de Desenvolvimento de Produto, 3, **FMEA Aplicado no Desenvolvimento de Sistemas Hidráulicos**. Universidade Federal de Santa Catarina, Florianópolis, Setembro, 2001, 8 p.
34. Z. L. Kovács, **Redes Neurais artificiais: Fundamentos e Aplicações**. Escola Politécnica da Universidade de São Paulo, 1996, 174 p.
35. WILSON, Howard B., TURCOTTE, Louis H., **Advanced Mathematics and Mechanics Applications Using MATLAB**. 2.ed., CRC Press, USA, 1997, 632 p.
36. WISBECK, John Oersted, **Técnicas híbridas de processamento de sinais biomédicos implementados com redes neurais artificiais**. 2000. 174 f. Tese de Doutorado – Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis.

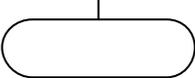
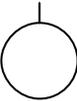
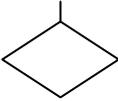
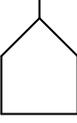
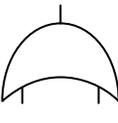
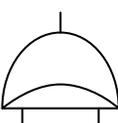
APÊNDICES

**APÊNDICE 1 – SIMBOLOGIA PARA A CONSTRUÇÃO DA ÁRVORE
DE FALHAS**

Simbologia para a construção da Árvore de falhas

Segundo BLANCHARD, (1995), a simbologia para a construção da Árvore de falha é dado pela tabela abaixo.

Tabela A1 – Símbolos construtivos da árvore de falha

<i>Simbologia da árvore de falha</i>	<i>Descrição</i>
	Oval - Representa os eventos de topo.
	Retângulo - Evento representado por uma falha intermediária.
	Círculo - Evento de falhas de nível baixo, também chamadas de falhas básicas
	Losango - Evento não desenvolvido
	Casa – Representa uma entrada (ocorre ou não ocorre a falha).
	E lógico – O evento de saída ocorre somente se todos os eventos de entrada ocorrerem simultaneamente.
	OU lógico – O evento de saída ocorre se qualquer um dos eventos ocorrerem na entrada.
	E PRIORIDADE – O evento de saída ocorre se todos os eventos de entrada ocorrerem em uma ordem predeterminada.
	OU EXCLUSIVO – O evento de saída ocorre se somente uma das entradas ocorrer

**APÊNDICE 2 – RESUMO DAS PRINCIPAIS ARQUITETURAS DE
REDES NEURAS ARTIFICIAIS**

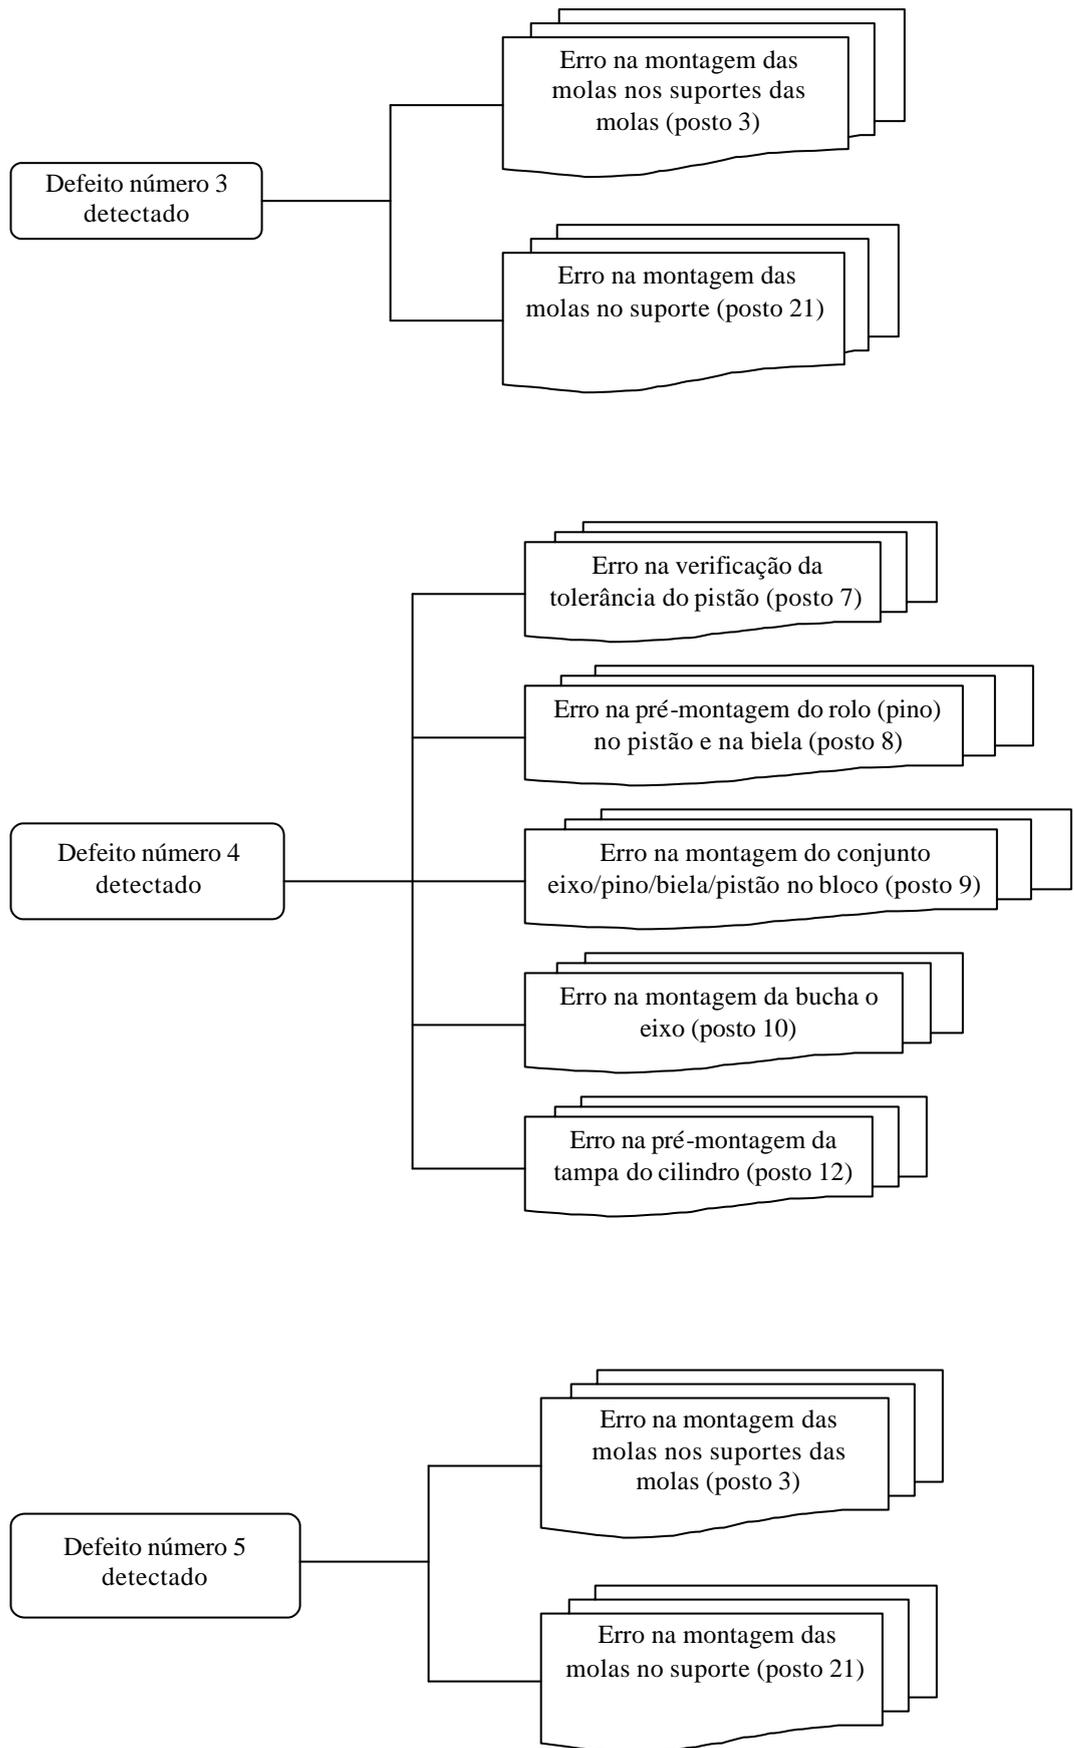
Rede	Ano	Inventores	Aplicação	Vantagens	Desvantagens
ADALINE/MADALINE	1960	B. Widrow	Filtragem de sinal adaptativo; equalização adaptativa	Rápida, fácil de implementar, tanto em circuito analógico como VLSI	Assume relação linear entre entrada e saída desejada. Somente é possível classificar espaços linearmente separáveis
Adaptative Resonance Theory (ART)	1983	G. Carpenter & S. Grossberg	Reconhecimento de padrões	Capaz de aprender novos padrões, de novas categorias de padrões e reter as categorias já aprendidas	Natureza dos exemplos categóricos podem mudar com o aprendizado
Backpropagation Perceptron	1974, 1986	P. J. Werbos, D. Parker, D. Rumelhart	Reconhecimento de padrões, filtragem de sinais, remoção de ruído, segmento de sinal/imagem, classificação, mapeamento, controle robótico adaptativo, compressão de dados	Operação rápida. Boa em formar representações internas das características dos dados de entrada ou classificação e outras tarefas. Bem compreendida, com muitas aplicações de sucesso	Tempo de treinamento longo
Recurrent	1987	Almeida, Pinela	Controle robótico, reconhecimento da fala, previsão do elemento seqüencial	Melhor rede até agora para classificação, mapeamento de informações variando no tempo	Rede complexa, pode ser difícil treinar e otimizar
Time-delay	1987	D. W. Tank & J.J Hopfield	Reconhecimento da fala	Desempenho equivalente aos melhores métodos convencionais, rápida operação	Janela fixada para a atividade temporal representada, responde desastrosamente para diferenças em escala na entrada
Rede de ligações funcionais	1988	Y. H. Pao	Classificação, mapeamento	Somente duas camadas (entrada e saída) são necessárias, rápida para treinar	Não é claro o modo de identificar funções adotadas para ligações funcionais
Redes de funções de base radial	1987, 1988	Múltiplos pesquisadores	Classificação, mapeamento	Uma rede com uma única camada oculta de neurônios é equivalente a rede perceptron multicamadas básico com duas camadas ocultas	Não é bem conhecida ainda
Backpropagation de função utilidade no tempo	1974	P. J. Werbos	Maximiza o índice de desempenho ou a função utilidade no tempo, neurocontrole (robótica)	Abordagem neural mais compreensiva para os modelos de controle e/ou previsão	Pode ser usado somente depois de identificado o modelo diferenciável, adaptação off-line se o modelo é dinâmico e assume que o modelo é exato
BAM – Memória Associativa Bidirecional	1987	B. kosko	Heteroassociativa (memória endereçada por conteúdo)	Simples, regra de aprendizado, arquitetura e dinâmica claras, prova clara da estabilidade dinâmica	Capacidade de armazenamento e precisão de recuperação pobres
Boltzmann Machine, Cauchy Machine	1984, 1986	G. Hinton, T. Sejnowski, D. Ackley, H. Szu	Reconhecimento de padrões (imagem, sonar, radar), otimização	Capaz de formar representação ótima das características dos padrões. Segue superfície de energia para obter otimização no ponto mínimo	A máquina de Boltzmann possui tempo de aprendizado longo, enquanto a máquina de Cauchy oferece aprendizado rápido

Fonte: (SARI et al, 1996) pg. 48.

Brain-State-in-a-box (BSB)	1977	J. Anderson	Revocação autoassociativa	Possivelmente melhor desempenho que a rede Hopfield	Incompleta exploração em termos de desempenho e aplicação em potencial
Hopfield	1982	J. Hopfield	Evocação autoassociativa, otimização	Conceitualmente simples, possui estabilidade dinâmica, de fácil implementação em circuitos VLSI	Incapaz de aprender novos estados (pesos fixados para Hopfield discreta), armazenamento de memória pobre, pode estabilizar em muitos estados espúrios
Quantização do vetor de aprendizagem	1981	T. Kohonen	Revocação autoassociativa (complementação do padrão a um padrão parcial apresentado), compreensão de dados	Capaz de auto-organizar representações vetoriais de distribuições aleatórias em dados apresentados. Execução rápida após treinamento completado	Características não resolvidas na seleção do número de vetores usados e tempo de treinamento apropriado. Treinamento lento
Neocognitron	1975, 1982	K. Fukushima	Reconhecimento de caracteres manuscritos e outras figuras	Capaz de reconhecer padrões independente da escala, translação e rotação	Requer muitos neurônios e camadas, estrutura complexa, medida de escala para palavras é um problema ainda não resolvido
Mapas de preservação da topologia de auto-organização	1981	T. Kohonen	Mapeamentos complexos (envolvendo relações e vizinhança), compreensão de dados, otimização	Capaz de auto-organizar representações vetoriais de dados com uma ordenação significativa entre as representações	Características não resolvidas na seleção do número de vetores usados e tempo de treinamento apropriado. Treinamento lento

Tabela A2 – Resumo das primeiras arquiteturas de redes neurais artificiais
 Fonte: (SARI et al, 1996) pg. 48.

APÊNDICE 3 – ÁRVORES DE FALHA



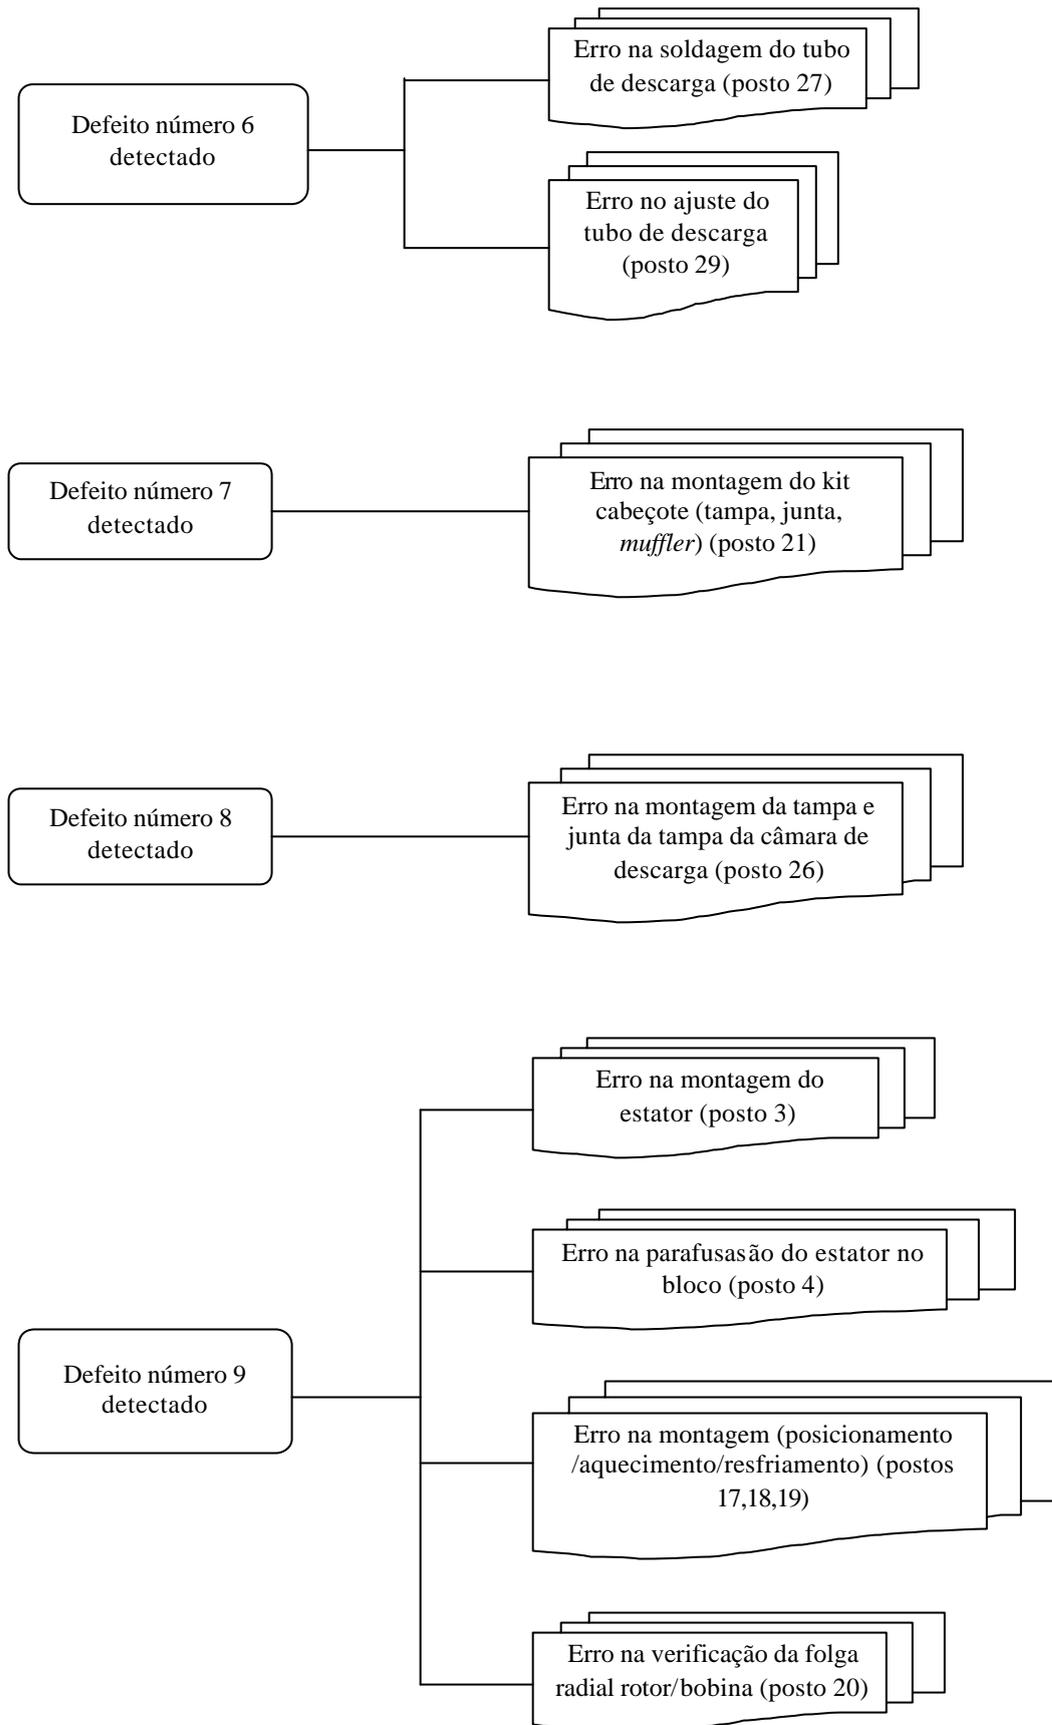


Figura A3 – Árvores de falha dos principais modos de falha