

UNIVERSIDADE FEDERAL DE SANTA CATARINA

Programa de Pós-Graduação em Metrologia Científica e Industrial

Pedro Henklein

**ANÁLISE DE ENSAIOS DE DESEMPENHO DE
COMPRESSORES HERMÉTICOS DURANTE O
TRANSITÓRIO**

Dissertação submetida à Universidade Federal de Santa Catarina
para obtenção do grau de Mestre em Metrologia

Orientador: Carlos Alberto Flesch, Dr Eng.

Florianópolis, 22 de setembro de 2006

ANÁLISE DE ENSAIOS DE DESEMPENHO DE COMPRESSORES HERMÉTICOS DURANTE O TRANSITÓRIO

Pedro Henklein

Esta dissertação foi julgada adequada para a obtenção do título de

“MESTRE EM METROLOGIA”

e aprovada na sua forma final pelo

Programa de Pós-Graduação em Metrologia Científica e Industrial

Prof. Carlos Alberto Flesch, Dr. Eng.

ORIENTADOR

Prof. Marco Antônio Martins Cavaco, Ph. D

COORDENADOR DO PROGRAMA DE PÓS-GRADUAÇÃO

BANCA EXAMINADORA:

Prof. Armando Albertazzi Jr, Dr. Eng.

Prof. Arcanjo Lenzi, Ph. D.

Prof^a Jacqueline Gisèle Rolim. Dr^a. Eng.

Marco Aurélio de Oliveira, M. Sc.

Ao meu pai, Everlindo

À minha mãe, Regina

A minhas irmãs, Joana e Isabel

À minha namorada, Clarice

AGRADECIMENTOS

Especialmente aos meus pais, Everlindo e Regina, pelo apoio e amor incondicional em todos os momentos da minha vida.

Ao professor Carlos Alberto Flesch, por quem tenho grande amizade, admiração e respeito, pela orientação neste trabalho.

À minha namorada e minhas irmãs pela companhia, compreensão e amor, sempre presentes.

A Deus, pela onipresença, mesmo nos momentos mais difíceis.

Aos membros da banca, Jacqueline, Armando, Marco e Arcanjo, pelas contribuições.

Aos professores e funcionários do Programa de Pós-graduação de Metrologia Científica e Industrial, pela oportunidade a mim concedida de poder ampliar meus conhecimentos.

A todos os amigos de mestrado e Labmetro, de Curitiba e Florianópolis pela grande amizade.

À UFSC e PósMCI por me concederem a oportunidade de realização do mestrado.

À Embraco pela oportunidade e pelo apoio concedido na realização da dissertação.

Por fim, a todos que direta ou indiretamente contribuíram para que este trabalho pudesse ser concretizado.

SUMÁRIO

LISTA DE ILUSTRAÇÕES.....	8
LISTA DE TABELAS	11
LISTA DE ABREVIATURAS.....	12
LISTA DE SÍMBOLOS.....	13
RESUMO.....	14
ABSTRACT.....	15
1 INTRODUÇÃO	16
1.1 CONTEXTUALIZAÇÃO.....	16
1.2 OBJETIVO DA DISSERTAÇÃO.....	18
1.3 ESTRUTURA DA DISSERTAÇÃO.....	19
2 ENSAIOS DE DESEMPENHO DE COMPRESSORES HERMÉTICOS	21
2.1 COMPRESSORES HERMÉTICOS PARA REFRIGERAÇÃO	21
2.1.1 Circuito de refrigeração.....	22
2.1.2 Princípio de funcionamento do compressor recíproco alternativo hermético.....	24
2.2 CARACTERIZAÇÃO DOS ENSAIOS DE DESEMPENHO	26
2.2.1 Objetivo dos ensaios	26
2.2.2 Bancada de ensaios.....	27
2.2.3 Métodos de ensaio.....	29
2.2.4 Requisitos gerais para os ensaios	34
3 TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL	37
3.1 INTRODUÇÃO AO CONCEITO DE INTELIGÊNCIA ARTIFICIAL.....	37
3.2 REDES NEURAIS	38
3.2.1 Modelo geral de neurônio.....	39
3.2.2 Arquiteturas neurais	41
3.2.3 Aprendizado	42

3.2.4 Tipos de Redes Neurais Artificiais	43
3.3 LÓGICA NEBULOSA (LÓGICA <i>FUZZY</i>).....	49
3.3.1 Conjuntos nebulosos.....	50
3.3.2 Função de pertinência.....	51
3.3.3 Operações com conjuntos nebulosos	52
3.3.4 Raciocínio nebuloso	53
4 ESTRUTURAÇÃO DO SISTEMA NEURAL DE ENSAIO	57
4.1 IDENTIFICAÇÃO DAS GRANDEZAS ANALISADAS	57
4.2 ADEQUAÇÃO DO SISTEMA À UTILIZAÇÃO DAS TÉCNICAS DE IA.....	61
4.2.1 Mudanças no programa (software)	61
4.2.2 Melhorias na automação da bancada	61
4.2.3 Desenvolvimento dos novos sistemas de medição.....	65
4.3 SELEÇÃO DAS GRANDEZAS ANALISADAS	72
4.3.1 Temperatura.....	73
4.3.2 Pressão	74
4.3.3 Fluxo de massa e capacidade instantânea de refrigeração	75
4.3.4 Grandezas elétricas	75
4.3.5 Vibração	76
4.3.6 Quantidade de óleo no separador.....	77
4.4 SELEÇÃO DA RNA MAIS ADEQUADA	78
5 DESENVOLVIMENTO DO MÓDULO NEURAL DE ENSAIO.....	81
5.1 ENSAIOS REALIZADOS PARA TREINAMENTO DA REDE	81
5.1.1 Leituras do transitório (ensaios de treinamento)	82
5.1.2 Resultados dos ensaios de treinamento	88
5.2 UTILIZAÇÃO DA LN COMO FERRAMENTA DE AUXILIO ÀS RNA	89
5.2.1 Utilização de LN durante o treinamento das RNA.....	90
5.2.2 Utilização de LN para execução das RNA	92

5.3 PROGRAMAÇÃO DAS REDES NEURAIS	94
6 RESULTADOS OBTIDOS	98
6.1 TESTES REALIZADOS COM AS REDES E DEFINIÇÕES DOS PARÂMETROS DO SISTEMA.....	98
6.1.1 Dados de entrada.....	98
6.1.2 Parâmetros das RNA	101
6.2 AVALIAÇÃO DO SISTEMA NEURAL DE ENSAIOS	104
6.2.1 Ensaios para avaliação	105
6.2.2 Classificação	106
6.2.3 Análise dos dados obtidos e avaliação numérica	108
7 CONCLUSÕES	123
7.1 TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL	123
7.2 GRANDEZAS MEDIDAS E ADEQUAÇÃO DO SISTEMA	124
7.3 ENSAIOS REALIZADOS.....	125
7.4 AVALIAÇÃO DO SISTEMA NEURAL DE ENSAIOS E REDUÇÃO DO TEMPO DE ENSAIO.....	126
7.5 OPORTUNIDADES FUTURAS	128
REFERÊNCIAS BIBLIOGRÁFICAS	130

LISTA DE ILUSTRAÇÕES

Figura 1.1 - Regime transitório e permanente.....	19
Figura 2.1 – Compressor alternativo hermético.	22
Figura 2.2 - Circuito básico de refrigeração.	23
Figura 2.3 – Princípio de funcionamento do compressor recíproco alternativo [11].	25
Figura 2.4 – Bancada de ensaio de compressores.....	28
Figura 2.5 – Diagrama do circuito (método C) [4].	31
Figura 2.6 – Diagrama do circuito (método F) [4].	33
Figura 2.7 – Transitório e regime permanente.	36
Figura 3.1 - Modelo geral de neurônio.	39
Figura 3.2 – Funções de transferência.....	40
Figura 3.3 – Neurônio da camada padrão [25].	44
Figura 3.4 - Perceptron	46
Figura 3.5 – Rede MLP.	47
Figura 3.6 – Formulação matemática.....	48
Figura 3.7 – Exemplos de funções de pertinência.	52
Figura 3.8 – Sistema nebuloso.....	53
Figura 4.1 – Pontos para medição de temperatura da carcaça.	59
Figura 4.2 – Medição de vibração.	60
Figura 4.3 – Controle da pressão de sucção.	63
Figura 4.4 – Situação anterior do controle de temperatura de saída do evaporador.....	63
Figura 4.5 – Situação atual do controle de temperatura de saída do evaporador.....	64
Figura 4.6 – Medição de temperatura com controlador Eurotherm.....	65
Figura 4.7 – Sistema de medição de temperatura implementado.....	67
Figura 4.8 – Acelerômetro para medição de vibração.....	69
Figura 4.9 – Visor de líquido e “gotejador”.	70

Figura 4.10 – Sistema de medição da quantidade de óleo.....	71
Figura 4.11 – Imagem do processamento da gota.....	71
Figura 4.12 – Circuito para medição das componentes harmônicas de corrente.....	72
Figura 4.13 – Estrutura do sistema neural de ensaio.....	78
Figura 4.14 – Neurônios dinâmicos.....	79
Figura 5.1 – Gráfico das temperaturas da carcaça (BD-01).....	82
Figura 5.2 - Gráfico das temperaturas da carcaça (BD-08).	83
Figura 5.3 – Gráfico do fluxo mássico (BD-05 e BD-06).	84
Figura 5.4 – Potência dissipada nas resistências do calorímetro.	84
Figura 5.5 – Gráfico da corrente que circula pelo compressor.....	85
Figura 5.6 – Harmônicas de corrente BD-07 ensaio 3.	85
Figura 5.7 - Harmônicas de corrente BD-04 ensaio 1	86
Figura 5.8 – Potência consumida pelo compressor.	87
Figura 5.9 – Vibração medida no compressor.	87
Figura 5.10 – Uso de lógica nebulosa durante o treinamento da rede.....	90
Figura 5.11 – Nebulização para capacidade de refrigeração.....	91
Figura 5.12 – Nebulização para consumo de potência ativa.....	91
Figura 5.13 – Uso de lógica nebulosa durante a execução da rede.	93
Figura 5.14 – Programa de execução das redes.	94
Figura 5.15 – Programa de treinamento das redes.....	95
Figura 5.16 – Estrutura dos dados de entrada.....	96
Figura 5.17 – Estrutura dos dados de saída.	96
Figura 6.1 – Janela de tempo para o treinamento da rede de consumo.....	101
Figura 6.2 – Janela de tempo para o treinamento da rede de capacidade.....	101
Figura 6.3 – Configuração final da rede de capacidade.....	103
Figura 6.4 – Configuração final da rede de consumo.	104
Figura 6.5 – Classificação dos resultados de capacidade de refrigeração.	107
Figura 6.6 – Classificação dos resultados de consumo de potência ativa.	108
Figura 6.7 – Saída da RNA de capacidade para o ensaio BD-03.2.....	109

Figura 6.8 - Saída filtrada da RNA de capacidade para o ensaio BD-03.2.	110
Figura 6.9 – Saída do sistema neural para a capacidade do ensaio BD-03.2. ...	111
Figura 6.10 – Saídas da RNA de capacidade para todos os ensaios.	112
Figura 6.11 – Saída filtrada da RNA para todos os ensaios.	113
Figura 6.12 – Saídas do sistema neural para todos os ensaios.	114
Figura 6.13 – Saída do sistema neural para o ensaio BD-06.4.	115
Figura 6.14 – Saída da RNA de consumo de potência ativa para o ensaio BD-03.2.	116
Figura 6.15 – Saída do sistema neural para consumo do ensaio BD-03.2.	117
Figura 6.16 – Saídas da RNA de consumo para todos os ensaios.	118
Figura 6.17 – Saídas filtradas da RNA de consumo para todos os ensaios.	119
Figura 6.18 – Saídas do sistema neural de consumo para todos os ensaios.	120

LISTA DE TABELAS

Tabela 3.1 - Operações Nebulosas.....	53
Tabela 4.1 – Medições normais.	58
Tabela 4.2 – Medições adicionais.	59
Tabela 4.3 – Incertezas finais dos sistemas de medição de temperatura associadas a cada transdutor.	67
Tabela 4.4 – Frequências centrais segundo a ISO.	69
Tabela 4.5 – Classificação das variáveis de temperatura.	74
Tabela 4.6 - Classificação das variáveis de pressão.	75
Tabela 4.7 - Classificação das variáveis de fluxo de massa e capacidade de refrigeração.	75
Tabela 4.8 - Classificação das grandezas elétricas.	76
Tabela 4.9 - Classificação das variáveis de vibração.....	77
Tabela 5.1 – Resultado dos ensaios de treinamento.	88
Tabela 5.2 - Resultado do processo de nebulização.	92
Tabela 5.3 – Resultados do sistema neural de ensaio.	93
Tabela 6.1 – Resultados dos ensaios de avaliação.	106
Tabela 6.2 – Resultados da classificação para capacidade de refrigeração.	114
Tabela 6.3 - Resultados da classificação para consumo de potência ativa.	120
Tabela 6.4 – Desempenho do sistema.	121

LISTA DE ABREVIATURAS

IA	<i>Inteligência Artificial</i>
LN	<i>Lógica Nebulosa</i>
RNA	<i>Rede Neural Artificial</i>
MNE	<i>Módulo neural de ensaios</i>
SNE	<i>Sistema neural de ensaios</i>
MLP	<i>Perceptron multicamadas (Multi Layer Perceptron)</i>
COP	<i>Coeficiente de desempenho</i>
PID	<i>Proporcional Integral Derivativo</i>

LISTA DE SÍMBOLOS

Φ_0 - capacidade de refrigeração do compressor.

P - potência ativa consumida pelo compressor.

η_i - eficiência isentrópica.

ε - coeficiente de desempenho.

q_{mf} - fluxo de massa de refrigerante.

ϕ_i - quantidade de calor cedido pela fonte de alimentação variável.

F_l - fator de perda do calorímetro.

T_a - temperatura ambiente.

T_g - temperatura interna do calorímetro.

h_{g2} - entalpia do gás saturado saindo do calorímetro.

h_{f2} - Entalpia do líquido entrando no calorímetro.

E_i - entradas da RNA.

w_i - pesos das conexões.

Φ - função de combinação do neurônio.

η - função de transferência do neurônio.

y - saída do neurônio.

θ - bias ou polarização do neurônio.

RESUMO

Para acompanhar a evolução dos sistemas de refrigeração são necessários métodos adequados de avaliação de produto. Dentre os ensaios executados com compressores herméticos para refrigeração, encontram-se, com grande importância, os ensaios de desempenho, que tem como principal finalidade estabelecer a capacidade de refrigeração, o consumo de potência ativa do compressor e o coeficiente de desempenho.

Atualmente as limitações dos ensaios de desempenho correspondem ao custo elevado da infra-estrutura e ao longo período de ensaio. O objetivo desta dissertação é verificar a viabilidade do método proposto à inferência de características de regime permanente durante o período transitório, diminuindo o tempo de ensaio.

Foi realizada uma completa estruturação do método de ensaio, incluindo o estudo das variáveis medidas e dos métodos envolvidos, adequações do sistema atual de ensaios ao novo método e a definição dos parâmetros de entrada e saída do sistema de inferência.

Decorrente da complexidade da análise dos dados no transitório e a ausência de regras explícitas para tal tarefa, para realizar a inferência das características de regime permanente do compressor foram utilizadas redes neurais artificiais. São descritos no decorrer do trabalho o treinamento e a avaliação do sistema neural desenvolvido.

A redução do tempo médio de ensaio foi significativa e a confiabilidade dos resultados mantida. A aplicação da solução proposta irá possibilitar o aumento do número de ensaios realizados dentro das indústrias.

ABSTRACT

In order to follow the evolution of the refrigeration systems, it is essential to develop suitable methods of product evaluation. Specifically, when talking about hermetic compressors, performance tests have been highlighted as one of the most important evaluation tests. The purpose of this test is to determine the refrigerating capacity, the compressor electrical power and the coefficient of performance.

Nowadays the performance tests are limited by the elevated infrastructure costs and the long test time. The aim of this thesis is to verify the feasibility of the proposed method to infer steady state compressor characteristics during the transient, reducing the average test time.

A full development of the test method has been done, including a study of measured variables and involved methods, system adequacies to the new test procedure and delimitation of input and output system parameters.

Due to the complexity of the transient data analysis and the absence of explicit rules for this task, artificial neural networks were employed to infer the steady state characteristics of the compressor. The neural system training and its evaluation are described on the thesis.

The average test time has been significantly reduced and the results reliability maintained. The application of the proposed solution will enable industry to increase the number of tests performed.

1 INTRODUÇÃO

A medida que os processos industriais e os produtos evoluem é necessário que os meios e métodos de avaliação da produção estejam aptos a identificar as melhorias implementadas. Na indústria de sistemas de refrigeração dentre os ensaios de avaliação de produto com maior importância estão os ensaios de desempenho de compressores herméticos.

Atualmente dois fatores limitam o número de ensaios de desempenho realizados: o custo elevado das bancadas e o tempo de duração. A problemática abordada nesta dissertação está relacionada com a duração dos ensaios. Os resultados desses ensaios são calculados a partir dos dados de regime permanente e grande parte do tempo é despendida durante o transitório. A opção proposta neste trabalho para diminuir o tempo médio dos ensaios é analisar os dados de transitório e realizar a inferência dos parâmetros de regime permanente através de redes neurais artificiais (RNA).

Com o intuito de facilitar a compreensão, a introdução é dividida em três partes: contextualização; objetivo da dissertação; estrutura do documento.

1.1 CONTEXTUALIZAÇÃO

Os sistemas de refrigeração se mostraram ao longo do tempo essenciais para uma série de atividades desenvolvidas pelo homem, como a conservação de alimentos e medicamentos, condicionamento de ar e procedimentos médicos. Não existe atividade industrial, comercial, agrícola, de produção ou manufatura, de serviço ou utilidade, que não dependa, direta ou indiretamente, do uso da refrigeração [1].

A maioria dos sistemas de refrigeração se baseia no princípio de compressão e expansão de fluido com mudança de fase. Dentro desses sistemas o compressor tem papel destacado por ser o elemento ativo que força a circulação do fluido [1], [2].

O princípio descrito no parágrafo anterior acompanhou toda a história dos sistemas e compressores de refrigeração, sendo os primeiros desenvolvidos por volta dos anos de 1860 a 1875. O princípio não mudou até hoje, mas, em função de diversas exigências de mercado impostas pelos consumidores, os fabricantes executaram muitas melhorias construtivas [2], [3].

Para identificar e quantificar essas melhorias é necessário analisar uma série de parâmetros do compressor, obtidos através de ensaios específicos. Dentre esses ensaios, encontram-se os ensaios de desempenho, cujo objetivo é determinar a capacidade de refrigeração, a potência elétrica ativa consumida, a eficiência isentrópica e o coeficiente de desempenho, com o compressor sob condições preestabelecidas [4].

Além da identificação das melhorias, existem outras razões para determinação dos quatro parâmetros obtidos nesse tipo de ensaio [5]:

- permitir a correta aplicação do sistema de refrigeração, através dos dados obtidos nos ensaios;
- fornecer dados para a conexão adequada dos elementos de um sistema de refrigeração;
- detectar tendências durante o processo de fabricação;
- comparar dados entre fabricantes.

De acordo com o descrito, os ensaios de desempenho mostraram-se de extrema importância e são executados com uma frequência grande dentro de uma indústria de compressores. O problema envolvido com esses ensaios é o tempo característico a eles, o que prejudica o número de execuções ou exige um investimento muito alto em infra-estrutura [1].

O número menor de execuções força a diminuição da amostra para a análise estatística de controle de qualidade, o que acarreta em diminuição da segurança estatística fornecida. Na área de pesquisa e desenvolvimento a limitação de ensaios resulta em falta de agilidade na avaliação das melhorias implementadas [6],[7].

Os ensaios de desempenho de compressores, dos quais pretende-se diminuir o tempo de duração, são baseados na norma ISO 917 - *Testing of Refrigerant Compressors* [4]. Essa norma estabelece que os resultados finais de capacidade de refrigeração, potência elétrica ativa consumida, eficiência isentrópica e coeficiente de desempenho devem ser calculados com base nos dados de regime permanente. O regime permanente é caracterizado por um período contínuo de 1 h de operação em que algumas variáveis específicas possuem valores centrais e limites de variação em valores estabelecidos. O restante do tempo de ensaio é denominado, no âmbito deste trabalho, período transitório [4].

Atualmente, segundo dados obtidos junto à empresa fabricante de compressores (EMBRACO) e a laboratórios específicos de realização deste tipo de ensaio, o tempo médio de um ensaio é de aproximadamente 4 h. Desse tempo, perto de 3 h são destinadas ao transitório e 1 h ao regime permanente. As principais causas do tempo elevado de transitório estão associadas à inércia térmica do compressor e dos componentes do sistema de refrigeração e aos procedimentos de controle das variáveis [5].

1.2 OBJETIVO DA DISSERTAÇÃO

O objetivo desta dissertação de mestrado é verificar a viabilidade da aplicação do método proposto à inferência de características de regime permanente durante o transitório em ensaios de desempenho de compressores herméticos de refrigeração. A solução proposta deve reduzir o tempo de ensaio sem comprometer a confiabilidade dos resultados.

Devido à complexidade da análise dos dados no transitório e à ausência de regras explícitas para tal tarefa, optou-se, como meio de solução, pela utilização de redes neurais artificiais (RNA). Essa ferramenta é empregada para analisar as medições realizadas durante o transitório dos ensaios e tirar conclusões quanto ao comportamento do compressor em regime permanente (Figura 1.1) [8].

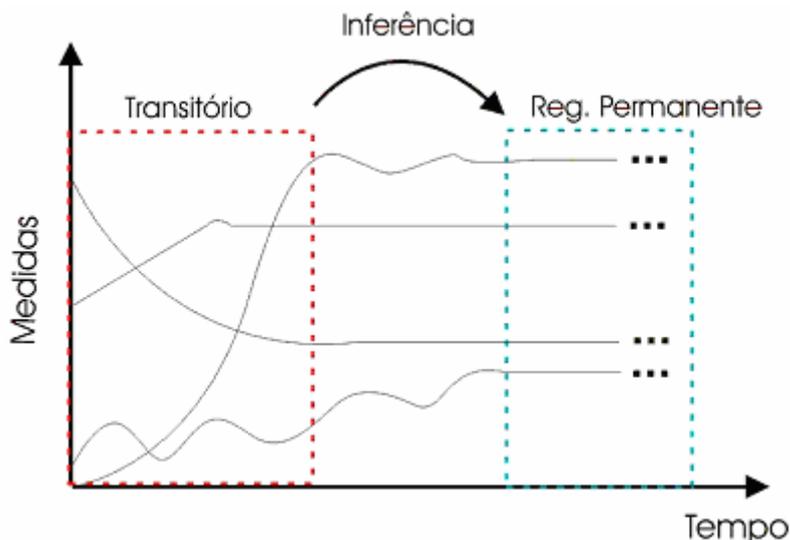


Figura 1.1 - Regime transitório e permanente.

Como a maior parte do tempo de ensaio é despendida durante o transitório, as redes neurais analisam os dados provenientes desse período e encerram os ensaios sem a necessidade de se atingir o regime permanente.

Não foram identificadas na literatura referências que servissem de base para a pesquisa desenvolvida, assim, foi necessária a realização de um trabalho com caráter investigativo que resultasse em um completo método de ensaio. Esse trabalho incluiu as tarefas: estudo e definição das medições realizadas; adequação do sistema atual de ensaios a aplicação das ferramentas de inteligência artificial; desenvolvimento do módulo de diagnóstico dos ensaios.

Como o objetivo é verificar a viabilidade da aplicação do método, a dissertação se baseia no estudo de um modelo de compressor e propõe a extrapolação para os demais modelos. O método proposto deve ser aplicado a testes internos da indústria, pelo fato de não cumprir todos os requisitos das normas da área. Para testes de comparação entre fabricantes os procedimentos normativos devem continuar sendo seguidos [4].

1.3 ESTRUTURA DA DISSERTAÇÃO

A dissertação foi estruturada em sete capítulos, procurando facilitar a compreensão com uma divisão clara dos assuntos abordados.

No capítulo 2 é realizada uma revisão bibliográfica a respeito dos ensaios de desempenho de compressores herméticos, incluindo uma breve explicação sobre sistemas de refrigeração e compressores herméticos, além da caracterização dos ensaios de desempenho.

O capítulo 3, ainda no âmbito da revisão bibliográfica, sintetiza-se um estudo das técnicas de inteligência artificial, dando ênfase a redes neurais artificiais e lógica nebulosa, uma vez que essas correspondem às técnicas utilizadas no desenvolvimento do trabalho.

O capítulo 4 apresenta as atividades necessárias para estruturar o sistema neural de ensaios. Essas atividades, anteriores ao desenvolvimento do módulo de diagnóstico dos ensaios, preparam os dados, fazem a adequação do sistema atual e definem parâmetros importantes, tais como o tipo de rede neural utilizado e quais as variáveis de entrada.

As atividades envolvidas com o treinamento e programação das redes neurais para diagnósticos dos ensaios no transitório estão apresentadas no capítulo 5. Nesse capítulo também se encontram as descrições dos ensaios realizados e da utilização de lógica nebulosa.

Os resultados obtidos no trabalho são descritos no sexto capítulo, incluindo a avaliação do sistema neural de ensaios através dos ensaios específicos para tal tarefa.

No capítulo 7 são estabelecidas as conclusões da dissertação e propostas as oportunidades para continuidade do projeto.

2 ENSAIOS DE DESEMPENHO DE COMPRESSORES HERMÉTICOS

O compressor hermético representa o principal elemento do sistema de refrigeração e o seu desempenho depende de muitos aspectos construtivos. Para a correta determinação do desempenho são realizados ensaios em bancadas específicas, que buscam determinar a capacidade de refrigeração, a potência elétrica ativa consumida, a eficiência isentrópica e o coeficiente de desempenho [4].

Neste capítulo estão expostos alguns conceitos sobre compressores herméticos para refrigeração e descritos os ensaios de desempenho realizados com estes.

2.1 COMPRESSORES HERMÉTICOS PARA REFRIGERAÇÃO

O compressor é responsável por forçar a circulação do fluido no sistema de refrigeração e pode ser apresentado em diferentes configurações. Em relação aos aspectos construtivos, os compressores de refrigeração podem ser divididos em recíprocos alternativos e rotativos. Os alternativos podem ser novamente classificados em abertos, semi-herméticos e herméticos [1], [2].

O compressor recíproco alternativo hermético tem o motor e a unidade compressora montados em um mesmo eixo, os quais são instalados dentro de um corpo de aço, cuja tampa é soldada hermeticamente após a montagem do conjunto [1]. Os motores utilizados nos compressores são motores de indução, assíncronos, monofásicos e de dois pólos [9]. Os compressores abordados nesta dissertação são compressores recíprocos alternativos herméticos, cujo desenho indicando as diversas peças que o compõem está na figura 2.1.

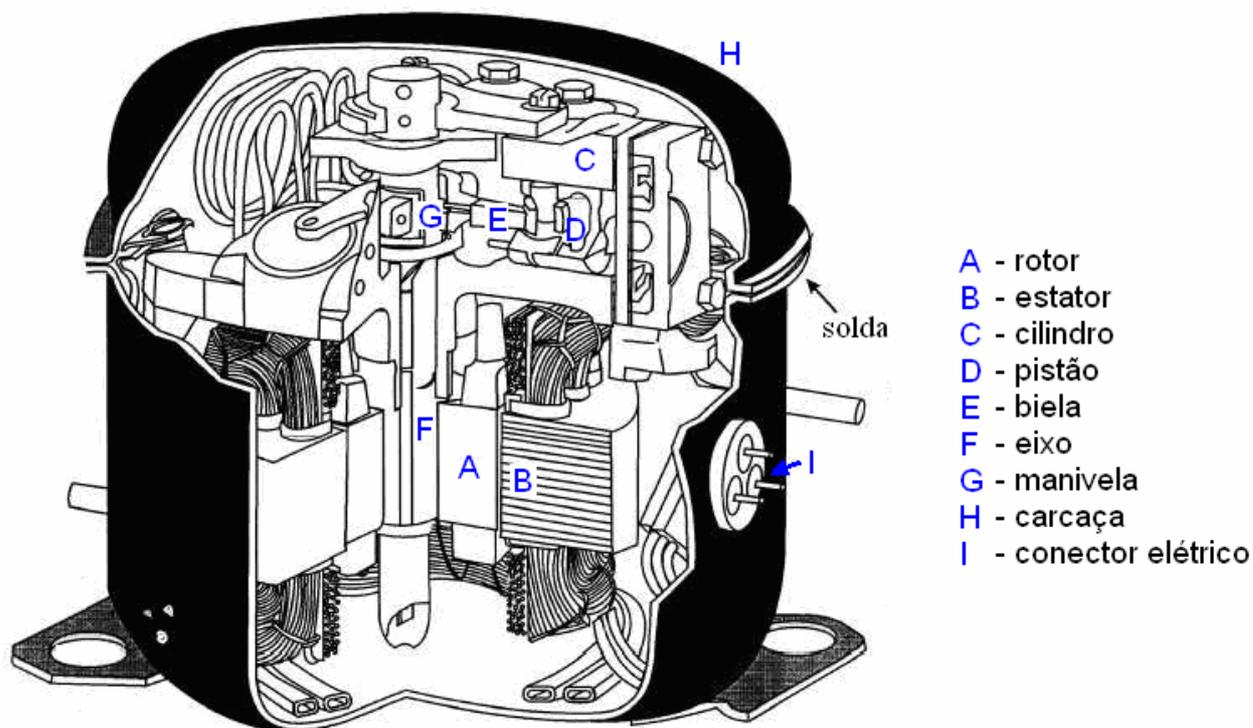


Figura 2.1 – Compressor alternativo hermético.

Para dar continuidade ao assunto, nos itens 2.1.1 e 2.1.2, são descritos o circuito de refrigeração e o princípio de funcionamento dos compressores recíprocos alternativos herméticos.

2.1.1 Circuito de refrigeração

O objetivo de um sistema de refrigeração é a transferência de calor de um volume de contorno para outro, ocasionando uma diferença de temperatura entre os dois ambientes. Para tal fim é necessário um conjunto de equipamentos arranjados de forma adequada, o que é chamado de um circuito de refrigeração (Figura 2.2) [2], [10].

Para realizar a transferência de calor através do circuito de refrigeração utiliza-se uma substância com características específicas, chamada de agente ou fluido refrigerante. A capacidade de absorção ou liberação de calor é muito maior na troca de fase e cada refrigerante possui diferentes temperaturas de evaporação e condensação, por isso para cada aplicação deve ser utilizado um tipo de refrigerante de acordo com o projeto [9].

De um circuito para outro podem existir pequenas diferenças, pela inclusão de alguns componentes ou pela simples troca. Porém alguns itens básicos estão sempre

presentes, fornecendo a possibilidade da montagem de um circuito básico de refrigeração, como mostrado na figura 2.2 [9], [10]:

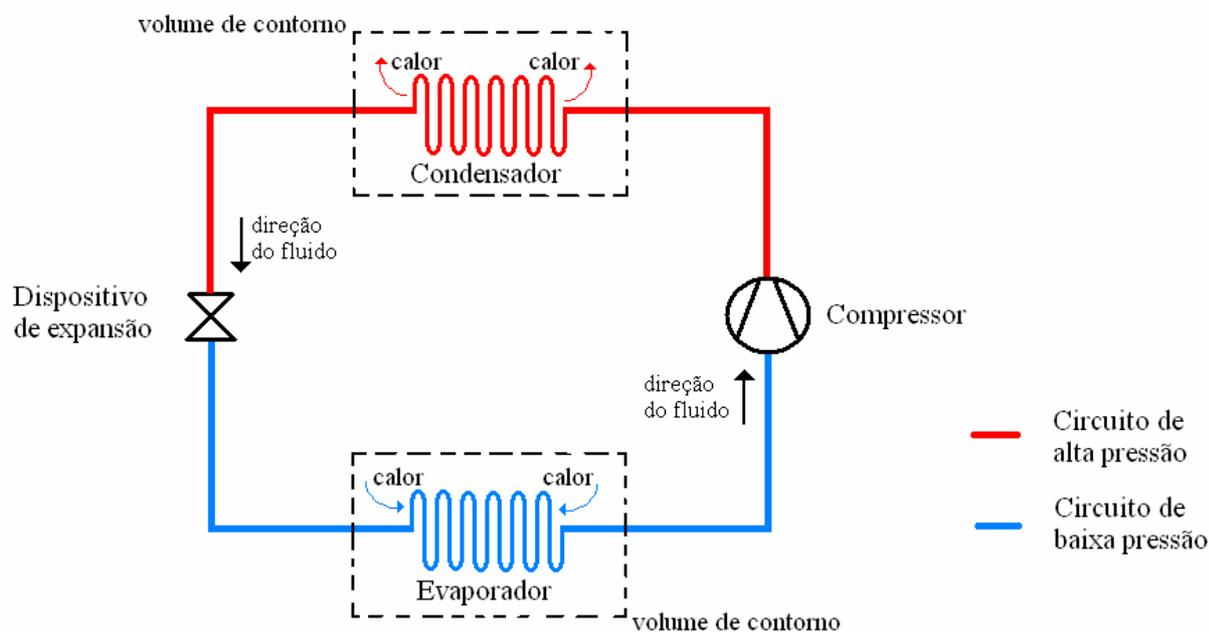


Figura 2.2 - Circuito básico de refrigeração.

O compressor succiona do evaporador fluido refrigerante na forma gasosa sob baixa pressão e o descarrega no condensador, ainda na forma gasosa, sob alta pressão (processo de compressão). Logo a seguir, no condensador, o gás é condensado, liberando o calor absorvido no evaporador e durante a compressão. O refrigerante, agora líquido, passa pelo dispositivo de expansão (tubo capilar ou válvula de expansão), cuja função é descomprimir o líquido da pressão de condensação para a pressão de evaporação. Essa redução de pressão provoca, no evaporador, a evaporação do refrigerante, absorvendo o calor do volume de contorno a ser refrigerado. Para garantir o bom funcionamento do compressor o fluido admitido pelo compressor deve estar completamente na fase gasosa, o que faz com que alguns circuitos realizem a inserção de um acumulador logo após o evaporador [10].

Quanto mais rápido o compressor succionar o refrigerante em forma gasosa, do evaporador, menor será a pressão e a temperatura nesse ambiente. Isso significa que a capacidade do circuito depende não somente do volume de refrigerante, mas também da velocidade de circulação, isto é, a massa de refrigerante por unidade de tempo (fluxo mássico) [1], [10].

A pressão do fluido é controlada por dois elementos, o compressor e o dispositivo de expansão, que dividem o circuito em um lado de alta pressão (condensador) e um de baixa pressão (evaporador). Esta divisão pode ser vista na figura 2.2 e na figura 2.4 [10].

O dispositivo de expansão oferece resistência à circulação de fluido, fazendo com que a pressão diminua. O tubo capilar geralmente é utilizado em sistemas de pequeno e médio porte; já a válvula de expansão em circuitos de grande porte. O compressor tem a função de forçar a circulação de refrigerante (aumentar a pressão) e seu funcionamento será descrito no item 2.1.2 [9].

2.1.2 Princípio de funcionamento do compressor recíproco alternativo hermético

A função do compressor é transferir energia externa, no caso energia elétrica, para o fluxo de gás que circula em seu interior, fazendo com que o refrigerante percorra o circuito de refrigeração, vencendo as perdas de carga e realizando as trocas de calor [2], [10].

A energia elétrica fornecida ao motor do compressor faz com que esse entre em funcionamento, gerando movimento circular sobre seu eixo. O movimento circular do eixo excêntrico é transformado, através do conjunto biela-manivela, em movimento retilíneo uniforme do pistão. Com o auxílio das válvulas de sucção e descarga, o pistão, nos seus movimentos descendentes e ascendentes, provoca a transferência de fluido do lado de baixa pressão para o de alta pressão. O volume e a pressão no interior do compressor variam de acordo com diagrama exposto na figura 2.3. O princípio de funcionamento é similar ao de uma bomba (Figura 2.3) [10], [11].

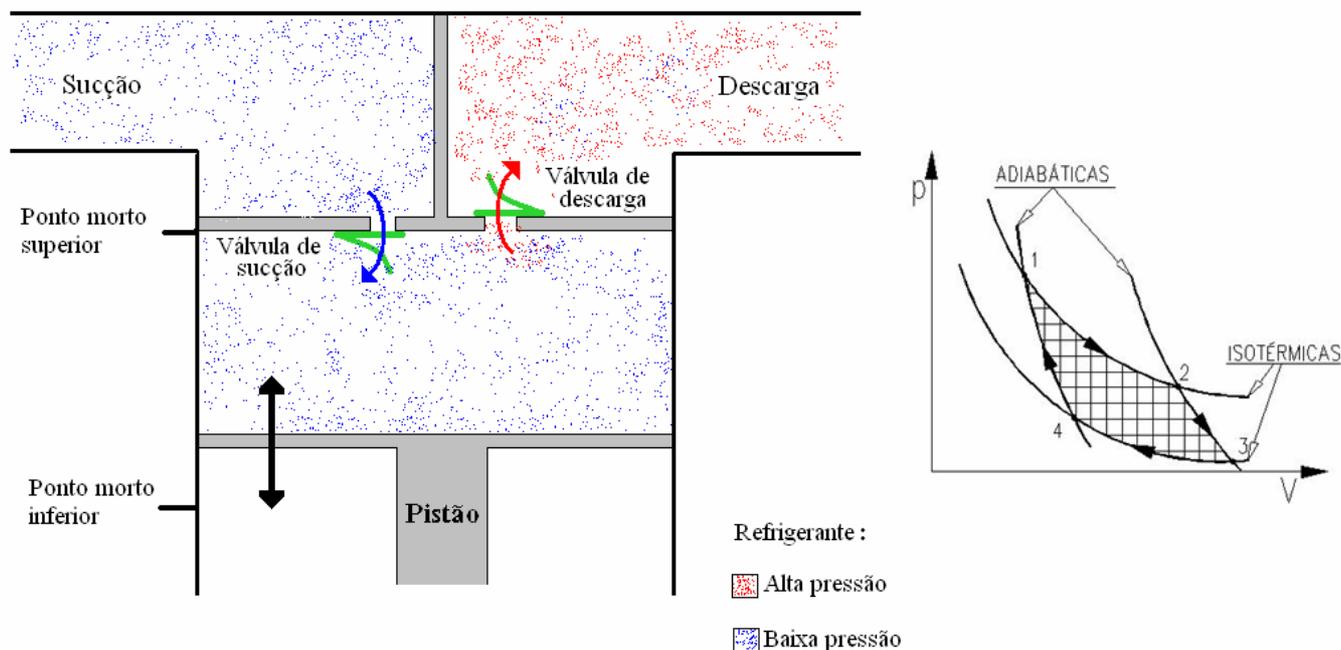


Figura 2.3 – Princípio de funcionamento do compressor recíproco alternativo [11].

O movimento do pistão possui dois limites físicos, o ponto morto superior e o ponto morto inferior. O período em que o pistão está no sentido ponto morto superior para ponto morto inferior é chamado de etapa de expansão, uma vez que o fluido no interior do cilindro sofre um processo de expansão em função do aumento de volume. Quando a pressão no interior do cilindro torna-se menor que na região de sucção a válvula de sucção se abre permitindo a entrada de refrigerante. Durante toda a etapa a pressão interna é menor do que a pressão de descarga, assim a válvula de descarga permanece fechada impedindo a saída do refrigerante do cilindro. Essas válvulas são comandadas unicamente pela diferença de pressão [10], [11].

Quando o ponto morto inferior é atingido o pistão movimenta-se no outro sentido (ponto morto inferior para ponto morto superior) e o fluido vai sendo comprimido e a pressão interna do cilindro aumentando, constituindo a etapa de compressão. Nesta etapa, pelo fato da pressão interna ser maior que a de sucção, a válvula de sucção permanece fechada e, quando a pressão interna atinge um ponto em que é maior que a pressão de descarga, a válvula de descarga se abre permitindo com que o fluido seja direcionado, sob alta pressão, para o resto do sistema. Quando o pistão atingir o ponto morto superior um novo ciclo é iniciado [11].

É importante destacar que a função do compressor é deslocar o fluido refrigerante no sistema, mas as trocas de calor são realizadas no condensador e evaporador, assim o sistema de refrigeração pode envolver uma quantidade maior de energia que a entregue pelo compressor [2].

2.2 CARACTERIZAÇÃO DOS ENSAIOS DE DESEMPENHO

Após a etapa final de montagem dos compressores herméticos para refrigeração é necessário determinar parâmetros inerentes a ele e para isso existem diversos ensaios que podem ser aplicados. Entre eles estão os ensaios de tombamento, ruído e vibração, proteção térmica, alta tensão (isolação elétrica dos terminais) e desempenho.

Nesta dissertação são abordados os ensaios de desempenho baseados na norma ISO 917 - *Testing of Refrigerant Compressors* [4]. Essa norma, bem como outras semelhantes, busca estabelecer procedimentos padrões para avaliação e determinação de características do compressor, tornando possíveis as reproduções de resultados e comparações entre diferentes fabricantes.

2.2.1 Objetivo dos ensaios

Os ensaios de desempenho têm como objetivo a determinação da capacidade de refrigeração, da potência elétrica ativa consumida, da eficiência isentrópica e do coeficiente de desempenho, com o compressor sob condições preestabelecidas. Os métodos de ensaio propostos na norma provêm resultados com incertezas suficientes para permitir a análise da adequação de um compressor a qualquer condição de operação requerida em um sistema de refrigeração [4].

Os procedimentos estabelecidos pela norma ISO 917 são gerais para todas as condições de operação, sendo que cada uma estabelece valores diferentes para pressão absoluta de descarga e sucção, temperatura de sucção e velocidade de rotação. As demais variáveis podem ser fixas, independentemente da condição de ensaio [4].

A capacidade de refrigeração de um compressor (Φ_0) é o produto do fluxo de massa de refrigerante através do compressor e a diferença entre a entalpia específica

do refrigerante na entrada (sucção) e a entalpia específica de líquido saturado na temperatura correspondente à pressão de descarga na saída do compressor [4]. Em outras palavras a capacidade de refrigeração é uma medida da capacidade do compressor de gerar vazão mássica de refrigerante frente a um diferencial de pressão imposto entre as tomadas de sucção e descarga do compressor [2]. A unidade da capacidade de refrigeração é watt.

A potência elétrica ativa consumida (P) é a potência nos terminais do compressor hermético, sendo composta pelo consumo do motor e de elementos auxiliares necessários para manter o compressor em operação. Esta característica também é expressa em watt [4].

A eficiência isentrópica (η_i) é a razão do produto do fluxo de massa e a diferença na entalpia isentrópica pela potência consumida pelo compressor. O coeficiente de desempenho (ϵ) é a razão da capacidade de refrigeração pela potência consumida pelo compressor. A eficiência e o coeficiente de desempenho são adimensionais [4].

O método de determinação dos parâmetros citados acima pode ser aplicado em ensaios de controle de qualidade, nos quais patamares mínimos e máximos são estabelecidos e a amostra deverá se encaixar nesta faixa, ou em ensaios de pesquisa e desenvolvimento, para identificar e quantificar melhorias devido a mudanças construtivas ou de projeto.

2.2.2 Bancada de ensaios

De acordo com a norma ISO 917 [4], os ensaios de desempenho devem ser realizados em bancadas especiais, capazes de reproduzir diferentes condições de operação e realizar diversas medições. Nestas bancadas existem duas tarefas principais envolvidas, as operações de controle e as operações de medição[12].

As ações de controle buscam simular as condições reais de operação de um compressor, direta e indiretamente. A bancada deve possuir todos os controladores, atuadores e medidores para que a malha de controle seja eficiente para colocar as variáveis controladas dentro de limites estabelecidos pela norma.

Existem vários métodos para realizar os ensaios (item 2.2.3) e cada um estabelece diferentes medições em diferentes pontos do circuito, porém a estrutura

física que realiza o controle das variáveis é basicamente a mesma. Podem existir diferentes configurações de circuitos de bancada, para exemplificar, é exposto na figura 2.4 o circuito exemplo adotado no trabalho.

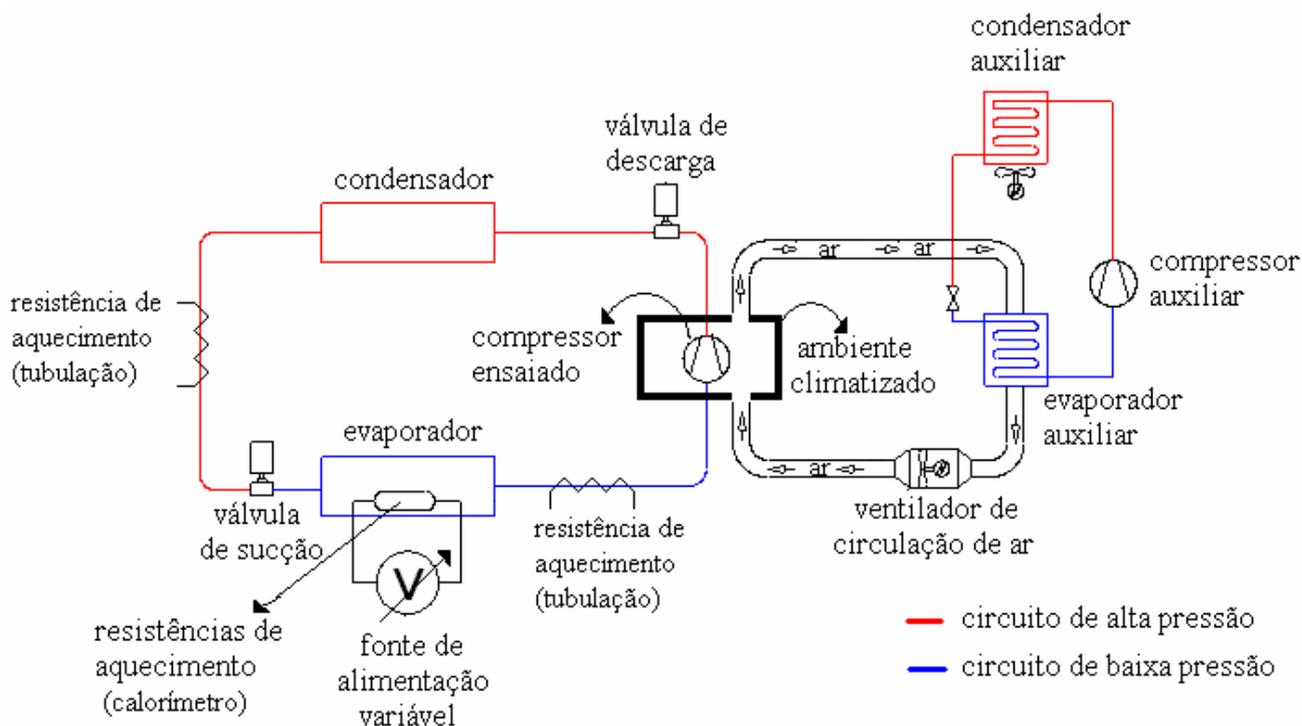


Figura 2.4 – Bancada de ensaio de compressores.

Na figura 2.4 pode-se ver que existem dois circuitos de refrigeração envolvidos, um para o compressor ensaiado e outro para realizar a climatização do ambiente do compressor, contando com um condensador auxiliar, um compressor auxiliar, um evaporador auxiliar, uma válvula de expansão e uma tubulação para direcionamento do ar frio.

Vários atuadores podem ser vistos na figura 2.4, como resistências de aquecimento e válvulas de pressão, que servem para impor a condição de operação, na qual é observado o desempenho do compressor. Vale salientar que dependendo do ponto de operação o compressor possui um comportamento diferente, podendo ter capacidade de refrigeração e consumo maiores ou menores [2].

Para os ensaios realizados nesta dissertação foram estabelecidos, em conjunto com a Embraco, os valores de referência para as variáveis controladas. A relação básica dessas variáveis em um ensaio de desempenho, podendo ter variações dependendo do método de ensaio, é:

- temperatura do ambiente do compressor (ambiente climatizado): 32,2 °C;
- temperatura de saída do trocador (evaporador): 32,2 °C;
- temperatura de entrada do trocador (evaporador): 32,2 °C;
- temperatura do ambiente do trocador: 32,2 °C;
- temperatura do separador de óleo: 80 °C;
- temperatura de entrada do compressor: 32,2 °C;
- pressão de sucção – depende da condição de operação do ensaio;
- pressão de descarga – depende da condição de operação do ensaio;
- tensão de alimentação do compressor: 110 V ou 220 V.

Todas as variáveis controladas são medidas, porém, conforme o método de ensaio instalado (descritos no item 2.2.3), existem variáveis livres que são somente medidas.

2.2.3 Métodos de ensaio

Os métodos para determinação da capacidade de refrigeração realizam duas tarefas: a obtenção do fluxo de massa de refrigerante no compressor; o cálculo das entalpias específicas na entrada e saída do compressor. Os cálculos das entalpias são realizados com o auxílio de tabelas de propriedades termodinâmicas do refrigerante usado e dos valores de pressão e temperatura nos pontos de medição [4].

A norma sugere nove métodos de ensaios, sendo que no mínimo dois devem ser executados simultaneamente. Cada método possui diferentes montagens de circuito e sistemas de medição. Os nove métodos propostos são [4]:

- método A – método do calorímetro com fluido secundário, posicionado na linha de sucção;
- método B – método do calorímetro inundado, posicionado na linha de sucção;
- método C – método do calorímetro a seco, posicionado na linha de sucção;

- método D1 – medição de vazão de refrigerante na linha de sucção, no estado gasoso;
- método D2 – medição de vazão de refrigerante na linha de descarga, no estado gasoso;
- método F – medição da vazão de refrigerante no estado líquido;
- método G – método do condensador com circulação de água gelada;
- método J – método da condensação parcial de fluido refrigerante;
- método K – método do calorímetro na linha de descarga.

Em alguns métodos aparece a palavra calorímetro. A definição clássica para esse elemento é um ambiente, ou volume, dedicado à quantificação das trocas térmicas entre elementos fixos ou que passam por seu interior [12]. No caso das bancadas é o ambiente onde se localiza o evaporador.

Na bancada de ensaios utilizada nesta dissertação, os métodos implementados foram os métodos C e F. Esses métodos serão detalhados nos itens 2.2.3.1 e 2.2.3.2

2.2.3.1 Método C – calorímetro a seco

No método do calorímetro a seco o evaporador consiste de uma serpentina por onde passa o fluido refrigerante que absorverá o calor durante a evaporação, envolta por um elemento que fornece o calor para a troca. Esse elemento pode ser uma resistência elétrica enrolada no evaporador (caso utilizado na dissertação) ou uma outra serpentina com um fluido de trabalho, como a água [4].

Para a determinação da capacidade de refrigeração várias medições precisam ser realizadas e a potência dissipada nas resistências de aquecimento, para controlar a temperatura de saída do evaporador, em regime permanente só pode ter variação de $\pm 1\%$. O circuito do método C está exposto na figura 2.5 [4].

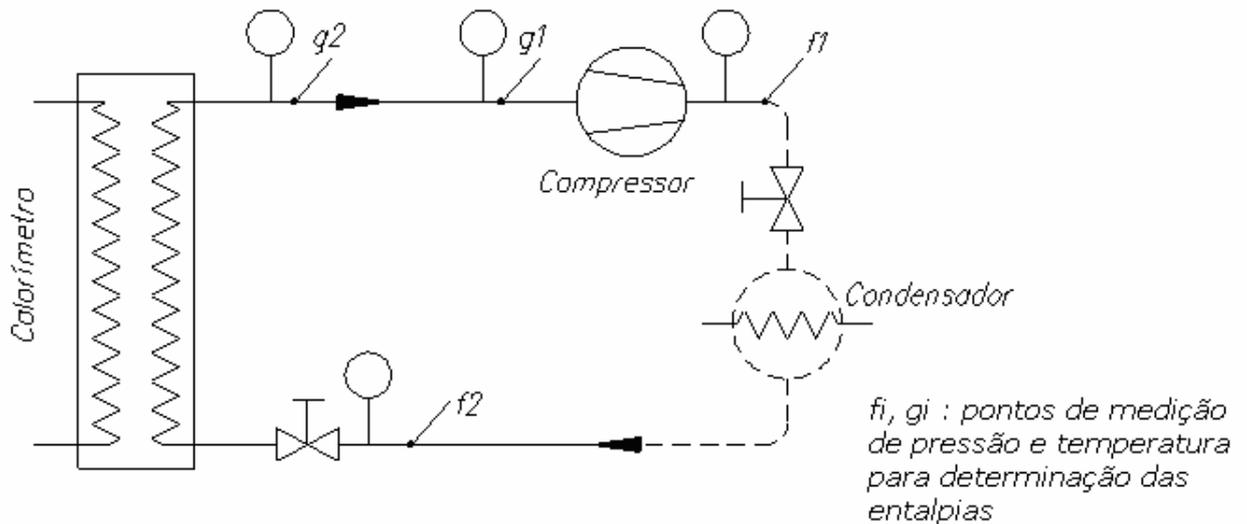


Figura 2.5 – Diagrama do circuito (método C) [4].

Durante todo o período do ensaio são lidas as pressões e temperaturas de entrada e saída de refrigerante no calorímetro (pontos de medição f_2 e g_2 respectivamente) e a energia dissipada nas resistências de aquecimento no interior do calorímetro (energia entregue pela fonte de alimentação variável). Dispondo destes dados é possível calcular o fluxo de massa do refrigerante que circula pelo calorímetro. Como o circuito é fechado e não existe perda de massa, o fluxo de massa presente no calorímetro é também o de todo o sistema, incluindo o fluxo através do compressor [4].

Segundo a ISO 917 o fluxo de massa de refrigerante é definido pela equação 1:

$$q_{mf} = \frac{\phi_i + F_l(T_a - T_g)}{h_{g2} - h_{f2}} \quad (1)$$

Onde:

- q_{mf} - fluxo de massa de refrigerante [kg/s];
- ϕ_i - quantidade de calor cedido pela fonte de alimentação variável [kJ];
- F_l - fator de perda do calorímetro [kJ/K];
- T_a - temperatura ambiente [K];
- T_g - temperatura interna do calorímetro [K];

- h_{g2} - entalpia do gás saturado saindo do calorímetro (h_{g2} é função da temperatura e pressão no ponto g2 e das propriedades termodinâmicas tabeladas do refrigerante utilizado) [kJ/kg];
- h_{f2} - Entalpia do líquido entrando no calorímetro (h_{f2} é função da temperatura e pressão no ponto f2 e das propriedades termodinâmicas tabeladas do refrigerante utilizado) [kJ/kg].

Durante o ensaio também é necessário realizar medições de temperatura e pressão nos pontos g1 e f1 (Figura 2.5), correspondentes à entrada e saída do compressor. A capacidade de refrigeração, de acordo com a norma ISO 917, é dada pela equação 2:

$$\phi_o = q_{mf} \frac{V_{ga}}{V_{gl}} (h_{g1} - h_{f1}) \quad (2)$$

Onde:

- ϕ_o - capacidade do compressor [kJ];
- q_{mf} - fluxo de massa de refrigerante [kg/s];
- V_{ga} - volume específico do refrigerante entrando no compressor, durante o ensaio [m³/kg];
- V_{gl} - volume específico do refrigerante entrando no compressor estabelecido anteriormente ao ensaio [m³/kg];
- h_{g1} - entalpia específica do refrigerante entrando no compressor nas condições básicas específicas de teste (h_{g1} é função da temperatura e pressão no ponto g1 e das propriedades termodinâmicas tabeladas do refrigerante utilizado) [kJ/kg];
- h_{f1} - entalpia específica do refrigerante líquido na pressão correspondente à descarga do compressor (h_{f1} é função da temperatura e pressão no ponto f1 e das propriedades termodinâmicas tabeladas do refrigerante utilizado) [kJ/kg].

2.2.3.2 Método F – medidor de fluxo de massa na fase líquida

No método F o circuito de refrigeração segue a configuração básica e é adicionado, entre o condensador e a válvula de expansão um medidor de fluxo de massa (Figura 2.6).

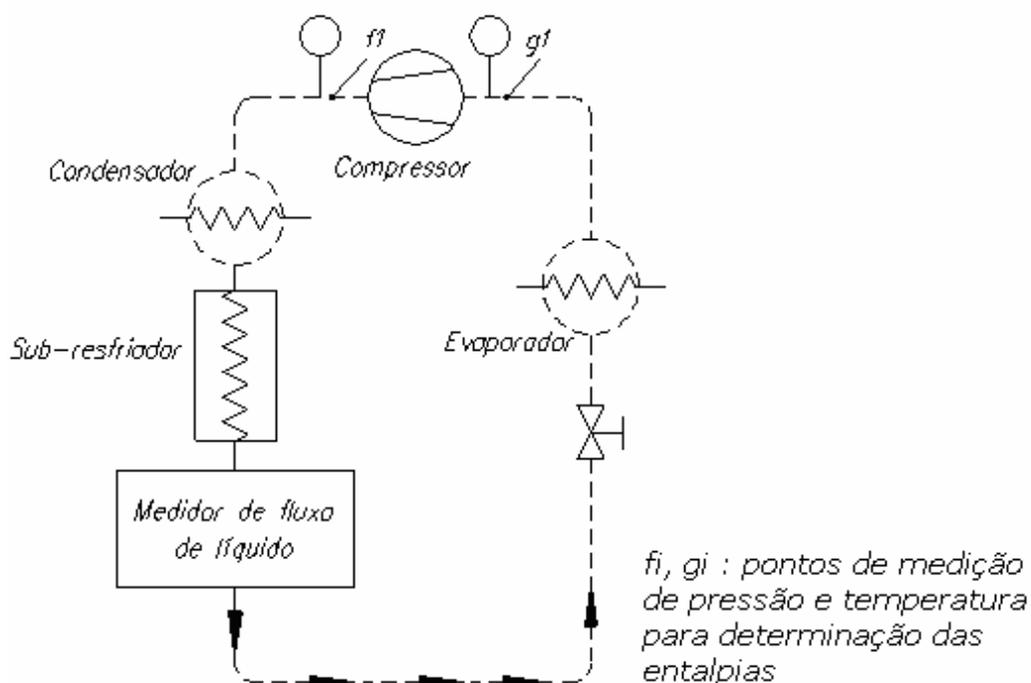


Figura 2.6 – Diagrama do circuito (método F) [4].

Para a correta medição, o refrigerante, no ponto de medição, deve estar totalmente líquido, sem a formação de bolhas. Para garantir tal fato, geralmente é adicionado um sub-resfriador logo após o condensador [4].

Neste método novamente devem ser realizadas as medições de pressão e temperatura do refrigerante na entrada e na saída do compressor (Figura 2.6, pontos de medição $g1$ e $f1$ respectivamente). A leitura do fluxo de massa no medidor também deve ser feita durante o período do ensaio [4].

Como o sistema utilizado possui um separador de óleo logo após a descarga do compressor, a norma indica que o cálculo da capacidade deve ser feito utilizando a equação 2, considerando que o fluxo de massa (q_{mf}) é o valor lido pelo medidor de fluxo de massa.

Para ambos os métodos de ensaio, além das medições necessárias para o cálculo da capacidade de refrigeração, outras medições que não são controladas

precisam ser realizadas para a completa caracterização dos parâmetros do compressor. São elas:

- temperatura de descarga do compressor;
- potência elétrica ativa consumida pelo compressor;
- corrente elétrica que circula pelo compressor;
- potência dissipada nos resistores localizados no evaporador;
- temperatura da carcaça do compressor;
- resistência de enrolamento (final do ensaio);
- frequência rotacional (final do ensaio).

2.2.4 Requisitos gerais para os ensaios

A norma exige que no mínimo dois métodos de ensaio sejam executados simultaneamente com correlação entre eles de $\pm 4\%$ do valor calculado, além disto, ainda existem outros requisitos gerais aplicados a todos os métodos. Esses requisitos podem ser divididos em duas categorias, a das especificações dos sistemas de medição e dos requisitos para identificar o regime permanente nos ensaios [4].

A respeito das especificações, a norma estabelece os tipos de sistemas de medição que podem ser utilizados (no mínimo um tipo) e os limites de incerteza aceitáveis, esses representados por valores limites do desvio padrão das medições¹. As especificações dos sistemas de medição são divididas por categoria de mensurando [4]:

- temperatura (termômetros de mercúrio, termopares e termorresistores):
 - fluido no calorímetro ou condensador – $\sigma = \pm 0,06 \text{ } ^\circ\text{C}$;
 - outras medições de temperatura – $\sigma = \pm 0,3 \text{ } ^\circ\text{C}$;
- pressão (coluna de mercúrio, tubo de bourdon e manômetros de diafragma ou fole):
 - pressão de sucção (absoluta) – $\sigma = \pm 1\%$ do valor medido;

¹ Mesmo não sendo a forma indicada pelo Guia para a Expressão da Incerteza de Medição do INMETRO [13], a representação de incerteza pelo desvio padrão é estabelecida pela norma ISO 917.

- outras medições de pressão – $\sigma = \pm 2\%$ do valor medido;
- grandezas elétricas:
 - todas as medições (potência, corrente, tensão e resistência) – $\sigma = \pm 1\%$ do valor medido;
- fluxo mássico (medidor de fluxo de massa líquido ou vapor e rotâmetros que medem simultaneamente massa ou volume):
 - medições na fase líquida – $\sigma = \pm 1\%$ do valor medido;
 - medições na fase gasosa – $\sigma = \pm 2\%$ do valor medido;
- velocidade de rotação (contador de revolução, tacômetro, estroboscópio e oscilógrafo) – $\sigma = \pm 0,75\%$ do valor medido;
- tempo – $\sigma = \pm 0,1\%$ do valor medido;
- massa – $\sigma = \pm 0,2\%$ do valor medido.

Durante o ensaio o compressor deve operar continuamente e, para que os valores finais sejam calculados, algumas variáveis precisam atingir os valores estabelecidos pela condição de operação (valores de referência) e suas variações devem permanecer durante um certo tempo dentro de limites estabelecidos pela norma. O período em que as variáveis cumprem estes requisitos continuamente é chamado de regime permanente (Figura 2.7)[4].

Depois da partida do compressor a bancada de ensaios inicia o processo de controle para que as variáveis atinjam os valores da condição de operação em que o compressor está sendo testado. Enquanto esses valores não estiverem continuamente dentro dos limites de variação em torno do valor de referência, o ensaio estará no transitório (Figura 2.7).

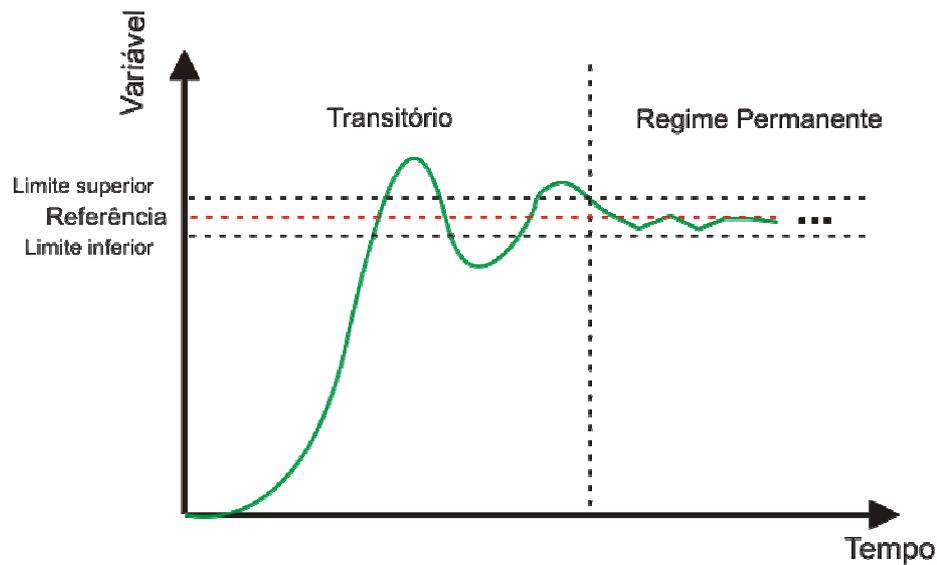


Figura 2.7 – Transitório e regime permanente.

Uma vez o compressor operando em regime permanente, as medições devem ser realizadas em intervalos eqüidistantes de no máximo 20 min, durante pelo menos 1 h. Os limites de variação impostos pela norma ISO 917 [4] para caracterizar o regime permanente são:

- as leituras de pressão não podem ter variação maior que $\pm 1\%$ do valor de referência;
- as leituras de temperatura não podem ter variação maior que $\pm 3\%$ do valor de referência;
- no método C, se a fonte de alimentação variável for contínua, a potência dissipada nos resistores de aquecimento não pode variar mais do que $\pm 1\%$ do valor médio da última 1 h. Caso a fonte de alimentação variável não for contínua a temperatura de saída do evaporador não pode variar mais que $\pm 0,6\text{ }^{\circ}\text{C}$;
- o limite de variação da tensão de alimentação do compressor é de $\pm 3\%$ e da frequência $\pm 1\%$ do valor de referência;
- no método F o valor lido no medidor de fluxo de massa não pode exceder o limite de $\pm 1\%$ do valor médio da última 1 h.

Os valores de capacidade de refrigeração, potência ativa consumida pelo compressor e coeficiente de desempenho são calculados tomando os valores médios consecutivos de 1 h de ensaio operando em regime permanente [4].

3 TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

Com o surgimento de novas tecnologias e, principalmente com estudo mais aprofundado dos processos, surge a necessidade de se analisar, entender, modelar e diagnosticar sistemas não lineares e com pouca informação sobre seu funcionamento. Neste panorama encaixam-se perfeitamente as técnicas de inteligência artificial (IA), buscando soluções simples para problemas complexos [14] [15].

Este capítulo busca introduzir o assunto referente à IA, dando ênfase às duas técnicas empregadas na dissertação, redes neurais artificiais (RNA) e lógica nebulosa.

3.1 INTRODUÇÃO AO CONCEITO DE INTELIGÊNCIA ARTIFICIAL

Não existe um consenso entre pesquisadores sobre o que é inteligência artificial, e sim, diversas definições da mesma. Entre as mais comentadas encontram-se [16]:

- Patrick Winston: “Inteligência artificial é o estudo de conceitos que permitem aos computadores serem inteligentes”;
- Elaine Rich e Kelvin Knigh: “Inteligência artificial é o estudo de como fazer os computadores realizarem coisas que, no momento, as pessoas realizam melhor”;
- Eugene Charniak e Drew McDermott: “Inteligência artificial é o estudo das faculdades mentais com o uso de modelos computacionais”.

A última definição apresenta várias vantagens, é relacionada com outras ciências afins (lógica, psicologia, evolução etc.), é desprovida de xenofobia humana e é independente de tecnologias de construção de computadores.

As técnicas de IA possuem diversos domínios de aplicação tais como bases de dados inteligentes, robótica, demonstração automática de teoremas, diagnóstico, monitoramento, ensino e manipulação matemática. Na metrologia a IA é uma área em pesquisa e expansão, tendo aplicações em todas as atividades do processo de medição (estabelecimento de requisitos do sistema de medição, projeto do processo de medição, avaliação de incertezas, avaliação das medições, calibração de sistemas de medição e interpretação de resultados de medição) [8], [17], [18].

As principais técnicas de IA são: redes neurais, sistemas especialistas, algoritmos genéticos, raciocínio baseado em casos e lógica nebulosa (*fuzzy*) [16].

3.2 REDES NEURAIS

As redes neurais artificiais são compostas por elementos, chamados neurônios, inspirados em modelos simplificados dos neurônios biológicos, operando em paralelo. Esses elementos podem diferir em algumas características, dependendo do tipo de rede em que são inseridos [16].

Pode-se dizer que as redes neurais constituem uma forma de aproximação universal de funções, que apresenta um desempenho satisfatório quando aplicadas à interpretação e classificação de padrões complexos. Estas são também bastante versáteis e podem aprender continuamente, além de apresentarem capacidade de generalização e alto desempenho computacional, devido ao seu forte paralelismo [19], [20].

As redes neurais diferem bastante das técnicas de IA que dependem do conhecimento prévio das regras que governam o fenômeno, pois são adaptáveis e inferem soluções a partir dos exemplos utilizados durante o treinamento. O fato de elas serem não lineares permite que capturem interações complexas entre as variáveis, como ocorre normalmente no mundo real [21].

Para a completa caracterização de uma rede neural artificial (RNA) é necessário determinar e especificar alguns itens, tais como: os neurônios, o estado global de ativação da rede, a conectividade da rede dada pelos valores de conexões sinápticas, como se propaga a atividade da rede, como se estabelece a conectividade da rede, o ambiente externo à rede e como o conhecimento é representado na rede [16].

3.2.1 Modelo geral de neurônio

O neurônio é o elemento fundamental de uma RNA. Existem diversos modelos de neurônios propostos por uma série de autores, porém para simplificar a explicação expõe-se um modelo geral de neurônio (Figura 3.1), sendo este uma generalização do modelo de McCulloch e Pitts [16].

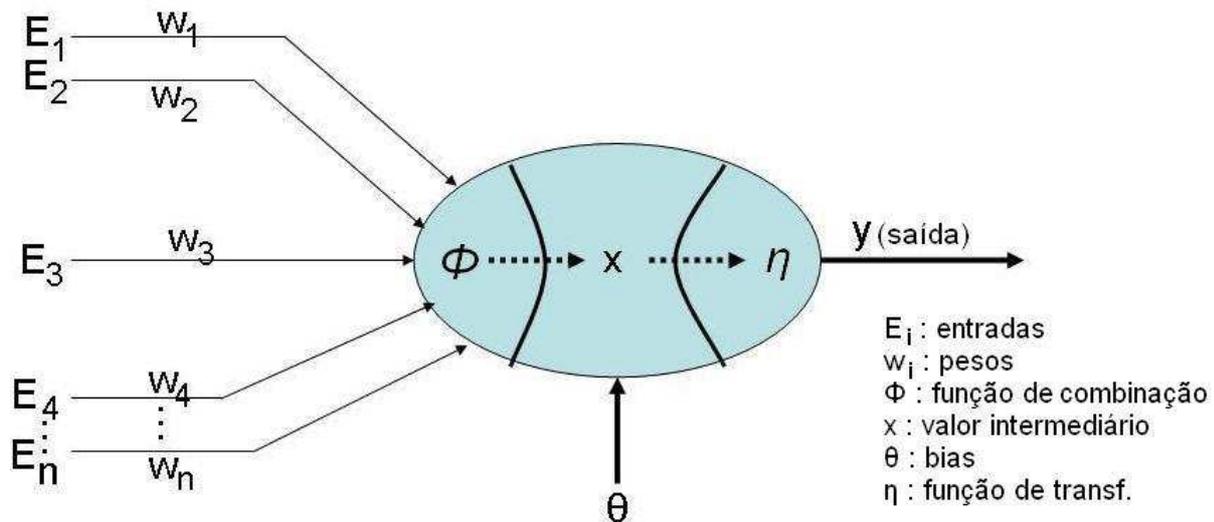


Figura 3.1 - Modelo geral de neurônio.

Neste modelo as entradas são representadas pelos símbolos E_1 a E_n e os pesos das conexões por w_1 a w_n . Os produtos das entradas pelos pesos das conexões são combinados por uma função Φ (função de combinação) para produzir um estado de ativação do neurônio que através da função η (função de transferência) vai produzir a saída do neurônio y . Um valor auxiliar θ (bias) é geralmente usado para representar uma polarização do neurônio [16].

Geralmente a função de combinação é a função soma e em algumas aplicações, de forma menos usual, a função produto é utilizada. Outros tipos de funções raramente são utilizados, porém isto é possível.

A função de transferência pode ter várias formas, incluindo, linear (Figura 3.2a), degrau (Figura 3.2b), tangente sigmóide (Figura 3.2c), entre outras. É a função de transferência que costuma atribuir a não-linearidade ao neurônio.

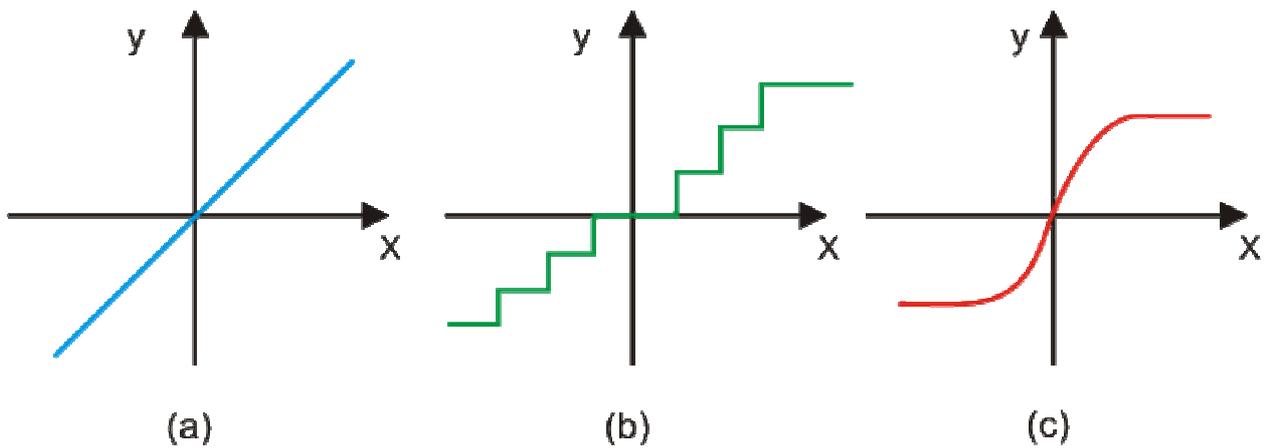


Figura 3.2 – Funções de transferência.

Algumas definições podem ser feitas partindo do modelo geral de neurônio [22]:

1. um neurônio é estático quando o valor de x e de y referem se ao mesmo instante que as excitações. Assim, pode se escrever:

$$x = \phi(w_i, u_i) \quad (3)$$

$$y = \eta(x) \quad (4)$$

onde:

- x – valor intermediário do neurônio;
 - Φ – função de combinação;
 - w_i – pesos das conexões;
 - u_i – excitações (entradas do neurônio);
 - η – função de transferência;
 - y – saída do neurônio.
2. um neurônio é linear se Φ e η são funções lineares;
 3. o neurônio é não estacionário se as funções Φ e/ou η são funções do tempo. Neste caso deve-se escrever:

$$x = \phi(w_i, u_i, t) \quad (5)$$

$$y = \eta(x, t) \quad (6)$$

onde:

- t – tempo.

4. o neurônio é dito dinâmico se para o cálculo de x em um determinado instante é necessário o conhecimento de x em um instante anterior.

$$x = \phi(w_i, u_i, t, x(t - n)) \quad (7)$$

$$y = \eta(x, t, y(t - n)) \quad (8)$$

onde:

- n – atraso ou deslocamento temporal.

3.2.2 Arquiteturas neurais

A princípio qualquer disposição organizada de neurônios pode dar origem a uma arquitetura de rede neural e dentro das topologias existentes, algumas se destacam e recebem maior atenção de pesquisadores e usuários. A arquitetura de uma rede neural é definida por quatro características básicas:

- número de camadas na rede;
- número de neurônios por camada;
- tipo de conexões (diretas (*feedforward*), ciclos (*backward/feedback*) e lateral);
- grau de conectividade entre os neurônios (um a um, conectividade plena, esparsa ou randômica).

O número de neurônios por camada e o número de camadas de uma rede depende muito da aplicação e delimitarão outras características como capacidade de generalização, armazenamento do conhecimento e esforço computacional.

Quanto ao tipo de conexões estabelecidas nas redes, têm-se dois grandes grupos, as redes diretas e as redes com ciclos ou realimentação (*feedback*). As redes diretas têm neurônios organizados em camadas com conexões unilaterais entre elas e sem ciclos. Frequentemente essas redes são chamadas de redes em camadas [16].

Os neurônios que recebem os sinais de excitação são chamados de camada de entrada, ou primeira camada. Neurônios que tem sua saída como saída da rede

pertencem à camada de saída ou última camada da rede. Já os neurônios que não pertencem a nenhuma destas camadas são os neurônios internos à rede e pertencem a uma ou mais camadas escondidas.

As redes diretas só produzem um conjunto de valores de saída para uma dada excitação de entrada e são muito bons em aproximações universais de funções e diagnóstico, porém mesmo quando utilizam neurônios dinâmicos (com retardo - atrasador) não conseguem modelar todos os sistemas dinâmicos [16], [22].

Redes com ciclos são aquelas redes que apresentam ao menos um ciclo em seu diagrama de conectividade. Quando além de ciclos as redes possuem neurônios dinâmicos, contendo um retardo, são chamadas de redes recorrentes. Quando uma nova entrada é imposta à rede, as saídas dos neurônios são computadas e, pelo fato da realimentação, as entradas de cada neurônio são modificadas, o que leva a rede a entrar em um outro estado [16].

O grau de conectividade indica como estão dispostas as conexões na rede neural, se todos os neurônios são ligados, uniformemente ou não e assim por diante.

3.2.3 Aprendizado

O conhecimento adquirido por uma rede está contido nos pesos de suas conexões e a tarefa dos métodos de aprendizado é estabelecer quais serão esses pesos.

As redes neurais são ajustadas ou treinadas para executar tarefas específicas, podendo o aprendizado ser supervisionado ou não. O treinamento supervisionado é realizado a partir de uma série de exemplares preestabelecidos, relacionando-se variáveis de entrada e respectivas saídas. Por outro lado, o aprendizado não supervisionado busca encontrar padrões de semelhança entre os vetores de entrada, agrupando-os de modo a representarem um determinado conhecimento. Esse tipo de aprendizado também é chamado de descobridor de regularidades devido à propriedade básica de seu funcionamento [23].

Outras características estão associadas direta ou indiretamente ao aprendizado. São elas, a complexidade das amostras, a capacidade de armazenamento e a complexidade computacional. A complexidade da amostra determina o número de padrões de treinamento necessários para treinar a rede de

modo a garantir uma boa generalização. Poucas amostras podem fazer com que a rede decore e só consiga bons resultados quando os casos testados são os mesmos utilizados no treinamento.

A capacidade de armazenamento refere-se a quantos padrões podem ser armazenados e quais funções e limites de decisões uma rede neural pode formar. A complexidade computacional refere-se ao tempo requerido para que um algoritmo de aprendizado chegue a uma solução [23].

Existem diversos tipos de regras para aprendizado em redes neurais artificiais, sendo que cada um é mais apropriado para uma determinada aplicação e/ou arquitetura de rede. Dentre os principais algoritmos encontram-se [16]:

- Hebb: a lei de Hebb goza da propriedade de localidade, o que significa que para alterar o valor de uma conexão apenas informações locais à sinapse em jogo são usadas, dando plausibilidade biológica ao algoritmo;
- regra delta: é uma generalização da lei de Hebb e efetua uma otimização que pode ser interpretada como o modelo matemático de um mecanismo de seleção. Esta regra só é aplicável a RNA com duas camadas;
- retropropagação (*Backpropagation*): é uma regra de aprendizado supervisionado que pode ser considerada uma generalização da regra delta. É aplicável a redes com duas ou mais camadas e geralmente diretas, porém, eventualmente, podendo ser cíclicas. É um método de gradiente descendente que minimiza a função erro quadrático estabelecida para a RNA;
- aprendizado competitivo: neurônios são inibidos por outros neurônios de modo que a competição entre eles leva a apenas um ser excitado.

3.2.4 Tipos de Redes Neurais Artificiais

Durante algum tempo vários pesquisadores estudaram redes com topologias bem definidas e para estas redes sugeriram algoritmos de aprendizado convenientes. Assim surgiram os vários tipos de RNA.

Na seqüência é apresentada uma breve explicação de alguns tipos de redes mais usuais. Os tipos de redes neurais descritos são: *Generalized Regression Neural*

Network (GRNN), Kohonen, Learning Vector Quantization, Probabilistic Neural Network, Hopfield e Multi Layer Perceptron (MLP) com algoritmo da Retropropagação. Por se tratar da arquitetura de rede utilizada na dissertação, um enfoque maior é dado à MLP com algoritmo da retropropagação. O objetivo também é de entender características básicas em uma análise mais profunda e, por indução, generalizar para as demais redes, possibilitando entender algumas de suas características.

3.2.4.1 Generalized Regression Neural Network (GRNN)

A rede GRNN é uma variação da rede de base radial, porém dotada de grande capacidade de generalização. É utilizada principalmente para aproximar funções. O funcionamento desta rede é similar à rede PNN (*Probabilistic Neural Network*), sendo que esta última determina limites de decisão entre padrões ou categorias, enquanto que a GRNN estima valores contínuos de variáveis dependentes [24].

Os neurônios de base radial utilizados neste tipo de RNA obedecem ao esquema da figura 3.3, sendo $p(1)$ a $p(R)$ as entradas da rede [25].

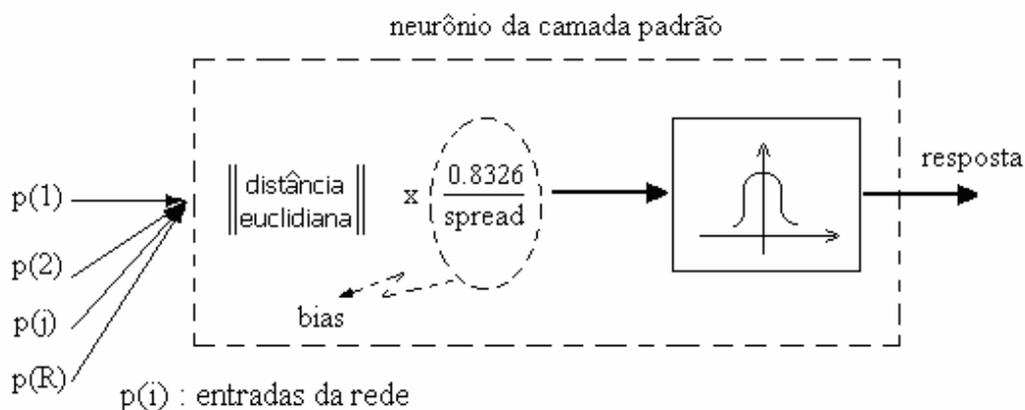


Figura 3.3 – Neurônio da camada padrão [25].

A rede GRNN é recomendada na solução de problemas de previsão, modelagem, mapeamento, interpolação ou controle.

Entre as principais vantagens apresentadas pela rede GRNN, citam-se:

- o processo de aprendizado ocorre em um único passo (não é um processo iterativo). A rede pode generalizar a partir do instante em que os exemplos são armazenados;
- apresenta um resultado satisfatório mesmo com poucos exemplos;

- não converge a um mínimo local da função utilizada como critério de erro (isto pode ocorrer com processos iterativos);
- a rede pode fornecer o mapeamento entre os conjuntos de amostras.

A principal desvantagem com relação a outras redes é que esta requer substancial esforço computacional para avaliar novos pontos, quando o conjunto de exemplos utilizados durante o treinamento for muito grande. Neste caso sugere-se a utilização de técnicas de agrupamento para primeiramente definir o centro dos agrupamentos [24].

3.2.4.2 Kohonen

É indicada para problemas de reconhecimento de padrões não especificados. A principal vantagem é a auto-organização, sendo uma ferramenta bastante indicada para refinar e comprimir dados. Os mapeamentos auto-organizáveis aprendem a reconhecer grupos de vetores de entrada de modo que os neurônios de uma camada, fisicamente próximos, respondam a vetores de entrada similares. A principal desvantagem está no tempo de treinamento e sua pouca eficiência (treinamento é não supervisionado) [26].

3.2.4.3 Learning Vector Quantization (LVQ)

É um método de classificação de padrão na qual cada unidade de saída representa classe ou categoria. Depois de treinada, a rede LVQ classifica um vetor de entrada de acordo com a proximidade entre o vetor de peso da unidade de saída e o vetor de entrada. A arquitetura é semelhante à Kohonen, mas cada vetor de saída representa uma classe conhecida, isto é, o aprendizado é supervisionado [26].

3.2.4.4 Probabilistic Neural Network

Constitui uma variação da função de base radial. É aplicada com bastante sucesso em reconhecimento de padrões, mapeamento não linear, e na estimação do grau com que um novo vetor de entrada pertence às classes pré-definidas. O processo de treinamento não envolve algoritmo iterativo, nem necessita de convergência. É um

processo extremamente rápido, onde os pesos constituem os vetores utilizados durante o treinamento [16].

3.2.4.5 Hopfield

A rede de Hopfield é uma RNA com ciclos, utilizada para memória associativa e para resolver otimização de problemas combinatórios. Esta rede possui neurônios dinâmicos, cuja dinâmica é introduzida por um retardo correspondente ao tempo de funcionamento do neurônio, e uma saída binária (excitada ou em repouso) resultado do uso de uma função de transferência de dois níveis. Algumas vezes usa-se também a função logística e neste caso a resposta de cada neurônio pode ter qualquer valor entre dois valores reais [16].

A rede de Hopfield sempre evolui na direção que a leva para o menor estado de energia. Isto implica que se um problema de otimização combinatória puder ser formulado como a minimização dessa energia, a rede de Hopfield pode ser utilizada para, deixando a rede evoluir livremente, encontrar a solução [16].

3.2.4.6 Perceptron Multicamadas com Algoritmo da Retropropagação

A rede perceptron consiste simplesmente de uma única camada de neurônios de um tipo específico (Figura 3.4) ligada aos dados de entrada. Sendo assim, o número de neurônios corresponderá ao número de elementos da saída. Esta rede, geralmente, é empregada na classificação de padrões.

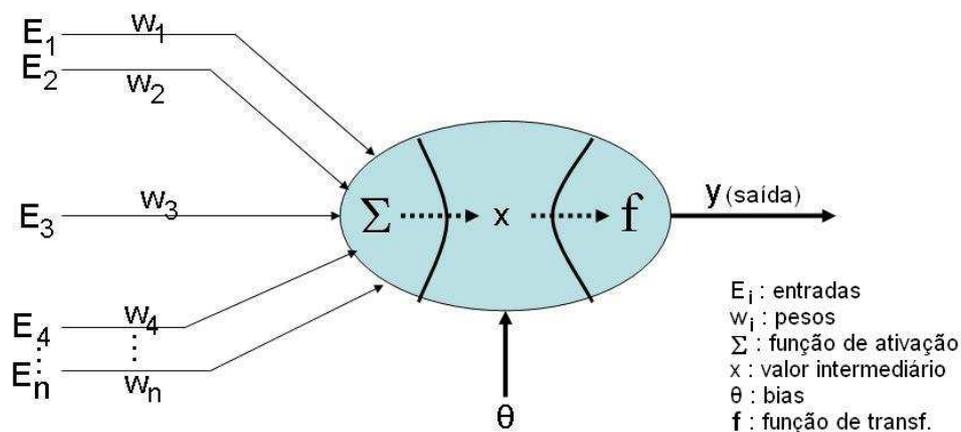


Figura 3.4 - Perceptron

Os valores de entrada E_r - para $r=1, \dots, n^\circ$ de variáveis de entrada - passarão pelas conexões sendo multiplicados pelos pesos $w_{1, r}$, que são calculados durante o treinamento. Sobre os resultados dessa multiplicação é realizado um somatório cujos valores são aplicados a uma função de transferência (f), produzindo um resultado (y).

Perceptron multicamadas são redes diretas compostas por várias camadas de neurônios, sendo que estes seguem o mesmo princípio de funcionamento da rede perceptron, cabendo ao projetista escolher o número de camadas e o número de neurônios por camada [16].

As redes perceptron multicamadas (MLP) com a retropropagação como algoritmo de treinamento (*Backpropagation*), utilizada em múltiplas aplicações (aproximação de funções, classificação e associação de padrões), constituem o tipo de rede mais utilizado, uma vez que estas não são limitadas a resolver problemas linearmente separáveis [27].

A arquitetura de uma rede MLP pode ser vista na figura 3.5. O número de entradas corresponde ao número de variáveis utilizadas. A informação é recebida por essas entradas, que por sua vez a encaminham aos neurônios das duas camadas ocultas. Destas camadas os dados são repassados para os neurônios de saída, que mais uma vez realizam processos de multiplicação e acumulação, e, por meio de uma função de transferência, produzem resultados (saídas da rede) (Figura 3.5).

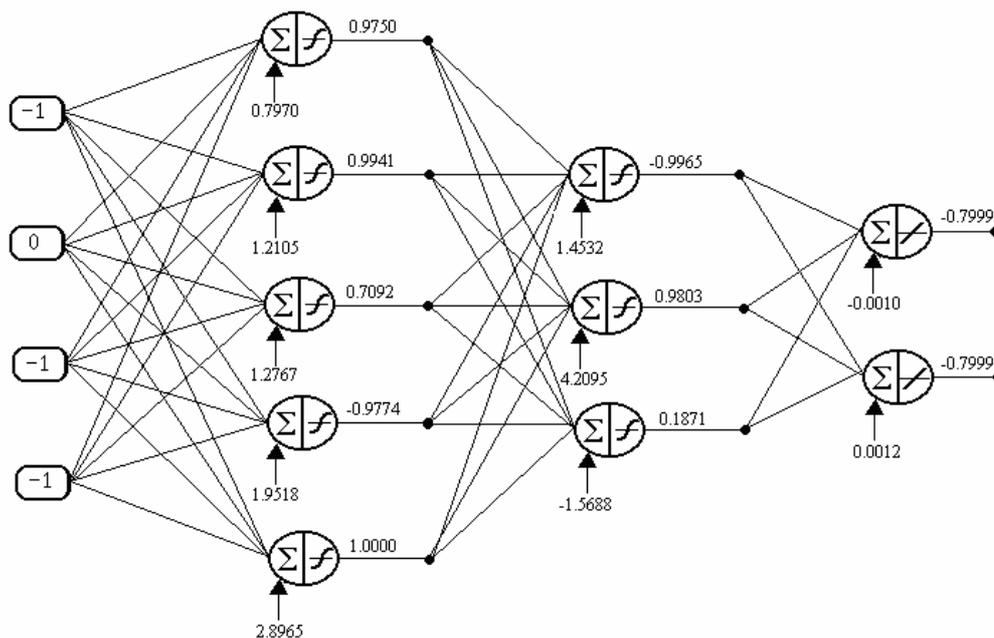


Figura 3.5 – Rede MLP.

Durante o treinamento os resultados da última camada (saída) são comparados com os valores esperados (informados pelo programador), encontrando-se as diferenças, que constituem um vetor de erros. As derivadas deste vetor em função dos respectivos pesos são determinadas, sendo transferidas no sentido inverso e voltando aos neurônios da camada oculta (processo de retropropagação). Nestes neurônios calcula-se a somatória das derivadas dos erros, definindo-se sua participação no erro de saída. Mediante algum procedimento matemático, como o método dos mínimos quadráticos, os neurônios modificam os pesos de suas conexões, diminuindo o erro apresentado pela rede. O processo repete-se ciclicamente, até que os neurônios da camada de saída apresentem um erro inferior ao estipulado [16].

Depois do processo de treinamento finalizado todo o conhecimento da rede está fixado nos pesos das conexões, que de agora em diante não mudarão até que um novo treinamento seja requerido. Dispondo dos pesos das conexões e de informações a respeito das funções de transferência e de combinação utilizadas, é possível estabelecer a representação matemática para a rede neural. Na figura 3.6 pode se ver a formulação matemática da rede representada na figura 3.5.

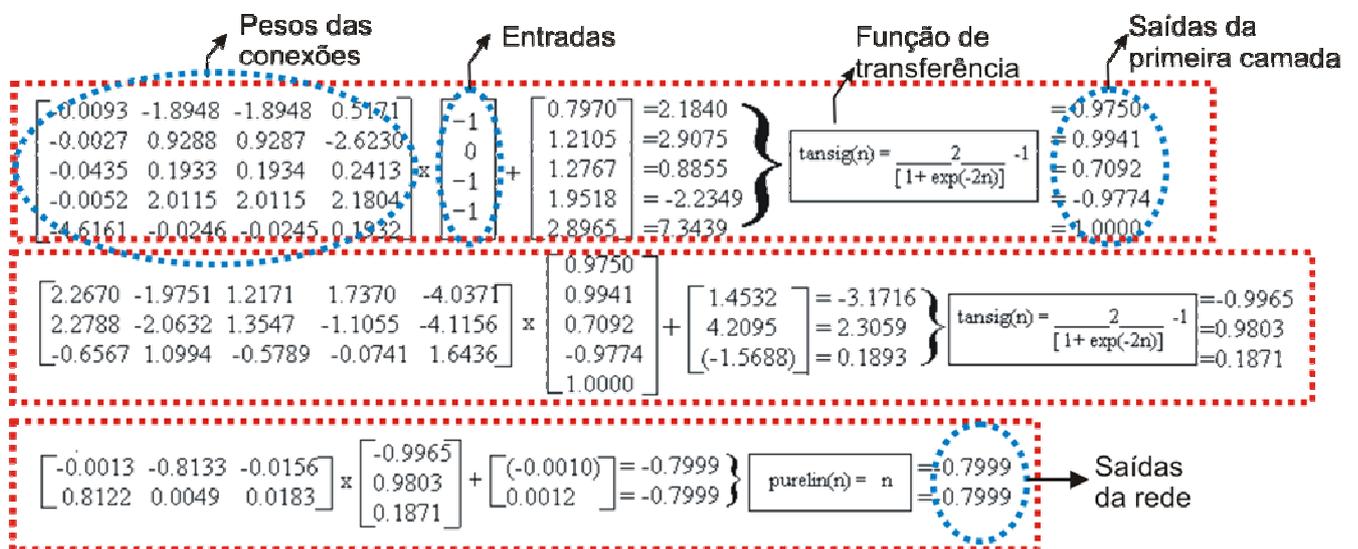


Figura 3.6 – Formulação matemática.

O primeiro retângulo selecionado na figura acima representa as operações realizadas da entrada até os neurônios da primeira camada, sendo a primeira matriz a de pesos das conexões e a segunda a de entradas da rede. Estão também indicadas a função de transferência e as saídas desta primeira camada. Na segunda seleção acontece a mesma coisa, com os dados indo das saídas da primeira camada até as

saídas da segunda camada. A última seleção são as operações realizadas na camada de saída, terminando com as saídas finais da rede.

As principais vantagens das RNA MLP com algoritmo de treinamento da retropropagação estão relacionadas à sua larga faixa de aplicação, simplicidade e eficiência. Por outro lado, a principal desvantagem é o fato do processo de treinamento ser bastante demorado, uma vez que exige muitos exemplos para possibilitar um aprendizado estável. Outro fator negativo é possibilidade do algoritmo convergir para um mínimo local, resultando em uma solução inválida. Neste caso, como há uma grande dependência do ponto de partida, deve-se reiniciar o processo de treinamento da rede para condições iniciais diferentes [27].

3.3 LÓGICA NEBULOSA (LÓGICA *FUZZY*)

O interesse por lógica nebulosa vem sendo estabelecido devido ao fato desses sistemas serem bastante robustos em aplicações envolvendo informações imprecisas e vagas, além de aplicações envolvendo objetivos conflitantes [25]. Outro aspecto atrativo é o pouco esforço computacional envolvido e a simplicidade de implementação. Algumas características e requisitos comuns à escolha de lógica nebulosa como técnica de IA a ser aplicada são [16]:

- ter disponibilidade de regras heurísticas (necessidade da ajuda de especialistas humanos);
- inexistência de expressão em forma matemática como método de solução;
- a modelagem matemática do problema requer várias simplificações, resultando em um modelo pouco preciso;
- o problema envolve restrições vagas e/ou múltiplos objetivos conflitantes.
- a complexidade do problema torna a solução computacional bastante pesada, caso técnicas convencionais sejam utilizadas;
- capacidade de supressão de ruídos – não é sensível a sinais inesperados.

A lógica nebulosa consiste em aproximar a decisão computacional à decisão humana. Isto é feito de forma que a decisão de uma máquina não se resume apenas a um “sim” ou um “não”, mas também tenha decisões “abstratas”, do tipo “um pouco mais”, “talvez sim”, e outras variáveis que representem as decisões humanas [25]. A lógica nebulosa tem se destacado principalmente na área de tomada de decisões e controle [26].

Alguns conceitos básicos encontrados em lógica nebulosa e que serão mais explorados no decorrer do texto são [16]:

- valores abruptos: valores que podem ser mapeados somente como pertencentes ou não pertencentes a um conjunto (como na lógica clássica);
- função de pertinência: define um conjunto nebuloso mapeando entradas de seu domínio a graus de pertinência;
- grau de pertinência: grau ao qual um valor abrupto é compatível com uma função de pertinência, o qual pode tomar dentro de um intervalo pré determinado, por exemplo $[0,1]$;
- etiqueta: nome descritivo, utilizado para identificar uma função de pertinência;
- domínio: valores (geralmente números) sob os quais é definida a função de pertinência.
- universo de discurso: todos os valores possíveis de uma variável do sistema.

3.3.1 Conjuntos nebulosos

A lógica nebulosa é baseada na teoria dos conjuntos nebulosos, que foi desenvolvida por Zadeh em 1973. Segundo essa teoria um conjunto não apresenta limites bem definidos podendo um elemento pertencer parcialmente a ele. O que vai caracterizá-lo será o grau de pertinência, que é uma medida que quantifica o grau de quanto este elemento pertence a um determinado conjunto [25], [28].

A lógica nebulosa tem obtido espaço em razão da existência de problemas complexos ou mal definidos, onde as técnicas convencionais não conseguem

demonstrar bons resultados. Os conjuntos nebulosos representam uma forma excelente na elaboração de modelos completos e eficientes, capazes de representar a imprecisão do raciocínio humano, no qual variáveis lingüísticas associadas a funções de pertinência são utilizadas, obtendo sistemas com maior robustez e capacidade de generalização e facilidades de modelagem [16], [28].

As variáveis lingüísticas são variáveis que podem assumir palavras ao invés de números. O valor de uma variável lingüística é chamado variável nebulosa, a qual é caracterizada por um conjunto difuso.

3.3.2 Função de pertinência

Um conjunto nebuloso é obtido simplesmente pela modificação do conjunto de valores de uma função característica, permitindo se obter valores em um conjunto mais geral. Um valor particular neste conjunto descreve o quanto este elemento pertence ao conjunto. A função característica que qualifica o elemento quantificando o “pertencer” e o “não pertencer” é chamada de função de pertinência. A função de pertinência associa um valor do conjunto universo a um número que representa o grau de pertinência do elemento a um conjunto difuso [16]. Por exemplo:

$$\mu_B(x) = x^2 \quad (9)$$

Como a função de pertinência vai caracterizar o conjunto nebuloso que, por sua vez, irá modelar o raciocínio impreciso em questão, é importante que as funções de pertinência usadas possam agregar o máximo de conhecimento sobre o assunto. A escolha deve ser muito criteriosa e geralmente dois métodos são utilizados, estatísticos e por experiências psicológicas [16].

- experimental: Estatístico [16].

Exemplo - Faz-se perguntas do tipo: “Um homem de 1,80 m é alto?” E a posteriori faz-se um estudo estatístico de todas as respostas.

- conceitual: Experiência Psicológica [16].

Exemplo: Coloque um "x" no ponto da linha que está um pouco a direita da marca.

É de extrema importância analisar algumas características da função de transferência, tais como forma, magnitude e largura da base [16]:

- forma: A triangular é uma das mais comuns, porém a normal, trapezoidal e exponencial também são utilizadas com frequência. Outros tipos de funções devem ser estudados antes da utilização, levando em conta, inclusive, fatores como complexidade computacional;
- magnitude: Normalmente a magnitude é normalizada a 1, mas em aplicações específicas outros valores são possíveis;
- largura da base: A largura da base irá definir a abrangência desta função.

Alguns exemplos de funções de pertinência são mostrados abaixo:

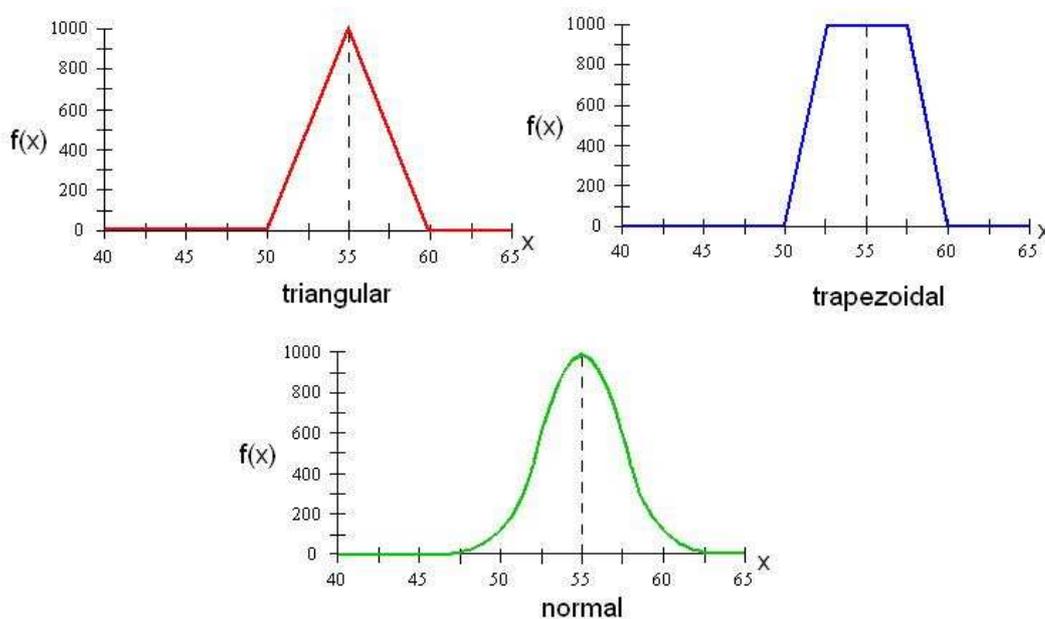


Figura 3.7 – Exemplos de funções de pertinência.

As funções de pertinência, em geral, mapeiam conjuntos em um intervalo de 0 a 1, partindo da classificação totalmente pertencente (1), passando por valores intermediários de grau de pertinência e chegando a totalmente “não-pertencente” (0). É possível perceber que a definição de conjuntos nebulosos abrange os conjuntos abruptos (*crisp*), uma vez que é possível determinar uma função que tem por imagem apenas dois valores distintos do conjunto $\{0,1\}$.

3.3.3 Operações com conjuntos nebulosos

Existem algumas operações básicas que são usadas para manipular as informações contidas nos conjuntos nebulosos, contemplando inclusive as operações com conjuntos abruptos (Tabela 3.1)[16]:

Tabela 3.1 - Operações Nebulosas

Operação	Conectivos da lógica de primeira ordem	Conectivos na Lógica Nebulosa
Interseção	A e B = $A \cap B$	$\mu_{A \cap B}(x) = \min_x\{ \mu_A(x), \mu_B(x) \}$
União	A ou B = $A \cup B$	$\mu_{A \cup B}(x) = \max_x\{ \mu_A(x), \mu_B(x) \}$
Complemento	\bar{A}	$\mu_{\bar{A}}(x) = 1 - \mu_A(x)$

3.3.4 Raciocínio nebuloso

A função de um raciocínio nebuloso é determinar uma possível conclusão a partir de uma série de premissas imprecisas. Esse tipo de raciocínio é na maior parte de natureza qualitativa e não quantitativa, assim é necessário utilizar a lógica nebulosa ao invés da lógica clássica.

O raciocínio nebuloso é um raciocínio que chega a uma conclusão baseado em dados imprecisos, representados por graus de pertinência a um conjunto nebuloso. No raciocínio nebuloso trabalha-se com imprecisão, envolvendo processos tais como: nebulização (*fuzzyfication*) e denebulização (*defuzzyfication*) [16].

Para explicar os procedimentos envolvidos em um raciocínio nebuloso é proposto um pequeno sistema (Figura 3.8) [16].

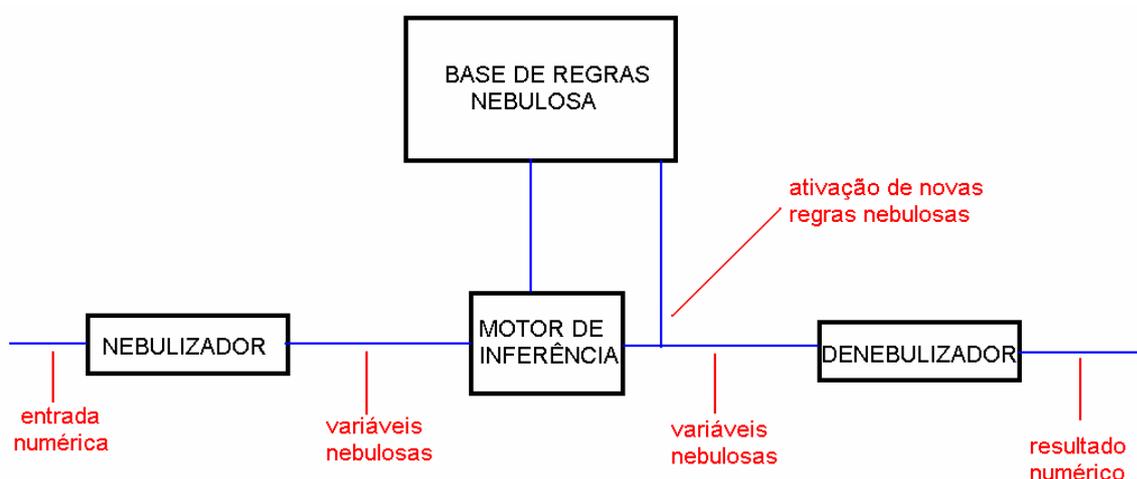


Figura 3.8 – Sistema nebuloso.

Este sistema mapeia entradas abruptas em saídas abruptas e é basicamente formado por quatro componentes: as regras, o nebulizador, o motor de inferência e o denebulizador.

3.3.4.1 Regras

Podem ser fornecidas pelo especialista ou ser extraída de dados numéricos. Em ambos os casos as regras de inferência são expressas como declarações do tipo “SE...ENTÃO”. Por exemplo : “ SE em um transformador de 230/138 kV os relés 51 e 50 (sobrecorrente) atuaram e os relés 49 (de imagem térmica) atuaram ou a temperatura no transformador é alta e status do disjuntor é fechado ENTÃO sobrecarga do transformador”. Essa regra mostra que se precisa de uma compreensão de :

1. variáveis lingüísticas versus valores numéricos das variáveis (relés versus 51);
2. variáveis lingüísticas quantificadoras (temperatura no transformador pode ter um número finito de termos lingüísticos relacionados com ela, podem ir de extremamente alta até muito baixa) o qual é feito utilizando funções de pertinência nebulosa;
3. conexões lógicas para variáveis lingüísticas, “e”, “ou” etc.;
4. implicações, por exemplo “Se A então B”.

Além de todas estas implicações é necessário entender e dominar o procedimento de combinar regras para obter um bom resultado.

3.3.4.2 Nebulizador

Mapeia valores numéricos de entrada em conjuntos nebulosos. Isto é necessário para ativar regras que estão em termos de variáveis lingüísticas, as quais possuem conjuntos nebulosos associados a eles. Estes conjuntos nebulosos podem ser representados por funções do tipo impulso, triangular, trapezoidal, normal, tipo S, tipo Z, tipo PI, entre outras. Cada função deve ser escolhida com cuidado para atribuir a representatividade da imprecisão ao conjunto [16].

3.3.4.3 Motor de inferência

Mapeia conjuntos nebulosos em conjuntos nebulosos. Ele manipula o caminho no qual as regras são combinadas. Da mesma maneira como os humanos utilizam muitos tipos diferentes de procedimentos inferenciais na compreensão de

pensamentos ou para a tomada de decisão, existem diversos processos inferenciais em lógica nebulosa [16].

3.3.4.4 Denebulizador

Mapeia conjuntos nebulosos de saída em valores numéricos. Em uma aplicação de controle, por exemplo, seria um número corresponde a uma ação de controle ou em uma aplicação de processamento de sinais poderia corresponder a uma predição do comportamento do sinal observado [16].

Existem vários métodos pesquisados e popularizados, porém alguns se destacam, o denebulizador máximo e o denebulizador do centróide.

O denebulizador máximo examina o conjunto nebuloso B e escolhe como sua saída o valor de y para o qual $\mu_B(y)$ é o máximo. Isso pode direcionar a resultados peculiares ou pode ter valores altos sem levar em consideração todos os valores sobre os quais encontra-se representado o conjunto nebuloso [16].

O denebulizador do centróide determina o centro de gravidade (centróide), \bar{y} , de B e utiliza este valor como a saída do sistema. O valor do centróide é calculado por:

$$\bar{y} = \frac{\int_S y \mu_B(y) dy}{\int \mu_B(y) dy} \quad (10)$$

onde:

- \bar{y} - centróide;
- S - domínio de $\mu_B(y)$;
- $\mu_B(y)$ – função de pertinência;
- y – valor abrupto.

Freqüentemente S é discretizado, de modo que \bar{y} pode ser aproximado pela utilização de somatório no lugar da integração. O denebulizador do centróide sempre tem valor único, no entanto este é geralmente difícil de calcular.

Para a correta utilização das técnicas de IA (RNA e LN) é necessário estruturar o sistema de ensaios proposto. Com este objetivo, o capítulo 4 apresenta as

grandezas analisadas e selecionadas, as adequações feitas no sistema de ensaios atual e o tipo de RNA escolhido.

4 ESTRUTURAÇÃO DO SISTEMA NEURAL DE ENSAIO

O tempo despendido nos ensaios de desempenho é elevado devido ao longo período de estabilização ou transitório. Na tentativa de realizar esses ensaios em um tempo muito menor é proposto um novo sistema de ensaio.

De acordo com a norma ISO 917 [4] os resultados dos ensaios são calculados somente com base nos dados de regime permanente, em razão disto os dados referentes ao transitório geralmente não são analisados ou muito menos armazenados. Sem dispor de uma base de dados e uma estrutura de ensaios direcionada à análise durante o transitório, foi realizado a estruturação e desenvolvimento do sistema neural de ensaio (SNE).

Na estruturação é feito um planejamento do que é medido, quais são as ações necessárias para a preparação da bancada de ensaios, quais grandezas são mais indicadas para a inferência das características de regime permanente e qual a RNA mais adequada.

4.1 IDENTIFICAÇÃO DAS GRANDEZAS ANALISADAS

Como já apresentado, os ensaios de desempenho simulam diversas condições de operação de um compressor e, para que o sistema seja capaz de controlar o processo e fornecer dados confiáveis, uma grande quantidade de medições é realizada. A bancada de ensaios, com os métodos C e F implementados, possui uma série de medições instaladas, denominadas medições normais, que são apresentadas na tabela 4.1:

Tabela 4.1 – Medições normais.

n ^o	Grandeza	n ^o	Grandeza
1	temperatura de entrada do compressor	10	tensão nas resist. de aquecimento
2	temperatura de entrada do trocador	11	pressão de sucção
3	temperatura do ambiente climatizado	12	pressão de descarga
4	temperatura de descarga do compressor	13	tensão eficaz no compressor
5	temperatura do separador de óleo	14	corrente eficaz no compressor
6	temperatura do ambiente do trocador	15	potência ativa consumida pelo compressor
7	temperatura da carcaça (lateral)	16	fluxo de massa de refrigerante
8	temperatura de saída do trocador	17	capacidade de refrigeração (método C)
9	potência dissipada nas resistências de aquecimento	18	capacidade de refrigeração (método F)

As grandezas expostas na tabela 4.1 são muito importantes e carregam uma grande quantidade de informação a respeito do desempenho do compressor, porém elas podem ser insensíveis a alguns fenômenos que ocorrem durante o transitório ou ter um tempo de estabilização muito elevado.

Pela falta de uma base de dados consistente sobre o transitório e buscando novas medições para auxiliar os modelos neurais na inferência do desempenho do compressor, foi realizado um estudo para definição de medições adicionais.

Sabendo que os ensaios abordados são executados com a carcaça do compressor já soldada (pronto para ser instalado em um sistema de refrigeração), a implementação de medições intrusivas no compressor não é possível, sobrando medições na parte externa do compressor e medições internas e externas nos outros componentes do circuito (evaporador, tubulação, condensador etc.). Considerando que as medições normais continuam a ser realizadas, a lista de grandezas adicionais a serem analisadas durante os ensaios é exposta na tabela 4.2:

Tabela 4.2 – Medições adicionais.

n ^o	Grandeza	n ^o	Grandeza
19	potência aparente consumida pelo compressor	26	temperatura da carcaça (solda)
20	potência reativa consumida pelo compressor	27	temperatura da carcaça (curva do óleo)
21	fator de potência do compressor	28	vibração do compressor (direção vertical)
22	pressão de entrada no calorímetro	29	vibração do compressor (direção horizontal)
23	pressão de saída do calorímetro	30	componentes harmônicas de corrente (1 a 15)
24	temperatura da carcaça (topo)	31	quantidade de óleo no separador
25	temperatura da carcaça (fundo)		

A aquisição dos valores de potência reativa, aparente e do fator de potência busca identificar mudanças construtivas do motor ou desbalancamento das impedâncias do circuito elétrico, refletindo em um consumo de potência ativa maior. A medição do fator de potência e das potências aparente, ativa e reativa é redundante, sendo eliminada na fase de classificação.

As quatro novas medições de temperatura da carcaça fazem o mapa de distribuição de temperaturas no compressor e são instaladas em pontos estratégicos (Figura 4.1). A temperatura no topo é a mais alta da carcaça, uma vez que o óleo que lubrifica o motor é expelido neste ponto. Na emenda (solda) é possível identificar algum problema na montagem ou no processo de soldagem. Na “curva” tenta-se avaliar o nível do óleo dentro do compressor, partindo do princípio que o óleo está em uma temperatura mais elevada e que sua inércia térmica é diferente do fluido que preenche o compressor. No fundo do compressor o óleo permanece acumulado, assim nessa medição estima-se a temperatura do óleo em repouso.



Figura 4.1 – Pontos para medição de temperatura da carcaça.

As medições de vibração são realizadas em dois pontos diferentes analisando duas direções, na vertical e horizontal em relação à base do compressor. Para cada ponto são medidas e analisadas diversas faixas de frequência para poder caracterizar algum comportamento específico nos compressores ensaiados [29]. Os dois pontos podem ser vistos na figura 4.2.



Figura 4.2 – Medição de vibração.

A medição das harmônicas, da primeira à décima quinta, carrega informações a respeito da forma de onda da corrente que circula no circuito elétrico do compressor. As imperfeições construtivas e o circuito elétrico do compressor distorcem a forma onda senoidal da corrente do motor. Os valores medidos podem revelar um consumo de potência ativa maior ou menor, identificado pela presença de harmônicas [29].

A quantidade de óleo presente em um compressor é fixada pelo fabricante e deve respeitar um nível mínimo mesmo quando em operação, pois este elemento é essencial para o seu funcionamento, servindo como lubrificante e transmissor de calor. Embora não seja desejável, uma boa parte do óleo circula no sistema junto com o fluido refrigerante e, para não ficar acumulado na bancada de ensaios, ele é separado por um dispositivo chamado separador de óleo, colocado logo após a descarga do compressor. A quantidade de óleo despendida e separada durante o ensaio pode ser um indicador do bom funcionamento do compressor.

As grandezas listadas na tabela 4.1 possuem os respectivos sistemas de medição instalados na bancada, porém para as medições adicionais (Tabela 4.2) é necessário especificar ou desenvolver e instalar todos os sistemas de medição. Esse assunto será abordado no item 4.2 .

4.2 ADEQUAÇÃO DO SISTEMA À UTILIZAÇÃO DAS TÉCNICAS DE IA

Para o novo sistema de ensaio proposto, diversas adaptações e desenvolvimentos precisam ser executados na bancada de ensaios, dividindo-se em três partes, as mudanças no programa de operação da bancada (*software*), as melhorias na automação da bancada e o desenvolvimento dos sistemas de medição para as grandezas adicionais.

4.2.1 Mudanças no programa (software)

A versão original do programa de operação da bancada, feita em Labview, realiza as aquisições das medições normais em intervalos de dez segundos, controla os processos necessários, calcula os valores de capacidade de refrigeração, consumo de potência ativa e coeficiente de desempenho e grava os dados de regime permanente em um arquivo de texto.

Para o novo sistema de ensaio o programa precisa de algumas modificações. Primeiramente é alterada a gravação dos dados, passando a guardar as leituras de todas as grandezas desde o início do ensaio, para possibilitar a análise do transitório. Posteriormente é incluída no programa a aquisição das medições citadas no item 4.1 .

O intervalo de aquisição dos dados era de dez segundos, mas para a análise do transitório esse período pode ser muito longo, uma vez que as variáveis estão em processo de estabilização e com grandes variações diferentemente do regime permanente. Para isso o intervalo foi reduzido para cinco segundos, não podendo diminuir mais do que isso, devido ao tempo necessário para comunicação do computador com a bancada e ao tempo de leitura de alguns equipamentos.

4.2.2 Melhorias na automação da bancada

Para excluir a influência do operador, o que pode aumentar o tempo de ensaio e dificultar a tarefa de inferência pelas redes neurais, deve-se efetuar o máximo de automação possível na bancada. É desejável que o transitório dos ensaios siga um mesmo padrão de controle, para que eventuais fenômenos ocorridos sejam atribuídos somente às características do compressor e não a mudanças na operação da

bancada. O quanto antes as variáveis controladas estabilizarem mais rápida pode ser a inferência das características de regime permanente por parte das técnicas de IA. Vale ressaltar que algumas características inerentes ao compressor são afetadas indiretamente pelo controle do sistema e que estas características terão comportamentos similares em casos representativos.

Segundo um estudo realizado por Poletto [48], dois processos de controle são muito importantes dentro do ensaio, o controle da pressão de sucção e da temperatura de saída do evaporador (variável relacionada com a temperatura interna do calorímetro). O controle da pressão de sucção já era executado, porém com alguns pequenos erros e com um tempo de estabilização não muito pequeno. O sistema de controle original utilizava um controlador PID-Eurotherm e uma válvula agulha motorizada como atuador. A partir disto um novo sistema de controle foi implementado.

Inicialmente a pressão é medida com o emprego de um transmissor de pressão e uma placa de aquisição de sinais. Com base no valor medido é calculado o sinal de controle no computador. O sinal físico é gerado pela própria placa, que apresenta funcionalidade de geração de sinais analógicos. Esse sinal, de baixa potência, passa por um estágio amplificador e alimenta um regulador de pressão de uma linha pneumática.

A pressão na saída do regulador é proporcional ao sinal de controle aplicado em sua entrada. O sinal de pressão que sai do regulador é responsável pelo controle da abertura de uma válvula proporcional. Essa válvula é o atuador final do sistema, visto que permite maior ou menor passagem de fluido refrigerante no estado gasoso para a câmara que alimenta o compressor. Essa maior ou menor passagem é que determinará a pressão na entrada do compressor. Esquematicamente, o sistema de controle é apresentado na figura 4.3:

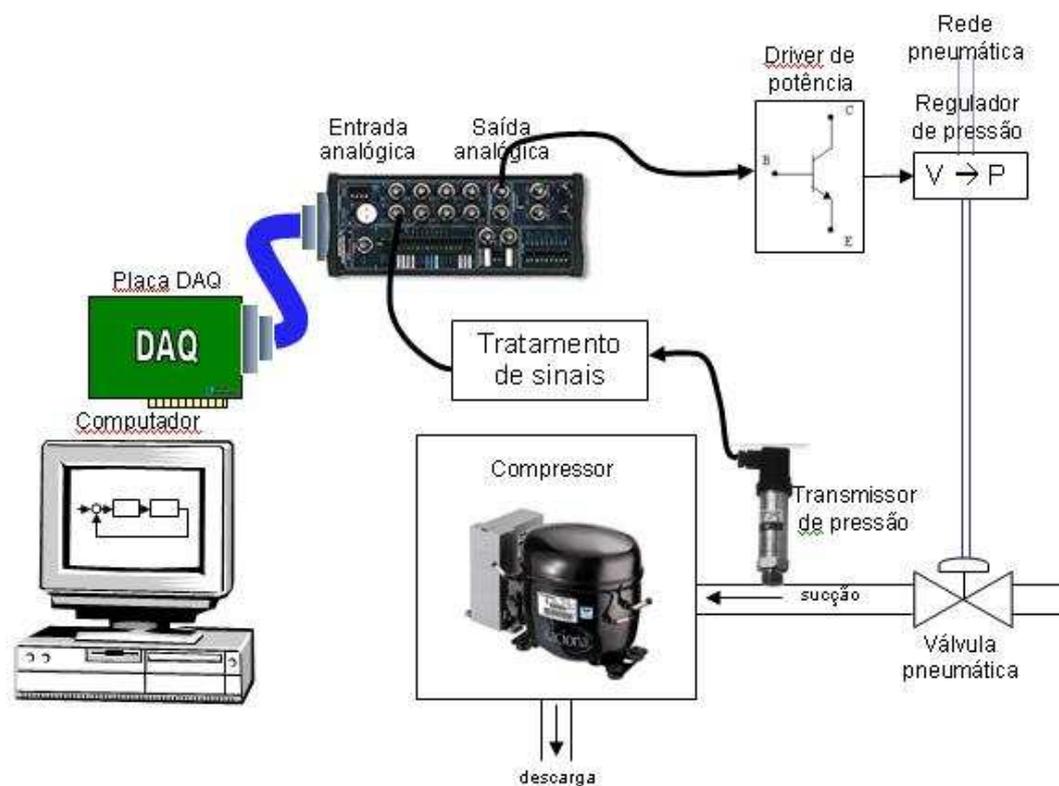


Figura 4.3 – Controle da pressão de sucção.

O controle automático da temperatura de saída do evaporador, por sua vez, encontrava-se com a opção de controle manual ou PID, sendo que o segundo divergia. Além desta limitação, o sistema anterior de alimentação das resistências (atuador) atribuía ao controle uma resolução limitada. A situação anterior do controle é mostrada na figura 4.4:

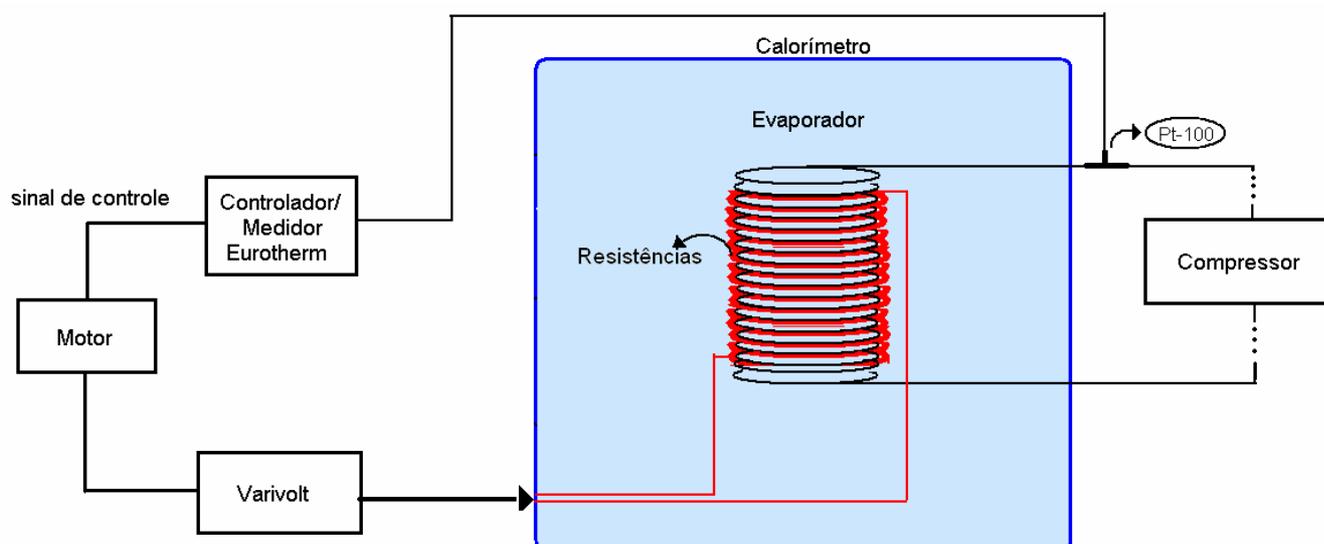


Figura 4.4 – Situação anterior do controle de temperatura de saída do evaporador.

O sistema de controle e medição de temperatura é composto pelo controlador/medidor Eurotherm e um Pt-100. O controlador/medidor realiza a alimentação do termorresistor, a aquisição da tensão e corrente sobre ele e o processamento desses dados, obtendo a temperatura de saída do evaporador. O controle também é realizado pelo controlador/medidor, através de um PID ou manualmente, enviando um sinal de controle para o sistema de alimentação das resistências de aquecimento [30].

O sistema de alimentação é constituído de um varivolt equipado de um motor de seleção de tap. O motor recebe o sinal de controle, muda de posição e seleciona um tap que corresponde a uma tensão, imposta pelo varivolt, nos terminais das resistências de aquecimento. Como estes tap's são muito limitados, a resolução do sistema também é limitada.

No novo controle desenvolvido os problemas foram solucionados, agora a estabilidade é atingida automaticamente e a resolução do atuador é boa (Figura 4.5).

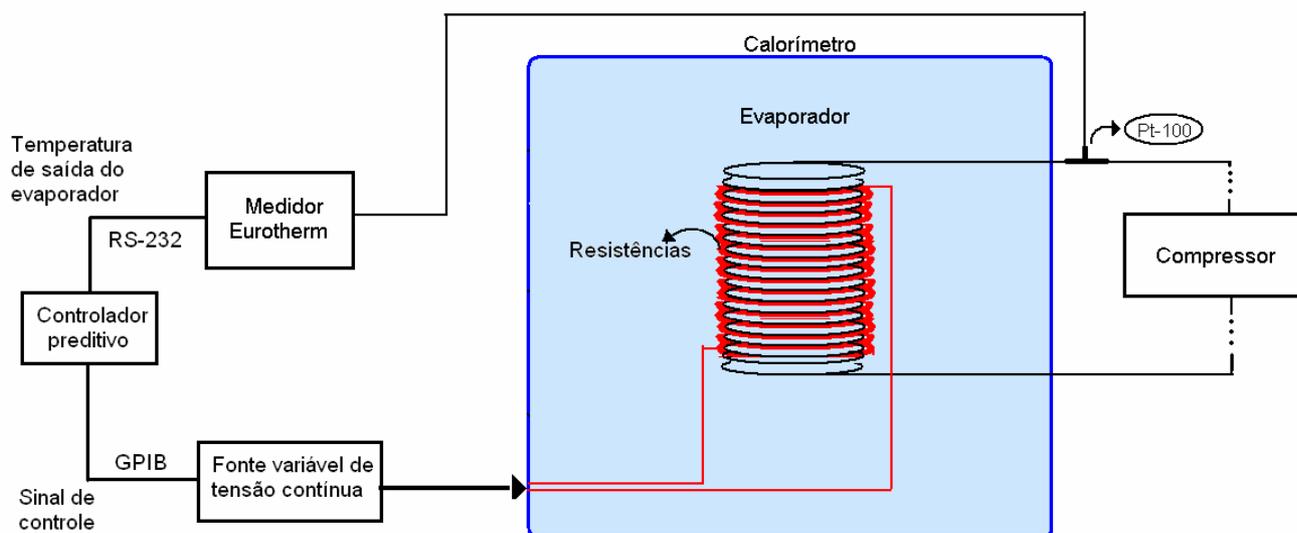


Figura 4.5 – Situação atual do controle de temperatura de saída do evaporador.

A medição da temperatura continua a ser realizada com o medidor Eurotherm e a comunicação com o computador é estabelecida via RS-232. O controle passa a ser realizado por um controlador preditivo (*software*), controlando a fonte variável de tensão contínua via GPIB, substituindo o conjunto motor e varivolt.

O controle preditivo consegue atuar eficientemente mesmo em um sistema com grande inércia térmica, fato que dificultava o controle PID. Para estabelecer tal controle, foi levantado o modelo aproximado da planta e implementado o controle com

base nos parâmetros estabelecidos por simulação e ajustados posteriormente durante a operação.

4.2.3 Desenvolvimento dos novos sistemas de medição

O objetivo da implementação dos novos sistemas de medição é o estudo do transitório, na tentativa de observar algum fenômeno que ajude na avaliação dos parâmetros do compressor. Pensando neste objetivo, o projeto e desenvolvimento dos novos sistemas de medição foram realizados considerando uma incerteza bem abaixo do indicado pelas normas, para que, assim, os fenômenos não ficassem mascarados na incerteza, identificando o comportamento real do compressor.

Como, somente após a aquisição e análise dos dados, é possível estabelecer alguma conclusão sobre a utilização definitiva destes novos sistemas de medição, foram desenvolvidos modelos provisórios. No caso de importância comprovada, uma versão final deve ser construída.

4.2.3.1 Temperaturas da carcaça

Atualmente as medições de temperatura na bancada de ensaio são feitas com termorresistores de platina (Pt100) e controladores Eurotherm. Os controladores realizam a alimentação, a medição de resistência e a conversão, segundo a curva do termorresistor, de resistência para temperatura. O esquema pode ser visto na figura 4.6:

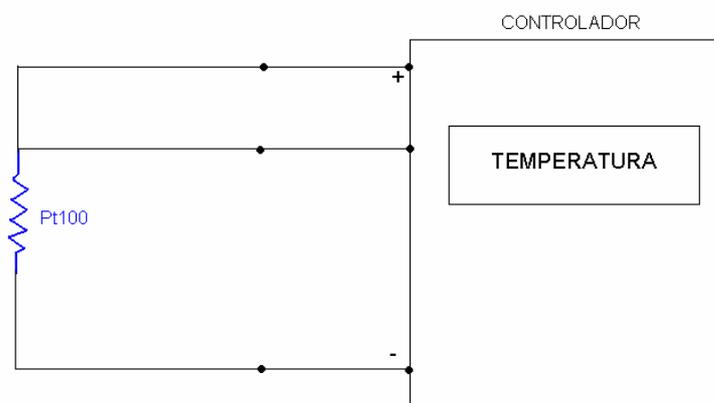


Figura 4.6 – Medição de temperatura com controlador Eurotherm.

Como o controlador tem preço muito elevado, incerteza grande e é necessário instalar mais quatro pontos de medição de temperatura, foi proposto um novo sistema de medição. Este novo sistema continua a usar termorresistores de platina (Pt100), porém as configurações de alimentação e medição são diferentes, seguindo o modelo de Anderson Loop [31].

O circuito de laço de corrente constante, também conhecido como Anderson Loop (nome atribuído em homenagem ao engenheiro que desenvolveu o circuito, Karl F. Anderson), é um conceito de circuito para condicionamento de sinais de transdutores resistivos, podendo ser implementado em diversas configurações, dependendo da aplicação [31], [32], [33].

Basicamente a estrutura proposta é composta por uma fonte de corrente constante em série com os transdutores resistivos e o resistor de referência. A medição de tensão sobre todos os elementos resistivos e o processamento (soma) das mesmas é feita através de amplificadores operacionais ou algum outro dispositivo qualificado para tal fim [31], [34], [35]. Um diagrama do sistema final desenvolvido encontra-se na figura 4.7. Nessa figura encontram-se os nomes dos componentes e a topologia do circuito.

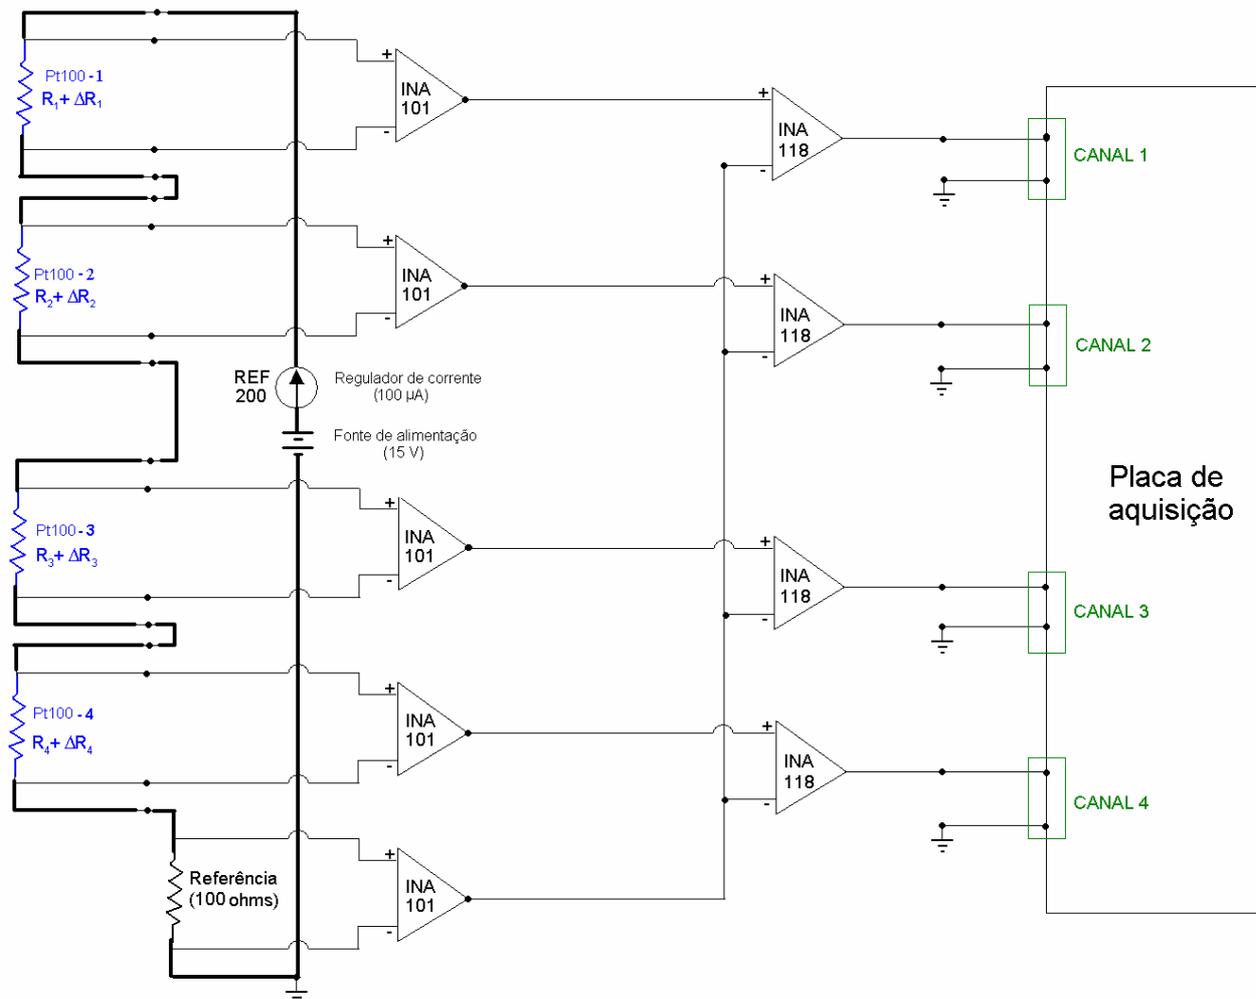


Figura 4.7 – Sistema de medição de temperatura implementado.

Depois do sistema implementado, foi realizado uma calibração e as incertezas finais, para as quatro cadeias de medição completas, foram calculadas. A incerteza final inclui as parcelas sistemáticas e aleatórias, inclusive a incerteza do padrão de calibração [37],[38],[39]. Os valores de incerteza obtidos estão expostos na tabela 4.3:

Tabela 4.3 – Incertezas finais dos sistemas de medição de temperatura associadas a cada transdutor.

Incertezas finais [°C] (95%, k=2)	Transdutores			
	pt100 -1	pt100 -2	pt100 -3	pt100 -4
	±0,1	±0,1	±0,1	±0,1

Existem inúmeras vantagens associadas a este circuito, entre as principais pode-se citar:

- imunidade à resistência dos cabos de ligação para medição;
- medição diferencial;

- linearidade da variação de resistência;
- dobro da sensibilidade do circuito de Ponte de Wheatstone (PW);
- utilização de múltiplos transdutores.

4.2.3.2 Vibração do compressor

Em um compressor hermético encontramos três tipos de vibração (classificação quanto a origem) [40]:

- desbalanceamento de forças presentes no equipamento;
- desbalanceamento de torques;
- flexão do corpo.

Os dois primeiros são classificados como de baixa frequência e o terceiro de alta frequência. Algumas fontes das vibrações de alta frequência são válvulas e fluxo de descarga de refrigerante [40].

O ruído gerado dentro do compressor hermeticamente fechado também é propagado pela carcaça, sendo que até 500 Hz as fontes são os movimentos do corpo sólido da carcaça (amplitude sensível às condições de operação do compressor) e de 600 Hz a 2,5 kHz as fontes são deformações localizadas na carcaça causadas pelos mecanismos internos do compressor. Um dado importante é a frequência natural da carcaça, que se encontra em aproximadamente 2 kHz ou 2,5 kHz [40]. Nestas frequências, qualquer mínima excitação vai ser amplificada. A análise dos sinais de vibração é feita como auxílio da transformada de Fourier e a frequência máxima analisada é de aproximadamente 10 kHz [41].

Segundo o teorema de Nyquist, para garantir que não haja sobreposição do espectro de frequência durante o processo de amostragem é necessário que a frequência de amostragem seja maior que duas vezes a frequência máxima do sinal amostrado. Porém, para garantir que a amplitude do sinal amostrado esteja correta, devido a imperfeições do sistema de aquisição, como de conversores analógico digitais, a frequência de amostragem neste caso precisa ser 5 vezes maior que a largura de banda.

Os compressores herméticos que são ensaiados nas bancadas são compressores que já estão prontos para venda, já estão lacrados e não podem ser

abertos. Assim, a única opção para medição de vibração é na carcaça. As grandes variações da pressão no cilindro e a pulsação do muffler de sucção são as maiores fontes de vibração na carcaça e as molas são os elementos que transmitem as vibrações dos componentes internos para a carcaça [41].

Para a medição da vibração do compressor foram utilizados acelerômetros PCB (Figura 4.8) e uma placa de aquisição rápida da National Instruments, modelo 4452. A frequência máxima adquirida é 10 kHz e a frequência de amostragem é 50 kHz.



Figura 4.8 – Acelerômetro para medição de vibração.

O processamento dos dados é realizado com o auxílio de ferramentas do Labview, utilizando a transformada de Fourier e análise de oitavas. Uma oitava é o intervalo entre duas frequências ($f_2 - f_1$), em que a razão entre elas (f_2/f_1) é dois. A ISO indica os valores centrais para as oitavas (Tabela 4.4). O valor armazenado no ensaio é a potência do espectro de frequência presente em cada oitava de 1 kHz a 10 kHz.

Tabela 4.4 – Frequências centrais segundo a ISO.

Número das bandas segundo a ISO	Frequência central da banda para as oitavas [Hz]	Frequência central da banda para 1/3 de oitava [Hz]
11, 12, 13	16	12.5, 16, 20
14, 15, 16	31.5	25, 31, 40
17, 18, 19	63	50, 63, 80
20, 21, 22	125	100, 125, 160
23, 24, 25	250	200, 250, 315
26, 27, 28	500	400, 500, 630
29, 30, 31	1000	800, 1000, 1250
32, 33, 34	2000	1600, 2000, 2500
35, 36, 37	4000	3150, 4000, 5000
38, 39, 40	8000	6300, 8000, 10000
41, 42, 43	16000	12500, 16000, 20000

4.2.3.3 Medição da quantidade de óleo no separador

No caso da medição da quantidade de óleo no separador não existe uma solução comercial, nem tão pouco indicações na literatura. Algumas condições tornam o desenvolvimento do sistema de medição ainda mais difícil: o circuito de refrigeração é fechado e não pode haver contaminação com umidade ou fuga de fluido refrigerante; no final do ensaio o óleo analisado precisa retornar ao compressor; a vazão de óleo é muito pequena, impedindo a utilização de medidores tradicionais de vazão.

Para mensurar tal grandeza foi escolhido um sistema de medição óptico com processamento de imagem, um “gotejador” e algumas modificações no circuito de retorno de óleo do separador ao compressor.

Em série com o separador de óleo, na tubulação de retorno, foi instalado um visor de líquido modificado. O visor de líquido é um dispositivo com a face transparente, utilizado em refrigeração para observar a passagem de refrigerante na tubulação e quantificar a umidade do sistema através de um indicador de umidade. Foi implementado um “gotejador”, com o auxílio de uma agulha e solda, dentro do visor de líquido (Figura 4.9).

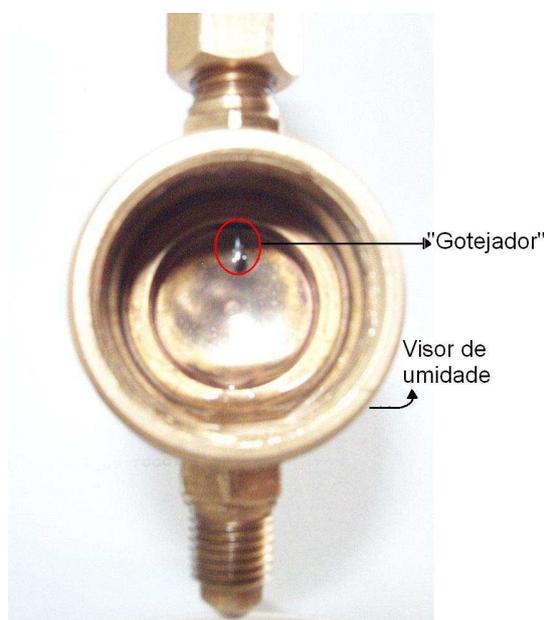


Figura 4.9 – Visor de líquido e “gotejador”.

Para contar o número de gotas de óleo que passam pelo gotejador utilizou-se uma câmera digital e um programa de processamento de imagem (Figura 4.10 e Figura 4.11).

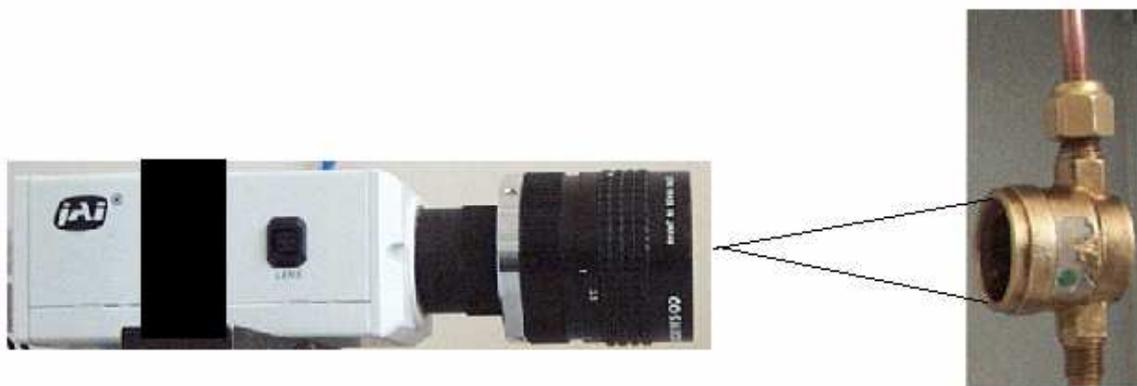


Figura 4.10 – Sistema de medição da quantidade de óleo.

A contagem é realizada através da variação de luminosidade de uma linha de píxeis. A primeira imagem, depois de iniciado o ensaio, é armazenada como padrão, e caso a luminosidade ultrapasse um limite estabelecido e retorne ao valor do padrão efetua-se a contagem de uma gota. O valor só é computado no retorno da luminosidade, com o objetivo de evitar a contagem dupla quando uma gota permanece um tempo maior antes de se desprender. A gota e a linha de píxeis podem ser vistas na figura 4.11.

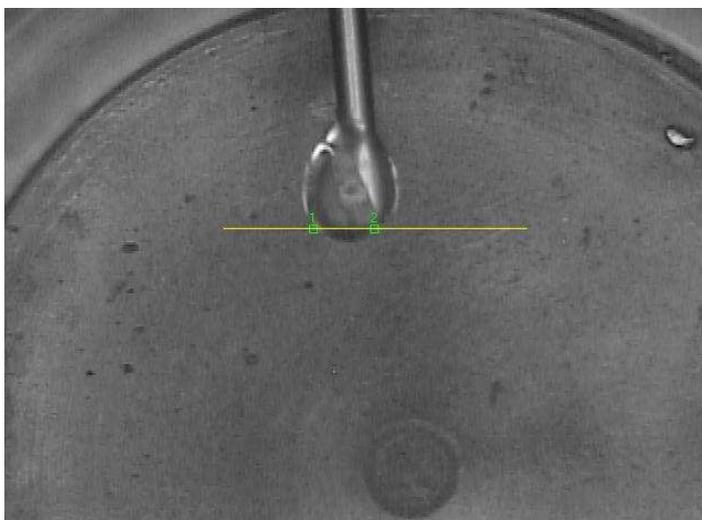


Figura 4.11 – Imagem do processamento da gota.

A aquisição e processamento da imagem ocorrem em períodos de cem milissegundos, porém o valor do número de gotas é gravado em períodos de cinco segundos, como as demais medições.

4.2.3.4 Medição das componentes harmônicas de corrente

As medições elétricas na bancada de ensaios foram objetos de estudo de outra dissertação pertencente ao mesmo projeto em parceria com a Embraco. Desse estudo foi utilizada a medição das componentes harmônicas da corrente do compressor. Por não se tratar do foco deste trabalho, é somente descrito o princípio básico da medição a partir do circuito exposto na figura 4.12:

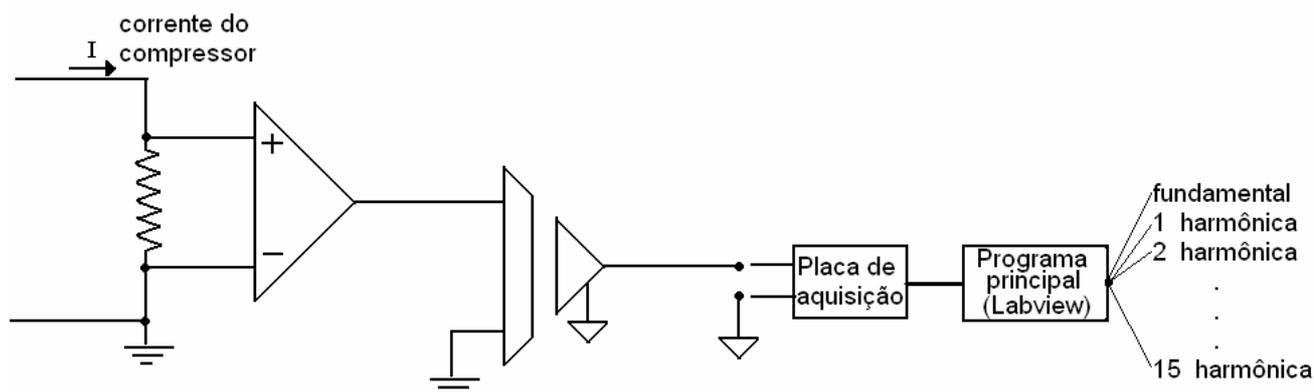


Figura 4.12 – Circuito para medição das componentes harmônicas de corrente.

Foi utilizado um *shunt* para medir a corrente do compressor. Esse resistor tem características e comportamento bem definidos pelo fabricante, permitindo a utilização e a avaliação da incerteza deste sistema. O programa principal faz todo o processamento dos dados e são armazenados todos os valores das componentes harmônicas (de 1 a 15), a cada execução do programa principal da bancada de ensaios. A frequência amostragem da placa de aquisição é 100 kHz e o tempo de aquisição de 1 s, porém somente de 5 em 5 s são gravados os valores médios calculados.

Para a medição de potência reativa e aparente e fator de potência só foi necessário utilizar os medidores da fonte de alimentação e uma alteração no programa principal.

4.3 SELEÇÃO DAS GRANDEZAS ANALISADAS

A priori todas as grandezas descritas na tabela 4.1 e na tabela 4.2 representavam possíveis entradas para a rede neural que realizará o processo de inferência do desempenho do compressor. Porém, após a execução dos ensaios, dispondo dos resultados calculados segundo a ISO 917 e todas as variáveis medidas

durante o transitório, pode-se analisar, classificar e selecionar as grandezas que agregam mais informação a respeito da capacidade de refrigeração e consumo de potência ativa.

O processo de análise, classificação e seleção foi dividido em variáveis de temperatura, pressão, fluxo mássico e capacidade de refrigeração, grandezas elétricas, vibração e quantidade de óleo. A classificação é realizada de acordo com a quantidade de informação agregada para a inferência de capacidade ou consumo, seguindo a escala: 0 para sem informação; 1 quantidade média de informação (pode ser explorado, mas possui alguma barreira que dificulta o uso); 2 para grande quantidade de informação.

A fim de melhorar o entendimento a respeito do critério utilizado, são exemplificados três casos de classificação. Na comparação direta entre ensaios com diferentes capacidades de refrigeração (valores de regime permanente), a temperatura de entrada do compressor, por ser uma variável controlada, se manteve no mesmo valor de regime com transitórios semelhantes, por isso foi atribuído classificação “0”, significando que esta variável não é sensível a mudanças na capacidade. Isso significa que para diferentes resultados finais a variável apresentou o mesmo comportamento.

No caso da temperatura do topo da carcaça, em ensaios com diferentes capacidades de refrigeração, diferentes temperaturas eram observadas, conferindo classificação “2”, o que indica uma boa fonte de informações para a inferência dos parâmetros de regime permanente. Para exemplificar a classificação 1, expõe-se o caso da vibração, onde a medição consegue identificar características comuns ao lote de fabricação do compressor, mas não diferencia as capacidades dentro do lote. A justificativa simplificada à classificação também é exposta nas tabelas 4.5 a 4.9.

4.3.1 Temperatura

Existem diversas variáveis de temperatura, algumas controladas, em função das condições de ensaios, e outras somente medidas. A tabela 4.5 indica quais são as variáveis de temperatura no sistema de ensaio e quais as respectivas classificações e justificativas.

Tabela 4.5 – Classificação das variáveis de temperatura.

Variável de temperatura	Classificação	Justificativa
entrada do compressor	0	Variável controlada e sem sensibilidade ao consumo e capacidade
entrada do trocador	0	Variável controlada e sem sensibilidade ao consumo e capacidade
ambiente climatizado	0	Variável controlada e sem sensibilidade ao consumo e capacidade
descarga do compressor	2	Valores específicos p/ cada compressor (sensível à cap. e cons.)
separador de óleo	0	Não é sensível à mudanças de consumo e capacidade
ambiente do trocador	0	Não é sensível à mudanças de consumo e capacidade
carcaça	1	Valores específicos p/ cada compressor (sensível à cap. e cons.)
saída do trocador	1	Variável controlada, mas com período de estabilização sensível à capacidade
carcaça - topo	2	Valores específicos p/ cada compressor (sensível à cap. e cons.)
carcaça - curva de óleo	1	Valores específicos p/ cada compressor (sensível à cap. e cons.)
carcaça - solda	1	Valores específicos p/ cada compressor (sensível à cap. e cons.)
carcaça - fundo	1	Valores específicos p/ cada compressor (sensível à cap. e cons.)

As variáveis controladas não adicionam informação alguma (classificação 0) para a inferência do desempenho do compressor, pois suas leituras no transitório e regime permanente são independentes da capacidade ou consumo do compressor. A única exceção é a temperatura de saída do trocador (classificação 1) que tem uma estabilização demorada e que depende um pouco da capacidade de refrigeração do compressor.

As duas variáveis com maior sensibilidade a mudanças de capacidade ou consumo são as temperaturas de descarga e do topo da carcaça, provavelmente em função da temperatura do motor e do conjunto cilindro e pistão. As outras medições da carcaça também são sensíveis, mas em menor nível.

4.3.2 Pressão

As variáveis de pressão em geral não são sensíveis à capacidade ou consumo, pelo fato de serem controladas ou terem comportamentos similares entre elas. As informações contidas nos transitórios das pressões de descarga e sucção têm possibilidade de serem usadas, mas o regime permanente é rapidamente atingido (Tabela 4.6).

Tabela 4.6 - Classificação das variáveis de pressão.

Variável de pressão	Classificação	Justificativa
sucção	0	*usar a leitura da placa de aquisição
descarga	1	Variável controlada com estabilização rápida
descarga (placa de aquisição)	0	*usar a outra leitura
entrada do calorímetro	0	Comportamento similar à descarga
sucção (placa de aquisição)	1	Variável controlada com estabilização rápida
saída do calorímetro	0	Comportamento similar à sucção

4.3.3 Fluxo de massa e capacidade instantânea de refrigeração

O fluxo de massa e os cálculos instantâneos de capacidade de refrigeração são as grandezas mais importantes para a inferência da capacidade de regime permanente, por isso todas têm classificação alta (Tabela 4.7).

Tabela 4.7 - Classificação das variáveis de fluxo de massa e capacidade de refrigeração.

Variável	Classificação	Justificativa
fluxo de massa	2	Variável sensível à capacidade
fluxo de massa- filtrado	2	Variável sensível à capacidade
fluxo de massa calculado através do calorímetro	1	Usar o fluxo de massa medido
capacidade calculada através do calorímetro	2	Variável sensível à capacidade
capacidade calculada através do fluxo de massa	2	Variável sensível à capacidade

Os dois métodos instalados obtêm direta ou indiretamente os valores de fluxo de massa e calculam a capacidade. Para obter mais informações durante o transitório as grandezas de ambos os métodos devem ser utilizadas. Existem duas justificativas para utilizar informações redundantes (fluxo de massa, capacidade calculada pelo fluxo de massa e capacidade calculada pelo calorímetro), a primeira é a incerteza de medição de cada medida e a segunda são os melhores resultados empíricos do sistema. Foram realizados diversos testes no sistema com e sem a utilização de informações redundantes e, mesmo sem uma explicação totalmente fundamentada, foi decidido utilizar informações redundantes em vista dos melhores resultados finais obtidos nesta configuração.

4.3.4 Grandezas elétricas

As grandezas elétricas mostraram-se essencialmente sensíveis ao consumo de potência ativa. As exceções são as variáveis relacionadas à tensão de alimentação, que são controladas e não apresentam variação significativa. A classificação das grandezas elétricas é vista na tabela 4.8.

Tabela 4.8 - Classificação das grandezas elétricas.

Grandeza elétrica	Classificação	Justificativa
tensão de alim. do compressor	0	Variável controlada e estável
corrente no compressor	2	Sensível ao consumo
freqüência da alimentação	0	Aproximadamente constante - 60 Hz
potência real consumida	2	Sensível ao consumo
potência aparente consumida	1	Já são usadas as potências ativa e reativa
potência reativa consumida	2	Sensível ao consumo e a retirada do capacitor
fator de potência do compressor	2	Sensível ao consumo
tensão nas resistências de aquec.	1	Usar somente a potência
corrente nas resistências de aquec.	1	Usar somente a potência
potência nas resistências de aquec.	2	Sensível à capacidade
componente DC na corrente do compressor	0	Não é sensível à mudanças de consumo e capacidade
componente fundamental na corrente do compressor	2	Sensível ao consumo
segunda harmônica (120Hz)	1	Sensível ao consumo
terceira harmônica (180Hz)	2	Sensível ao consumo
quarta harmônica (240Hz)	0	Não é sensível à mudanças de consumo e capacidade
quinta harmônica (300Hz)	2	Sensível ao consumo
sexta harmônica (360 Hz)	0	Não é sensível à mudanças de consumo e capacidade
sétima harmônica (420Hz)	2	Sensível ao consumo
oitava a décima quinta harmônica	0	Não é sensível à mudanças de consumo e capacidade

As potências, real e reativa, no transitório fornecem muitas informações para a inferência do valor de regime permanente. Além disto, as medições de corrente eficaz e as componentes harmônicas ímpares da corrente, medidas no transitório, são muito sensíveis ao consumo final do compressor. As componentes pares por sua vez não possuem variações significativas. A 2ª componente harmônica mostrou uma pequena variação com o consumo de potência ativa do compressor, porém esta variação, quando comparada com as componentes ímpares, fez com que essa variável ficasse em segundo plano, com classificação 1.

Quando comparadas as amplitudes das componentes harmônicas de dois compressores diferentes, fica clara a diferença de valores absolutos, da relação entre as componentes e da ordem de classificação de magnitude. Por exemplo, em alguns ensaios a 5ª harmônica é maior que a 7ª, já e em outros a 7ª maior que a 5ª.

4.3.5 Vibração

As medições de vibração têm um grande poder de identificar falhas na montagem de compressores [41], porém, em se tratando de inferir o desempenho, elas tornam-se um pouco limitadas. Os valores das potências das oitavas de freqüência, tanto vertical como horizontal, tiveram êxito ao diferenciar a capacidade ou consumo

de um lote de fabricação do compressor para o outro, mas a diferenciação dentro de um mesmo lote, mesmo com diferenças significativas nos resultados, não foi possível. Como visto na tabela 4.9 as baixas frequências não fornecem informação sobre o lote ou sobre a capacidade e consumo, já as altas frequências podem classificar o lote.

Tabela 4.9 - Classificação das variáveis de vibração.

Variável de vibração	Classificação	Justificativa
potência total das banda (vertical)	1	diferencia a capacidade do lote de compressor
potência total da banda (horizontal)	1	diferencia a capacidade do lote de compressor
oitava vertical (16 Hz)	0	sem variação
oitava vertical (31,5 Hz)	0	sem variação
oitava vertical (63 Hz)	0	sem variação
oitava vertical (125 Hz)	0	sem variação
oitava vertical (250 Hz)	1	diferencia a capacidade do lote de compressor
oitava vertical (500 Hz)	1	diferencia a capacidade do lote de compressor
oitava vertical (1000 Hz)	1	diferencia a capacidade do lote de compressor
oitava vertical (2000 Hz)	1	diferencia a capacidade do lote de compressor
oitava vertical (4000 Hz)	1	diferencia a capacidade do lote de compressor
oitava vertical (8000 Hz)	1	diferencia a capacidade do lote de compressor
oitava horizontal (16 Hz)	0	sem variação
oitava horizontal (31,5 Hz)	0	sem variação
oitava horizontal (63 Hz)	0	sem variação
oitava horizontal (125 Hz)	0	sem variação
oitava horizontal (250 Hz)	1	diferencia a capacidade do lote de compressor
oitava horizontal (500 Hz)	1	diferencia a capacidade do lote de compressor
oitava horizontal (1000 Hz)	1	diferencia a capacidade do lote de compressor
oitava horizontal (2000 Hz)	1	diferencia a capacidade do lote de compressor
oitava horizontal (4000 Hz)	1	diferencia a capacidade do lote de compressor
oitava horizontal (8000 Hz)	1	diferencia a capacidade do lote de compressor

4.3.6 Quantidade de óleo no separador

O sistema de medição da quantidade de óleo mostrou-se eficaz em seu funcionamento, porém o separador utilizado na bancada não demonstrou repetitividade suficiente para permitir a avaliação do desempenho do compressor pelo óleo despendido por esse. Desta forma essa variável não foi utilizada.

A utilização desta variável parece promissora caso algumas modificações sejam feitas no separador de óleo. A análise de relevância deve ser refeita com os dados obtidos nesta nova situação.

4.4 SELEÇÃO DA RNA MAIS ADEQUADA

Nos últimos tempos, a utilização de RNA para a inferência em processos dinâmicos tem se mostrado mais eficiente que outras técnicas convencionais como filtragem adaptativa, modelos de Markov, entre outros [42].

Para realizar a tarefa de inferência do desempenho do compressor em regime permanente através de dados do transitório existem diferentes abordagens com diferentes tipos de redes neurais ou recursos de inteligência artificial. As tarefas mais difíceis são definir qual é a estrutura do sistema neural de ensaio e qual a RNA a ser utilizada.

Para que a seleção da rede neural seja adequada é necessário conhecimento das características peculiares apresentadas pelo problema a ser solucionado. A estrutura do sistema neural de ensaios (Figura 4.13) é muito importante para essa seleção, pois ela delimita as características dos conjuntos de entrada e saída.

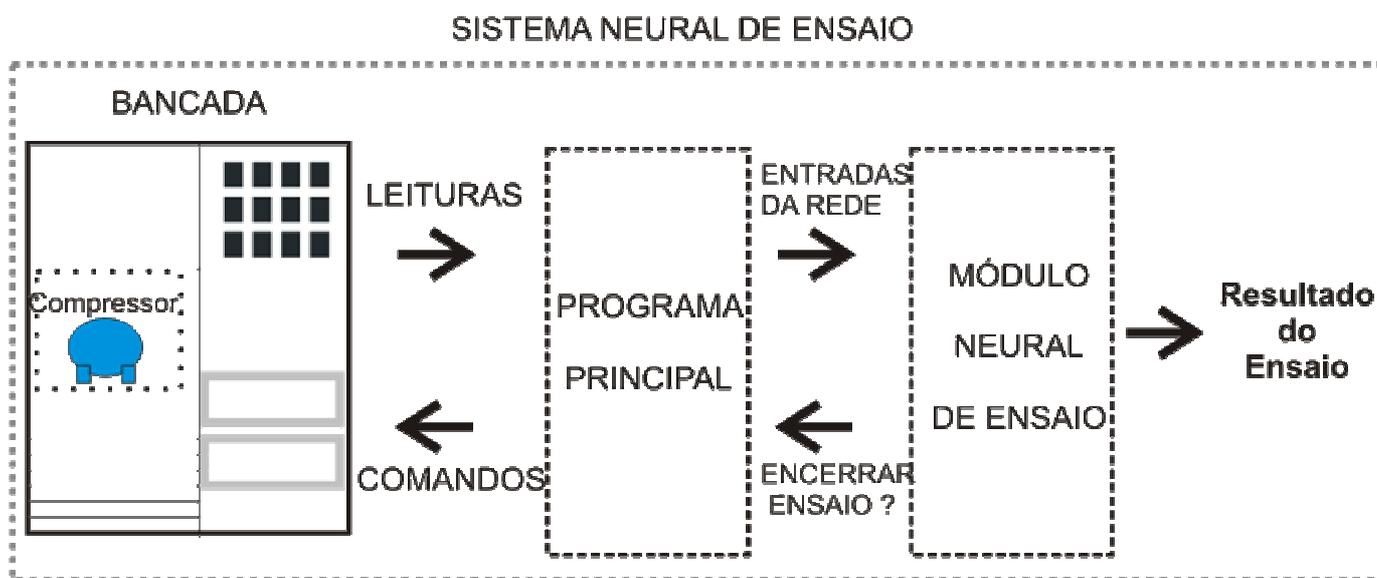


Figura 4.13 – Estrutura do sistema neural de ensaio.

Na estrutura proposta acima, os dados de entrada são apresentados ao módulo neural de ensaio (MNE) seqüencialmente durante o transitório em intervalos de cinco segundos. Como exposto no item anterior, somente algumas grandezas (leituras) representarão entradas para as redes neurais; as demais serão gravadas, mas não utilizadas. O resultado do sistema indicará em qual classe de capacidade de refrigeração e de consumo de potência ativa em regime permanente o compressor se

encaixa. No instante em que o MNE obtiver um resultado para o ensaio, ele enviará um comando ao programa principal para encerrá-lo.

O MNE será composto por duas redes neurais artificiais, uma para consumo de potência ativa e outra para capacidade de refrigeração. Elas serão independentes, porém poderão conter variáveis de entrada em comum. Isto se deve ao fato de que algumas variáveis são somente sensíveis a um parâmetro de saída e têm tempos de estabilização diferentes. O coeficiente de performance pode ser calculado a partir dos resultados obtidos com as duas redes.

Dispondo da forma com que os dados de entrada são apresentados e como deve ser a saída do sistema é possível caracterizar as RNA utilizadas como redes de inferência e classificação.

Por se tratar de um fenômeno essencialmente dinâmico, não linear e de inferência e classificação, segundo Gustafson [43], uma arquitetura muito indicada para tal aplicação é a perceptron multicamadas (MLP) direta com o algoritmo da retropropagação, utilizando neurônios dinâmicos na camada de entrada (Figura 4.14) [44] [45].

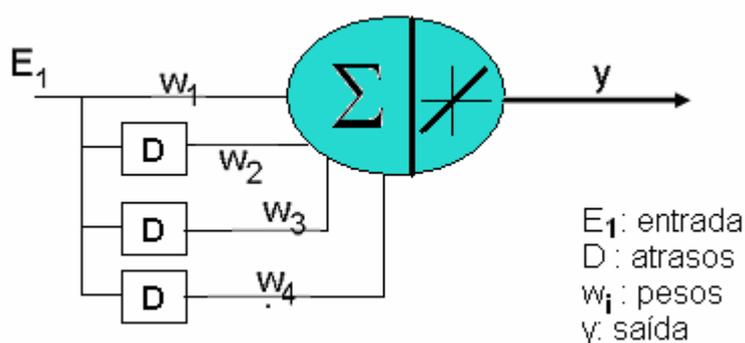


Figura 4.14 – Neurônios dinâmicos.

O uso de neurônios dinâmicos também atribui dinamismo à RNA, fazendo com que a saída em um certo instante de tempo dependa de valores anteriores (D representam os atrasos). A correta atuação da RNA depende da correlação entre a amostra atual da grandeza e as amostras anteriores, além da correlação entre todas as variáveis de entrada [46] [47].

Nesta abordagem, utilizando a MLP com a retropropagação, a rede é treinada com padrões de entrada e saída que representam respectivamente as medições do

transitório e as classes de desempenho em regime permanente do compressor (consumo e capacidade).

O número de neurônios e de atrasos, as funções de transferência, a função de treinamento e outras características das redes são determinados durante o treinamento após a realização dos ensaios para tal fim. Estes itens estão descritos no capítulo 5 .

5 DESENVOLVIMENTO DO MÓDULO NEURAL DE ENSAIO

Com o tipo de rede neural utilizada no MNE e a estrutura do SNE estabelecidos, é necessário realizar os ensaios de compressores para o treinamento e o delineamento dos parâmetros da rede.

Adicionalmente, com o intuito de auxiliar a tarefa das redes neurais, é feito o uso de lógica nebulosa para classificar os padrões de saída. Neste capítulo também são descritas as peculiaridades dessa última ferramenta.

5.1 ENSAIOS REALIZADOS PARA TREINAMENTO DA REDE

Para o bom treinamento de uma rede neural um grande número de casos deve ser utilizado nesta tarefa, cobrindo diversas possibilidades de excitações e respostas. Para que uma determinada resposta seja bem caracterizada, o conjunto de dados deve ser representativo. Devido a limitações inerentes ao projeto em que está inserida a dissertação, somente uma amostra pequena de compressores foi disponibilizada, resultando em um pequeno número de casos no treinamento. Mesmo diante de tal fato prosseguiu-se com a pesquisa, estando-se ciente de que com uma amostra maior os resultados seriam melhores.

A amostra recebida contém oito compressores do mesmo modelo, cinco de um lote de fabricação e três de outro. Para facilitar a identificação destes compressores cada um recebeu uma etiqueta com a sigla BD (banco de dados) e uma numeração de um a oito: BD-01; BD-02... BD-08.

Os ensaios para treinamento da RNA foram realizados com sete compressores (BD-01, BD-02, BD-04, BD-05, BD-06, BD-07 E BD-08), com três repetições para cada

um, resultando em um total de vinte e um ensaios. A amostra BD-03 foi utilizada para avaliação.

Para aumentar a dispersão nos resultados de consumo de potência ativa o artifício de retirar o capacitor permanente em um dos ensaios de cada compressor foi utilizado. Essa retirada ocasiona um desbalanceamento das impedâncias do circuito elétrico que tem como consequência aumento nas potências ativa, reativa e aparente.

5.1.1 Leituras do transitório (ensaios de treinamento)

Para exemplificar os dados obtidos com os ensaios de treinamento para as grandezas selecionadas no item 4.3 , são traçados gráficos de alguns ensaios, que podem ser vistos nas figuras 5.1 a 5.8. O eixo do tempo é padronizado com valor final de 7000 s (aproximadamente 2 h), considerado o valor máximo para a análise dos dados.

Na figura 5.1 as temperaturas da carcaça e de descarga para o ensaio 2 do compressor BD-01 estão traçadas em um mesmo gráfico. Fica clara a superioridade do valor das temperaturas de descarga, com grande variação no início, e do topo da carcaça.

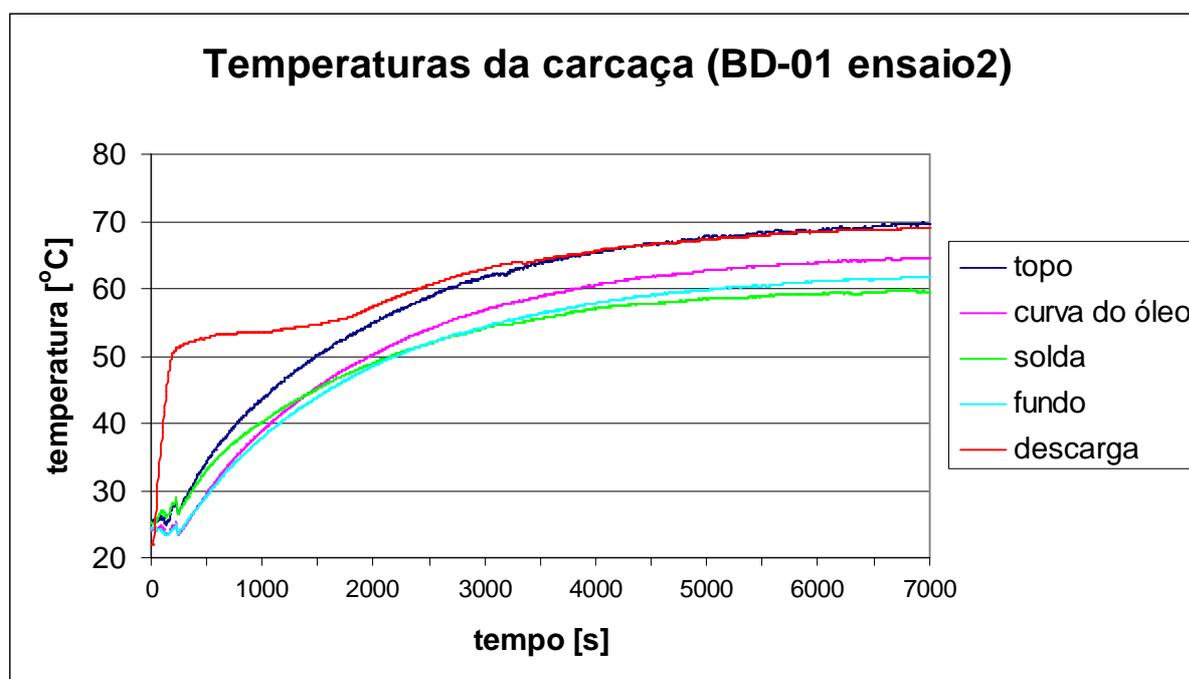


Figura 5.1 – Gráfico das temperaturas da carcaça (BD-01).

A fim de comparação na figura 5.2 encontra-se o gráfico para o ensaio 1 do compressor BD-08. Nota-se que a temperatura do topo, bem como de descarga, são mais sensíveis à mudança de compressor. Neste ensaio a temperatura estabilizada para descarga e topo não são a mesma, como no ensaio da figura 5.1.

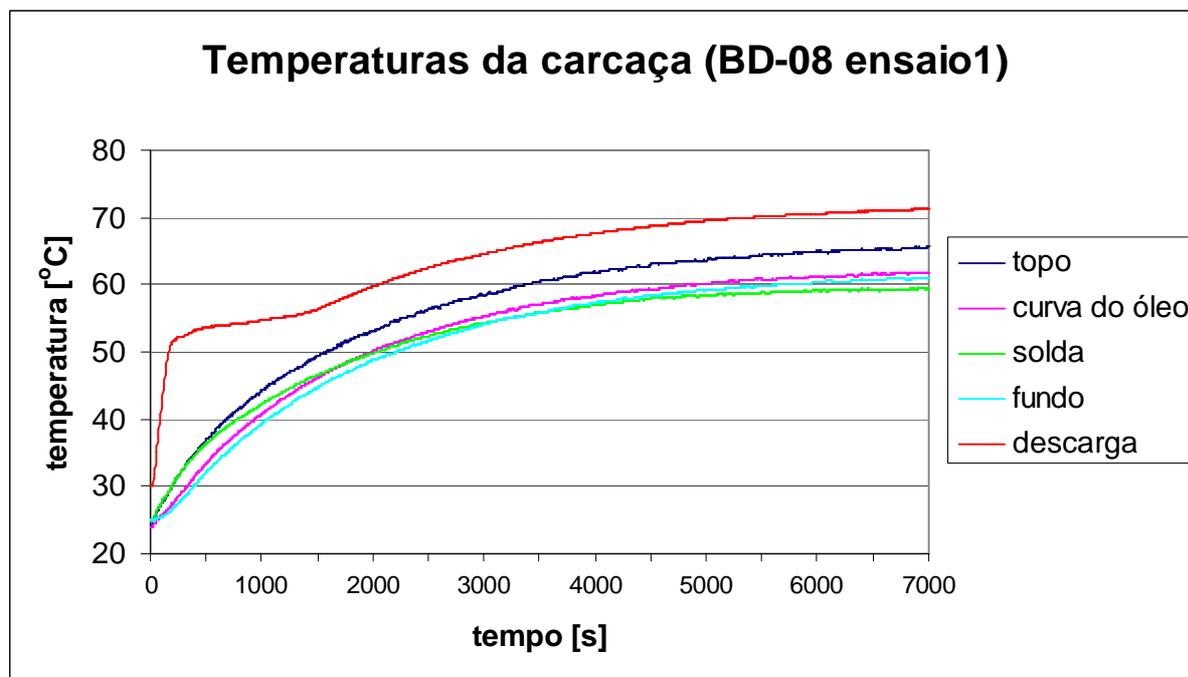


Figura 5.2 - Gráfico das temperaturas da carcaça (BD-08).

As grandezas medidas em um ensaio de desempenho possuem diversas correlações entre si, a variação de uma grandeza interfere no valor e/ou na estabilização de outra. Essa correlação pode ser facilmente notada, a exemplo da pressão de sucção e a corrente do compressor, ou de forma mais sutil, a exemplo da variação do fluxo de massa com a estabilização das temperaturas do corpo e descarga. Na figura 5.3 encontram-se os fluxos de massa para os ensaios com os compressores BD-05 e BD-06. Nota-se que o valor tem uma pequena diminuição com o passar do tempo. Esse fato é função do aumento da temperatura e as conseqüentes dilatação das peças e mudança de viscosidade do óleo. Uma variação de aproximadamente 0,0065 g/s no fluxo mássico equivale a 1 W na capacidade de refrigeração, considerando as condições de operação do ensaio.

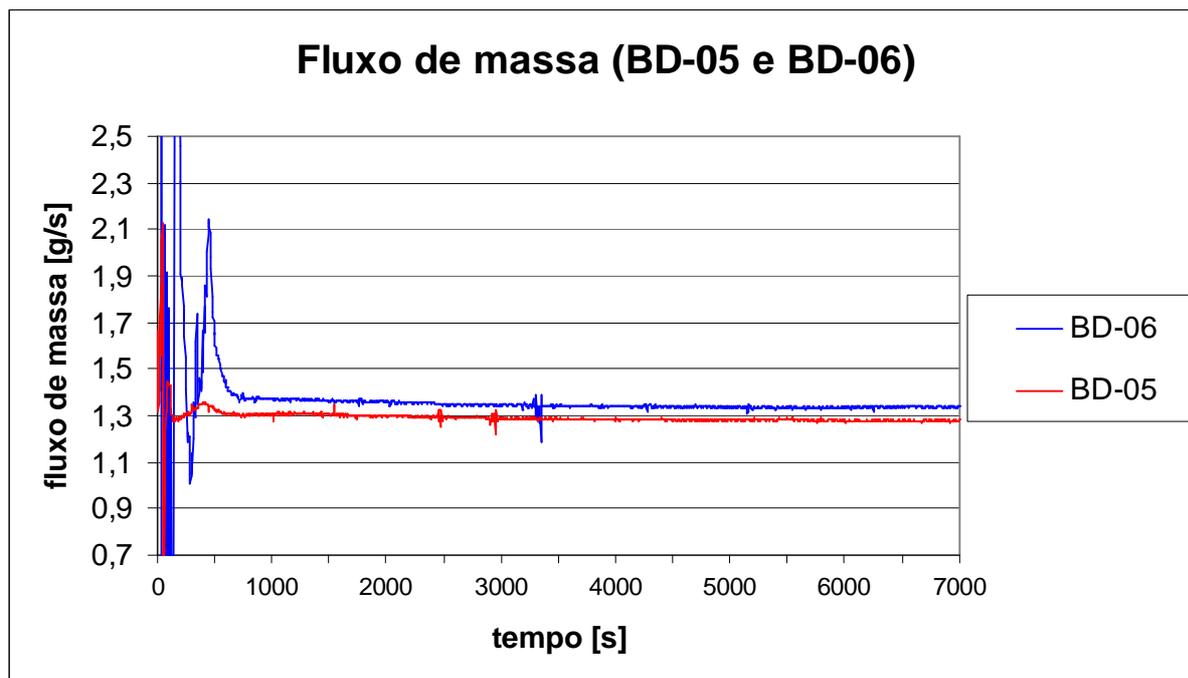


Figura 5.3 – Gráfico do fluxo mássico (BD-05 e BD-06).

O fluxo de massa, como descrito no item 2.2.3.1, também pode ser calculado a partir da potência dissipada nas resistências de aquecimento que realizam a troca térmica dentro do calorímetro. Na figura 5.4 estão traçadas as curvas de potência dissipada nas resistências de aquecimento para os primeiros ensaios com os compressores BD-05 e BD-06.

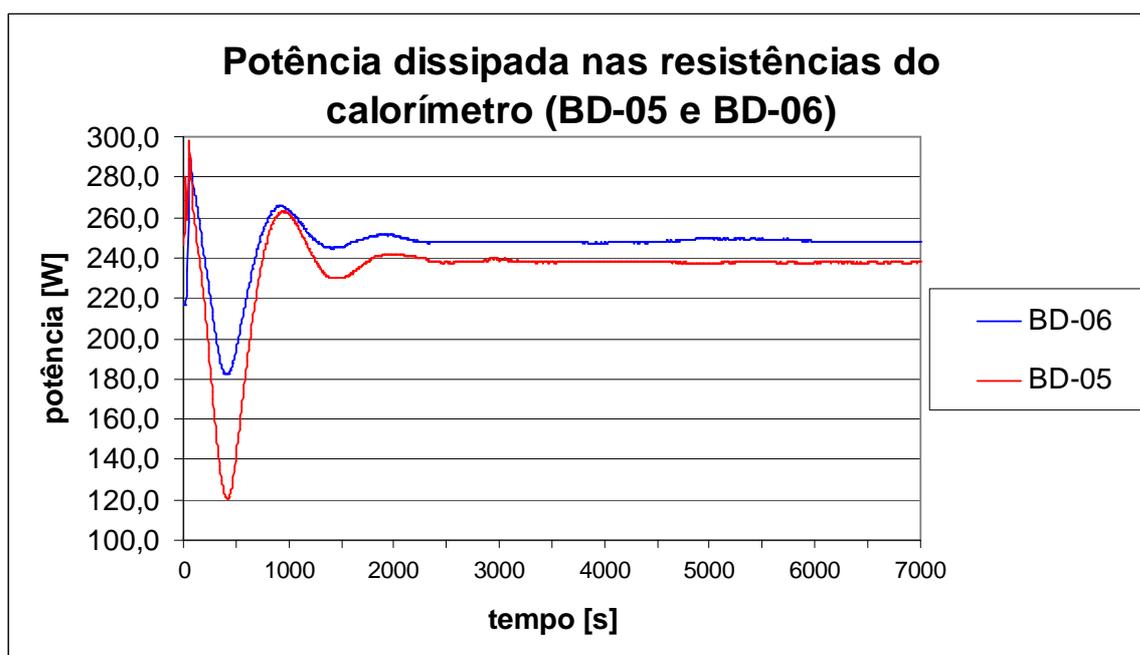


Figura 5.4 – Potência dissipada nas resistências do calorímetro.

A corrente que circula pelo compressor tem uma estabilização relativamente rápida, porém não é completamente senoidal. Na figura 5.5 encontram-se os valores da corrente eficaz (todas as componentes) e da amplitude da componente fundamental (60 Hz), já na figura 5.6 as amplitudes das componentes harmônicas para o mesmo ensaio.

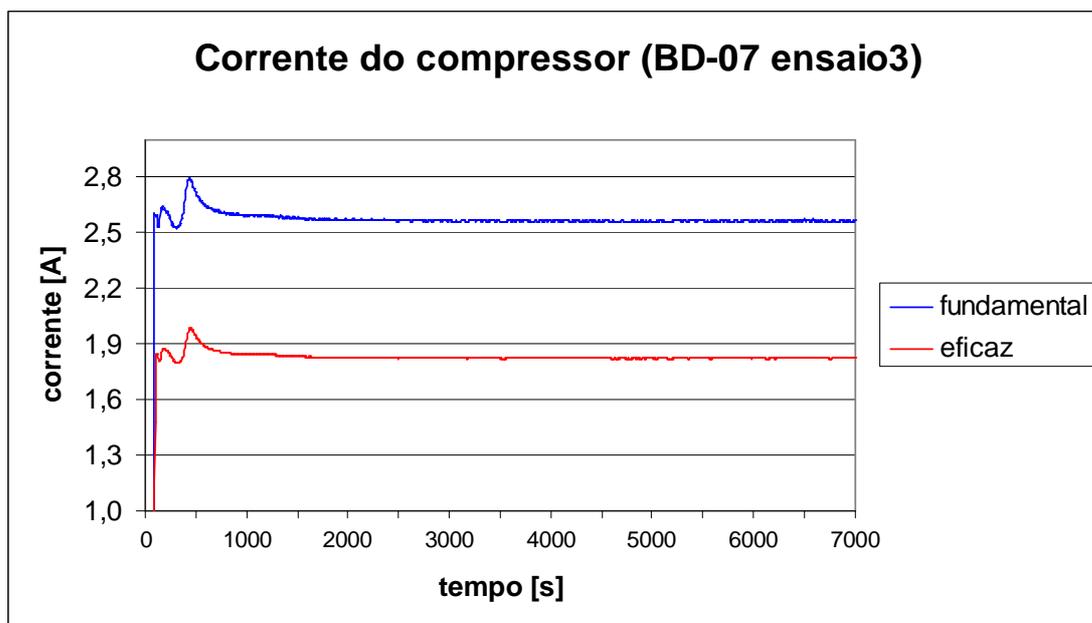


Figura 5.5 – Gráfico da corrente que circula pelo compressor.

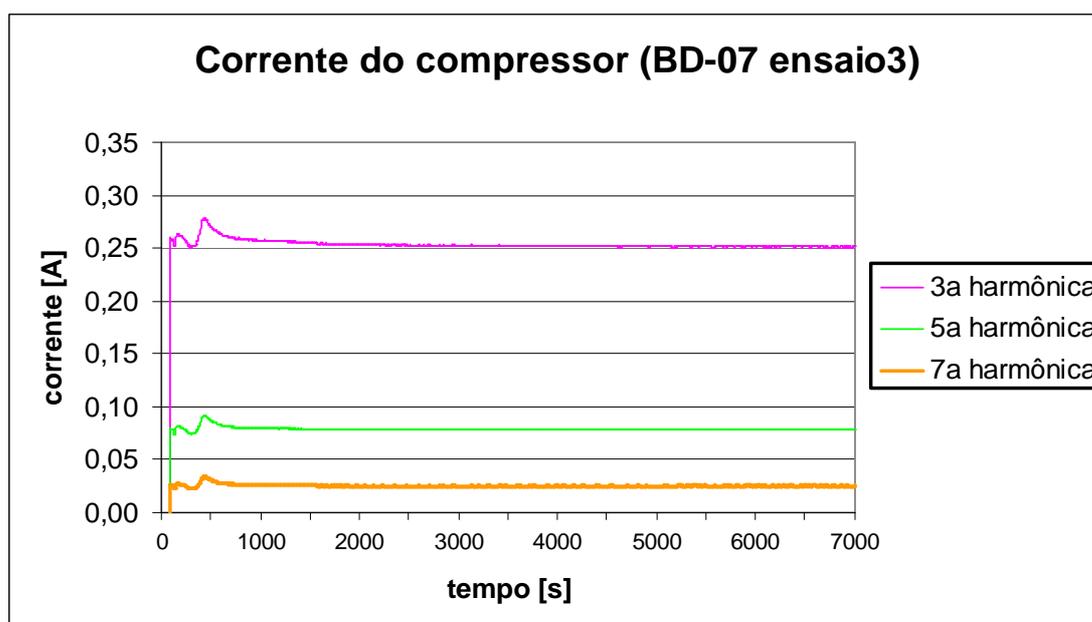


Figura 5.6 – Harmônicas de corrente BD-07 ensaio 3.

Com a finalidade de apresentar a diferença entre as componentes harmônicas de dois compressores diferentes é apresentada na figura 5.7 as amplitudes das componentes harmônicas para o compressor BD-04 ensaio 1. As amplitudes das componentes são diferentes nos ensaios BD-04.1 e BD07.3, bem como a ordem de magnitude. No ensaio BD-07.3 (Figura 5.6) a 5ª harmônica é maior que a 7ª, já no ensaio BD-04.1 (Figura 5.7) a 7ª harmônica é maior que a 5ª.

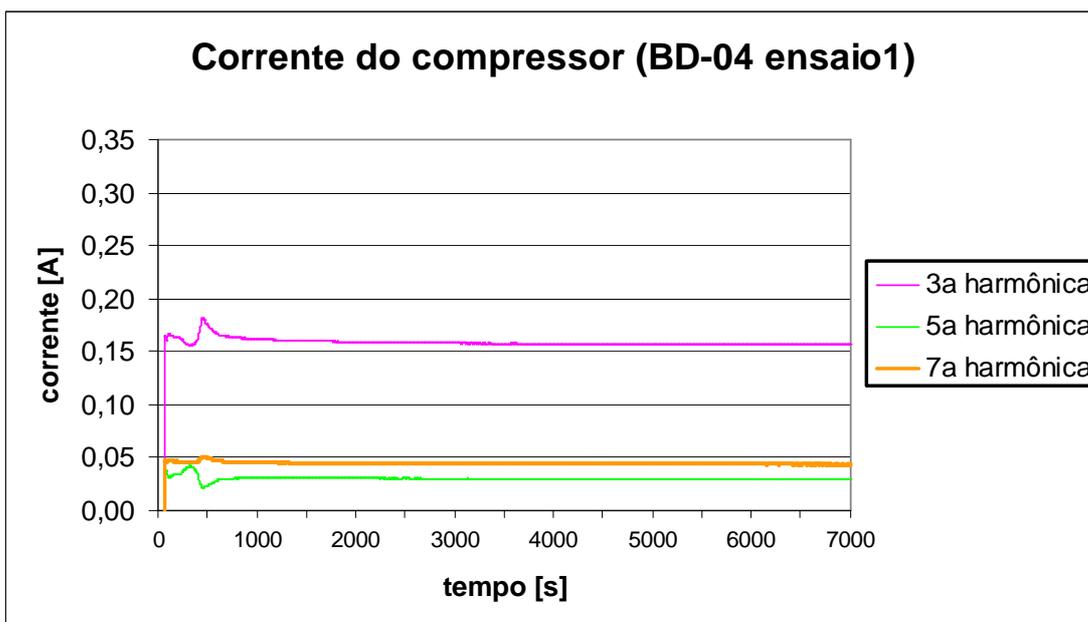


Figura 5.7 - Harmônicas de corrente BD-04 ensaio 1

Atualmente somente a potência ativa consumida pelo compressor é dado de catálogo e saída do ensaio, porém a potência reativa carrega bastante informação e foi uma variável bastante explorada. Na figura 5.8 estão traçadas as curvas de potência ativa e reativa para o ensaio 1 do compressor BD-02.

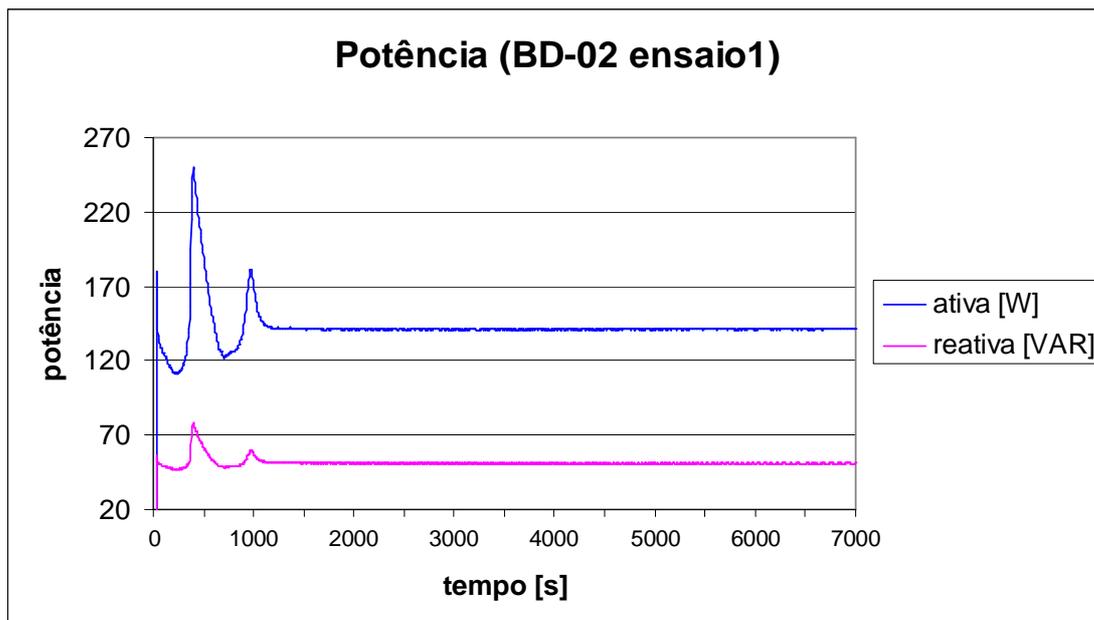


Figura 5.8 – Potência consumida pelo compressor.

As leituras da potência do espectro de frequência de vibração para as bandas de frequência selecionadas estão mostradas na figura 5.9.

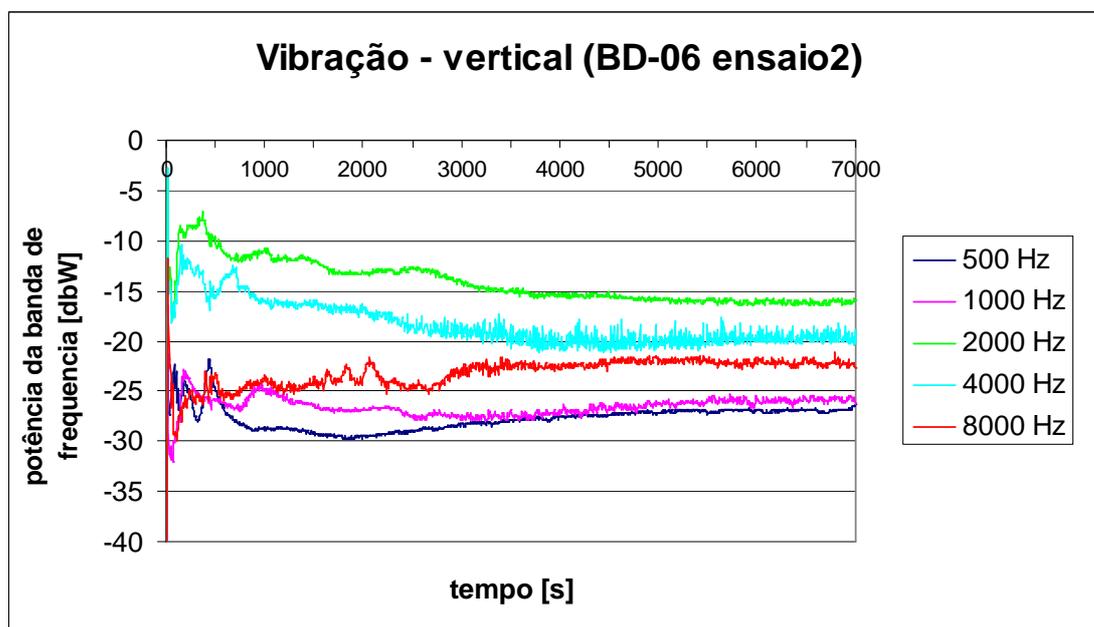


Figura 5.9 – Vibração medida no compressor.

Como dito no item 4.3.5, as medições de vibração são indicadas para a diferenciação de lotes ou de defeitos de fabricação, não sendo indicadas para a classificação de capacidade ou consumo.

5.1.2 Resultados dos ensaios de treinamento

O objetivo dos ensaios de desempenho é a determinação do consumo de potência ativa e da capacidade de refrigeração; os outros dois parâmetros, coeficiente de desempenho (COP) e eficiência isentrópica, são calculados a partir desses. Como cada compressor foi ensaiado três vezes, para os sete compressores de treinamento têm-se 21 ensaios com diferentes resultados. Esses resultados encontram-se na tabela 5.1:

Tabela 5.1 – Resultado dos ensaios de treinamento.

Resultados dos ensaios de treinamento						
Compressor	número do ensaio	Capacitor permanente	Capacidade [W]		Consumo [W]	COP
			Calorímetro	Fluxo de massa		
BD-01	1	COM	198,68	197,63	140,38	1,412
	2	COM	198,34	198,05	140,29	1,413
	3	SEM	199,05	197,29	150,28	1,319
BD-02	1	COM	196,74	196,32	141,30	1,391
	2	COM	198,97	196,71	141,56	1,398
	3	SEM	198,13	195,90	151,32	1,302
BD-04	1	COM	198,67	196,33	139,61	1,415
	2	COM	197,66	196,50	139,45	1,413
	3	SEM	196,79	195,96	148,68	1,321
BD-05	1	COM	195,60	194,76	140,19	1,392
	2	SEM	196,39	194,20	150,39	1,299
	3	SEM	195,70	193,94	150,15	1,298
BD-06	1	COM	204,02	202,71	143,99	1,412
	2	COM	204,73	202,69	143,73	1,417
	3	SEM	203,56	201,83	154,10	1,315
BD-07	1	COM	203,46	200,94	142,83	1,416
	2	COM	202,49	200,84	142,80	1,412
	3	SEM	201,62	199,98	152,62	1,316
BD-08	1	COM	204,62	203,15	144,39	1,412
	2	COM	204,19	202,83	144,90	1,404
	3	SEM	202,44	202,25	155,35	1,302

Para a capacidade de refrigeração estão mostrados os resultados obtidos com dois métodos diferentes, o calorímetro (C) e o fluxo de massa (F). As incertezas de medição para eles são $\pm 2,10$ W e $\pm 0,94$ W, respectivamente. Para o consumo de potência ativa a incerteza do sistema de medição é $\pm 0,58$ W [48].

O capacitor permanente é um elemento obrigatório, porém para “simular” um aumento de consumo ele foi retirado em alguns ensaios. Quando na retirada do capacitor o consumo variou em torno de 10%.

O consumo varia de $(139,45 \pm 0,58)$ W a $(155,35 \pm 0,58)$ W e a capacidade de $(193,94 \pm 0,94)$ W a $(203,15 \pm 0,94)$ W pelo método F e de $(195,60 \pm 2,1)$ W a $(204,73 \pm 2,1)$ W pelo método C [49], [50]. Os compressores BD-01, BD-02, BD-04 e BD-05 pertencem a um lote de fabricação e BD-06, BD-07 e BD-08 a outro.

5.2 UTILIZAÇÃO DA LN COMO FERRAMENTA DE AUXILIO ÀS RNA

As RNA têm grande capacidade de aprendizado, são flexíveis e modelam sistemas não lineares usando somente dados de entrada e saída ou excitação e resposta. Entretanto, devido à dificuldade de se explicar logicamente a relação causa-efeito, é problemático o ajuste fino das incertezas em sistemas neurais. De outra forma a lógica nebulosa possui vantagens na questão de justificar o resultado de acordo com o conhecimento adquirido (regras, funções de pertinência etc.). Assim uma aplicação combinada neuro-nebulosa (*neuro-fuzzy*) oferece potencial interessante para modelagem de sistemas não lineares [51], [52].

As saídas do sistema neural de ensaio são as classes de capacidade de refrigeração e de consumo de potência ativa em que o compressor se encaixa, por exemplo: capacidade – classe 1 (195 W a 198 W); consumo – classe 3 (140 W a 143 W). Na solução proposta, basicamente é feito uso de lógica nebulosa para caracterização dessas classes de saída, uma vez que a classificação por conjuntos abruptos, neste caso, dificulta o treinamento e aumenta o número de erros na avaliação. Nesta dissertação as classes foram determinadas com base nos resultados de capacidade e consumo obtidos nos ensaios, buscando estabelecer conjuntos com valores semelhantes. A situação ideal, capaz de ser executada com o aumento do número de ensaios de treinamento, é estabelecer as classes de acordo com a necessidade da aplicação. A caracterização das classes é necessária em dois momentos distintos, durante o treinamento e na execução das redes neurais.

5.2.1 Utilização de LN durante o treinamento das RNA

Durante o treinamento da RNA de consumo de potência ativa, para cada ensaio, são apresentadas as leituras das grandezas selecionadas como entradas e o grau de pertinência de cada classe de consumo, como saídas. Para a RNA de capacidade é feito a mesma coisa, mas com entradas e saídas correspondentes a este caso. O resultado de regime permanente obtido nos ensaios passa por uma base de regras que realiza o processo de nebulização (Figura 5.11 e Figura 5.12), em que o valor do resultado é transformado em graus de pertinência a cada classe, que representam as saídas da rede para o ensaio (Figura 5.10).

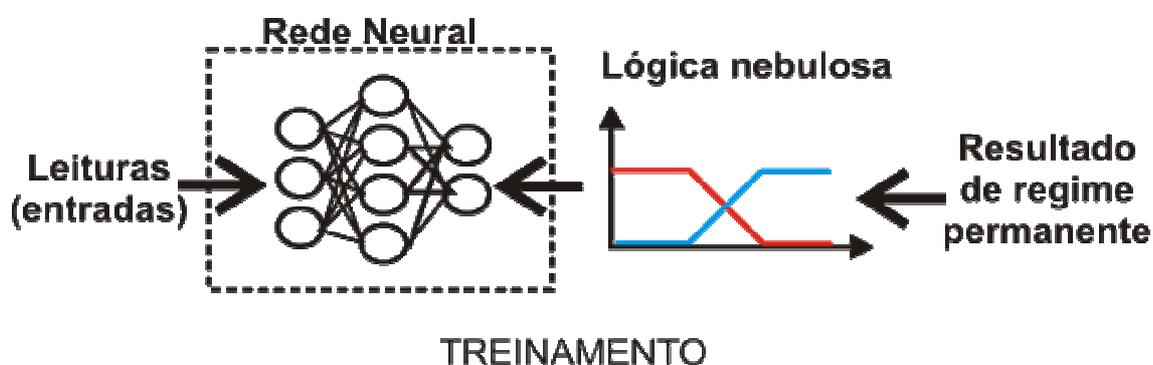


Figura 5.10 – Uso de lógica nebulosa durante o treinamento da rede.

O número de classes e seus limites diferem para capacidade e consumo, já a função de pertinência utilizada é a mesma, a trapezoidal. O processo de nebulização pode ser visto na figura 5.11 e na figura 5.12.

Para capacidade, existe uma divisão clara de valores entre os compressores dos dois lotes ensaiados e alguns compressores situam-se na transição entre essas duas regiões. Assim, para este parâmetro, foram estabelecidas duas classes. Como o resultado do fluxo de massa apresenta uma incerteza bem menor que o calorímetro, para este processo de classificação e nebulização foram utilizados os valores correspondentes à capacidade calculados pelo medidor de fluxo de massa.

A entrada do nebulizador é o valor de capacidade calculado pelo fluxo de massa (Tabela 5.1) e a saída são os graus de pertinência às classes C1 e C2 (Figura 5.11). Por exemplo: as classes de capacidade de refrigeração do ensaio 1 do compressor BD-07 (200,5 W) são $C1=0,3$ e $C2=0,8$.

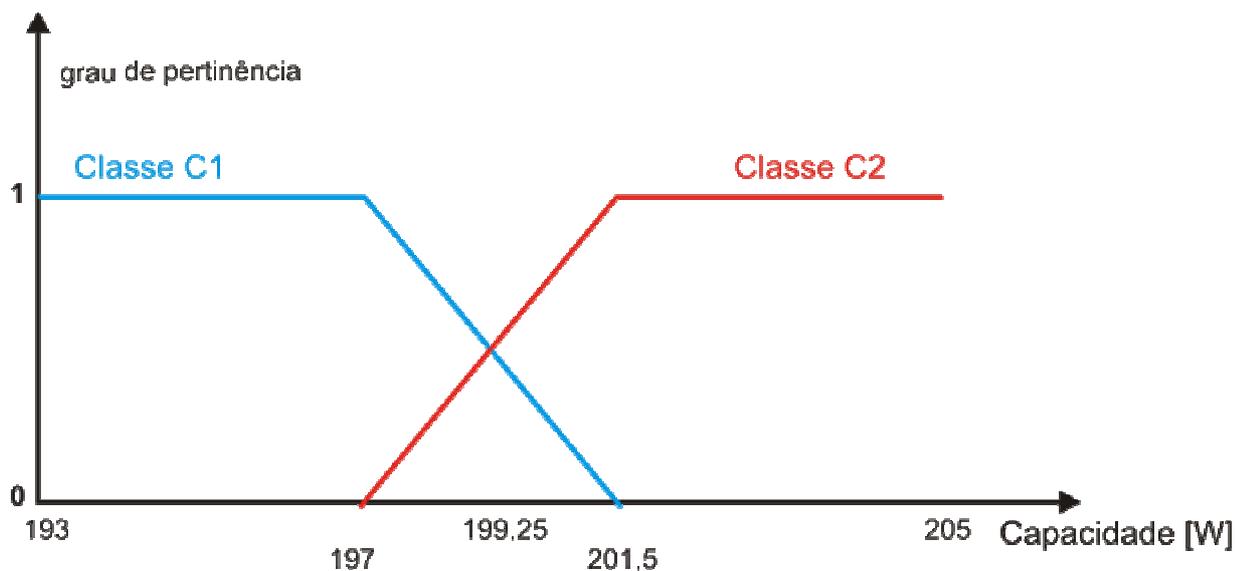


Figura 5.11 – Nebulização para capacidade de refrigeração.

Os limites da classe um são 193 W e 197 W, a região de transição situa-se entre 197 W e 201,5 W e a classe dois está entre 201,5 W e 205 W.

Com o uso do artifício da retirada do capacitor permanente, para o consumo de potência ativa existem quatro regiões de valores estabelecidas, duas originadas pelas diferenças entre os lotes com o uso do capacitor e duas pelas diferenças entre os lotes sem o capacitor. Da mesma forma, a entrada para o nebulizador é o valor de consumo (Tabela 5.1) e a saída são os graus de pertinência às classes C1, C2, C3, C4 (Figura 5.12). Para exemplificar: as classes para o consumo de potência ativa do ensaio 2 do compressor BD-04 (140W) são, C1=1, C2=0, C3=0, C4=0.

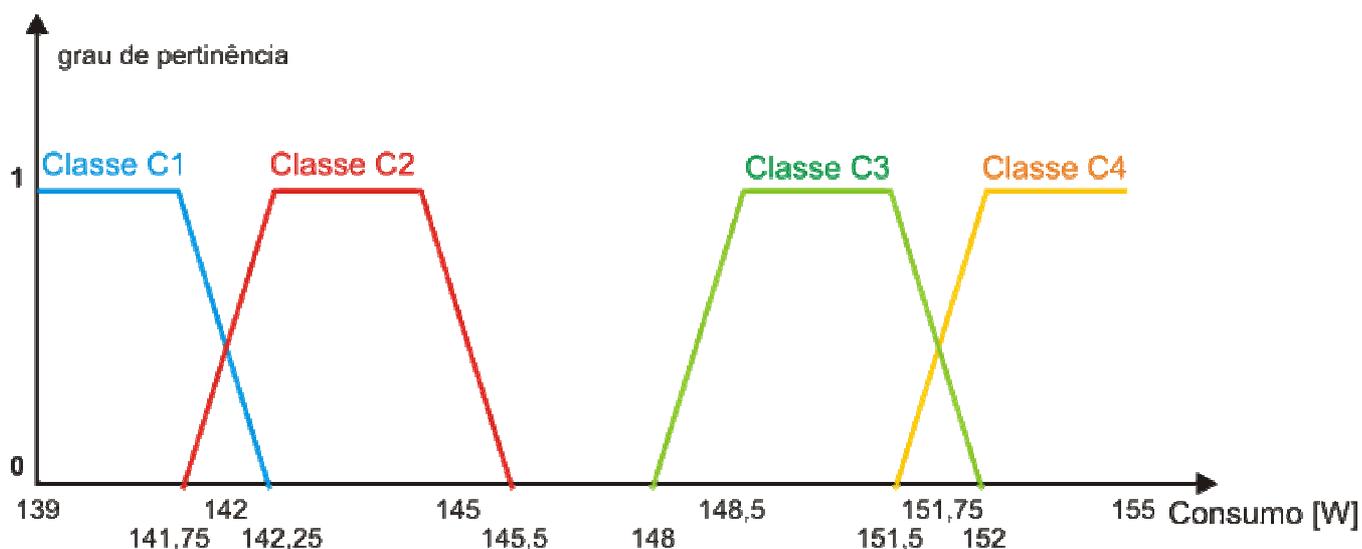


Figura 5.12 – Nebulização para consumo de potência ativa.

Os resultados do processo de nebulização para as classes mostradas nas figuras acima estão dispostos na tabela 5.2. Para melhorar o treinamento da rede, diminuindo as saturações dos neurônios, os limites superior (1) e inferior (0) do grau de pertinência são deslocados para 0,9 e 0,1, respectivamente.

Tabela 5.2 - Resultado do processo de nebulização.

Ensaio	Capacidade		Consumo			
	C1	C2	C1	C2	C3	C4
BD-01.1	0.72	0.28	0.9	0.1	0.1	0.1
BD-01.2	0.66	0.34	0.9	0.1	0.1	0.1
BD-01.3	0.76	0.24	0.1	0.1	0.9	0.1
BD-02.1	0.9	0.1	0.9	0.1	0.1	0.1
BD-02.2	0.9	0.1	0.9	0.1	0.1	0.1
BD-02.3	0.9	0.1	0.1	0.1	0.9	0.1
BD-04.1	0.9	0.1	0.9	0.1	0.1	0.1
BD-04.2	0.9	0.1	0.9	0.1	0.1	0.1
BD-04.3	0.9	0.1	0.1	0.1	0.9	0.1
BD-05.1	0.9	0.1	0.9	0.1	0.1	0.1
BD-05.2	0.9	0.1	0.1	0.1	0.9	0.1
BD-05.3	0.9	0.1	0.1	0.1	0.9	0.1
BD-06.1	0.1	0.9	0.1	0.9	0.1	0.1
BD-06.2	0.1	0.9	0.1	0.9	0.1	0.1
BD-06.3	0.1	0.9	0.1	0.1	0.1	0.9
BD-07.1	0.28	0.72	0.1	0.9	0.1	0.1
BD-07.2	0.29	0.71	0.1	0.9	0.1	0.1
BD-07.3	0.40	0.60	0.1	0.1	0.1	0.9
BD-08.1	0.1	0.9	0.1	0.9	0.1	0.1
BD-08.2	0.1	0.9	0.1	0.9	0.1	0.1
BD-08.3	0.1	0.9	0.1	0.1	0.1	0.9

5.2.2 Utilização de LN para execução das RNA

Após o treinamento da RNA, o conhecimento adquirido está fixado nos pesos das conexões. Sua execução passa a ser uma mera operação matemática, na qual são multiplicadas as entradas pelas matrizes dos pesos de cada camada de neurônios com as respectivas funções de transferência e elementos de polarização (bias), gerando a saída da rede.

Como as saídas das RNA são os graus de pertinência das classes, durante a execução é necessário traduzir esses valores em uma decisão de qual classe o compressor pertence (denebulização). Essa decisão forma o resultado do novo sistema de ensaio (Figura 5.13) [53].

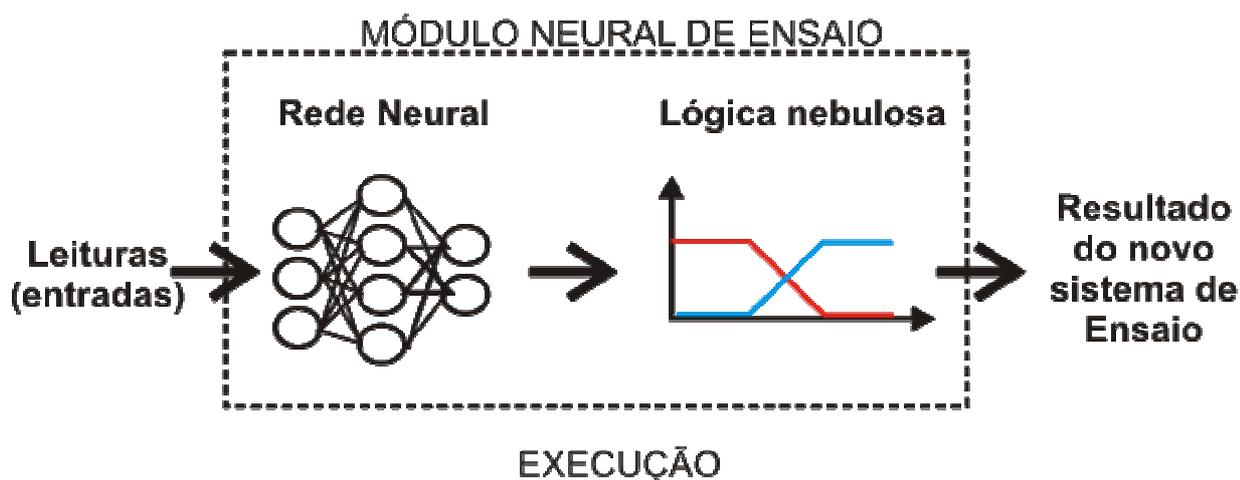


Figura 5.13 – Uso de lógica nebulosa durante a execução da rede.

O processo de denebulização novamente é composto por uma base de regras que indica a decisão tomada e a justifica com base nos dados dos graus de pertinência [54]. A saída deste processo é o resultado do sistema neural de ensaios (Tabela 5.3).

Tabela 5.3 – Resultados do sistema neural de ensaio.

Capacidade de refrigeração		
n° resultado	classe	pertinências
1	C1	__% à C1
2	transição de C1 para C2	__% à C1 __% à C2
3	transição de C2 para C1	__% à C1 __% à C2
4	C2	__% à C2
Consumo de potência ativa		
n° resultado	classe	pertinências
1	C1	__% à C1
2	transição entre C1 para C2	__% à C1 __% à C2
3	C2	__% à C2
4	C3	__% à C3
5	transição entre C3 para C4	__% à C3 __% à C4
6	C4	__% à C4

Na nebulização da capacidade são usadas faixas de transição largas e de consumo estreitas. Assim, na denebulização para capacidade é identificado o sentido da transição e para consumo somente se pertence ou não à transição. Para explicar as saídas representadas na tabela acima são exemplificados dois casos:

- consumo: n° 1 = a classe de consumo de potência ativa do compressor é C1 (139 W a 141,75 W) com um grau de pertinência de 93% a esta classe;

- capacidade: $n^{\circ} 2$ = a capacidade de refrigeração do compressor está entre as classes C1 e C2 na região de transição, com graus de pertinência à C1 de 70% e à C2 de 30%. A capacidade é menor que 201,5 W, provavelmente entre 197 W e 199,25 W.

5.3 PROGRAMAÇÃO DAS REDES NEURAIIS

Inicialmente a aplicação proposta para este novo sistema de ensaio é na pesquisa. Assim, a programação das redes neurais foi feita no ambiente Matlab, pois este possui uma biblioteca de RNA que facilita esta tarefa. Na opção de desenvolver uma solução final aplicada na indústria, uma linguagem como C ou Java pode ser utilizada.

Os dois processos distintos, treinamento e execução das redes, também possuem estruturas diferentes na programação. Na execução, o programa principal de ensaios é feito em Labview e o módulo neural em Matlab, porém como o Labview possui uma interface de comunicação entre os dois softwares, é possível a execução conjunta (Figura 5.14).

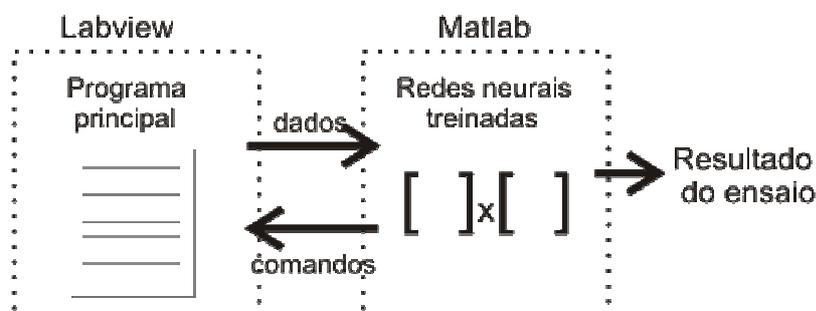


Figura 5.14 – Programa de execução das redes.

Por se tratar de um processo estritamente *off-line*, o treinamento das redes, feito somente no Matlab, é realizado a partir dos dados dos ensaios gravados automaticamente em planilhas do *Excel*. Assim é necessário um trecho do programa para fazer o resgate automático destes dados através do *ActiveX* e montar as matrizes para entrada e saída da rede. A estrutura do programa para treinamento está descrita na figura 5.15.

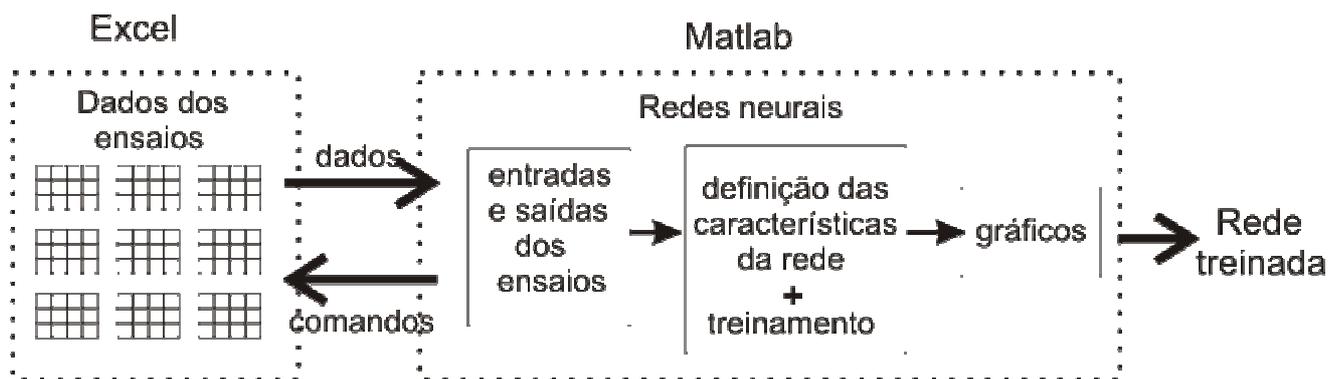


Figura 5.15 – Programa de treinamento das redes.

Dentro do programa em Matlab existem três blocos, a manipulação dos dados de entrada (dados do transitório) e saída (resultados de regime permanente) dos ensaios, a definição das características e treinamento das RNA e os gráficos para avaliação da rede treinada. Como saída, este programa salva a rede em um arquivo específico do Matlab (“rede treinada”), com os pesos das conexões dos neurônios, as funções de transferência, os atrasos e demais parâmetros que permitem a reprodução e execução dessa a qualquer instante.

Ao realizar o resgate dos dados dos ensaios, podem ser escolhidos o início e fim das leituras (primeiro e último instante de tempo a serem selecionados) e quais as variáveis do ensaio que servirão como entradas da rede.

Durante a programação, alguns artifícios são utilizados para manipular os dados de forma adequada para entrada e treinamento das redes. Para treinar a rede MLP dinâmica os dados têm que estar dispostos na forma mostrada na figura 5.16 e na figura 5.17. O recurso do Matlab aqui utilizado é o *cell array*, que permite armazenar diversas matrizes indexando as com índices, como se as matrizes fossem elementos de uma matriz superior. São necessários dois *cell arrays*, um com os dados de entrada e outro com os dados de saída. Para executar a rede os dados devem estar na mesma disposição, porém não é necessário matriz de saída, uma vez que esta será dada pela rede [55].

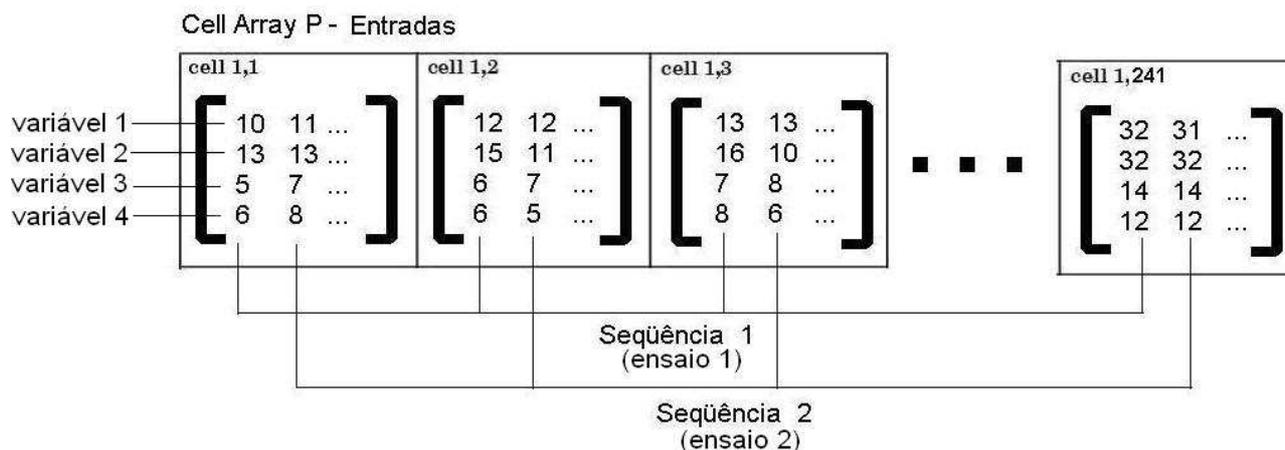


Figura 5.16 – Estrutura dos dados de entrada.

No *cell array* de entradas, cada célula (*cell*) representa um instante de tempo no qual é feita a aquisição dos dados (cinco em cinco segundos). Dentro de cada célula as linhas são as variáveis de entrada de cada ensaio (fluxo de massa, temperatura de descarga etc.) e as colunas os diferentes ensaios realizados e armazenados na base de dados. A união das colunas de cada célula constitui a seqüência de um ensaio completo [55].

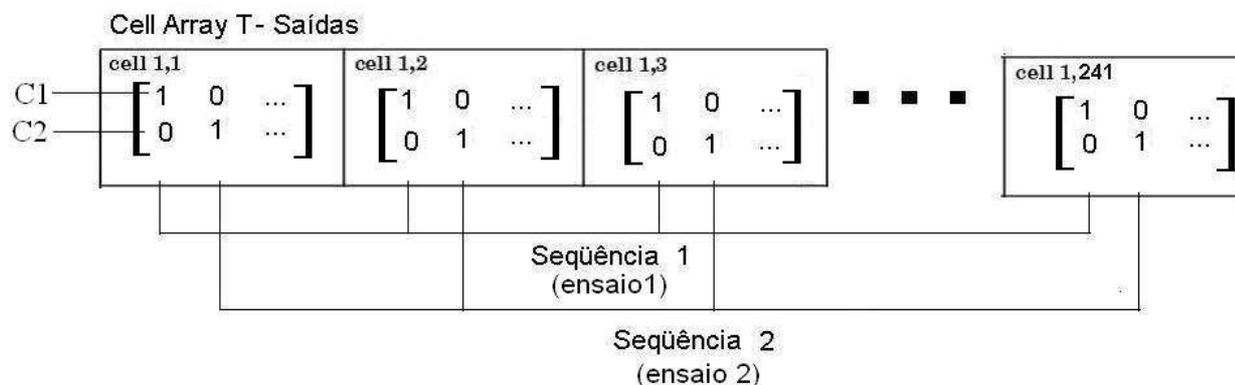


Figura 5.17 – Estrutura dos dados de saída.

Da mesma forma que no *cell array* de entrada, no *cell array* de saída cada célula representa um instante de tempo no qual é feita a aquisição de dados, porém em cada linha de uma célula posicionam-se as classes de saída (por exemplo, as classes de capacidade de refrigeração). Em cada coluna das células estão as classes de um ensaio para um determinado tempo, quando as colunas são unidas constituem uma seqüência de um ensaio [55].

O segundo bloco constitui a definição dos parâmetros da rede e do treinamento. A RNA selecionada para a aplicação é uma MLP dinâmica. No Matlab foi escolhida a

rede *newfftd*, uma rede MLP direta com atrasos nas entradas e treinamento da retropropagação. Para esta arquitetura o que precisa ser definido basicamente é [55]:

- máximos e mínimos de cada entrada para todos os ensaios de treinamento, para que seja feita a normalização das mesmas;
- vetor de atrasos. Por exemplo: ID= [1, 2, 3, 8] - este comando indica que serão utilizadas a primeira, segunda, terceira e oitava amostras anteriores;
- número de camadas escondidas;
- número de neurônios em cada camada;
- número de saídas;
- funções de transferência de cada camada de neurônios (a camada de entrada utiliza sempre a função linear).

Para o treinamento da rede mais alguns parâmetros devem ser estabelecidos:

- função de treinamento para o algoritmo da retropropagação;
- número de ciclos de treinamento (épocas);
- limite máximo de erro aceitável;
- função de desempenho (cálculo dos erros).

Para a avaliação da rede treinada e decisão relativa ao arquivamento dessa, outro bloco de programação traça os gráficos das saídas da rede correspondentes à execução com os ensaios utilizados no treinamento e alguns ensaios utilizados somente para avaliação.

No capítulo 6 são explorados a avaliação das redes e os testes realizados para chegar aos parâmetros finais.

6 RESULTADOS OBTIDOS

Por se tratar de uma pesquisa sem referências específicas na literatura e por não haverem regras bem aceitas pela comunidade científica para o estabelecimento dos parâmetros de uma RNA, foram realizados uma série de testes com o objetivo de determinar as características do sistema neural de ensaio que apresentassem os melhores resultados.

Para julgar quais seriam os melhores resultados, novos ensaios de desempenho de compressores foram efetuados e posteriormente executados com as redes. Esses ensaios de avaliação também são descritos, bem como os resultados finais obtidos.

6.1 TESTES REALIZADOS COM AS REDES E DEFINIÇÕES DOS PARÂMETROS DO SISTEMA

Os testes realizados com as redes e a definição dos parâmetros do sistema são descritos em duas partes, uma relativa aos dados de entrada para treinamento e outra às definições das RNA. Com todos os detalhes estabelecidos as configurações finais das RNA são apresentadas.

6.1.1 Dados de entrada

Dispondo da seleção das grandezas realizadas no item 4.3 foram escolhidas para representarem entradas para as redes somente as grandezas que tinham avaliação 2 (melhor classificação, grandezas com maior sensibilidade a mudanças de consumo ou capacidade). Para capacidade de refrigeração estas grandezas são:

- temperatura de descarga;
- temperatura do topo da carcaça;

- fluxo de massa de refrigerante (com e sem filtragem);
- potência dissipada nas resistências de aquecimento do calorímetro;
- capacidade instantânea calculada pelo fluxo de massa.

Foram realizados testes com inserção de outras grandezas, mas os resultados não foram positivos, ocasionando aumento do tempo e do erro de treinamento, provavelmente causados pela insensibilidade a mudanças de capacidade destas grandezas adicionais. Para o consumo de potência ativa as grandezas utilizadas são:

- corrente eficaz do compressor;
- potência ativa instantânea consumida pelo compressor;
- potência reativa instantânea demandada pelo compressor;
- amplitude da componente fundamental (60 Hz) de corrente do compressor;
- amplitude da 3ª harmônica de corrente;
- amplitude da 5ª harmônica de corrente;
- amplitude da 7ª harmônica de corrente;
- temperatura de descarga;
- temperatura do topo da carcaça.

Da mesma forma que com a capacidade, foram adicionadas outras grandezas durante o treinamento, mas não resultaram em benefício para a RNA. Além das variáveis utilizadas, outros fatores importantes para os dados de entrada são o início e fim das leituras para o treinamento da RNA. Essas definições são válidas somente para o treinamento, pois a execução posterior das redes será feita a partir do início do ensaio.

A necessidade de encontrar a melhor janela de tempo (início e fim) para o processo de treinamento, é justificada por cinco considerações:

1. a automação completa da bancada para a realização dos ensaios não foi atingida - a abertura de dois registros para a medição de pressão e a permutação da alimentação para partida do compressor entre a rede e a

fonte de alimentação foram executadas manualmente. Isto gera diferentes tempos de início “completo” (todas as medições) dos ensaios;

2. observou-se que algumas grandezas medidas, como o fluxo de massa, apresentavam oscilações anormais muito grandes nos primeiros instantes do ensaio (devido ao transitório do compressor e ao sistema de medição);
3. o número reduzido de ensaios para o treinamento dificulta o aprendizado com padrões de comportamento muito diferentes;
4. o tempo de treinamento e o esforço computacional aumentam muito com o aumento da janela de tempo;
5. janelas de tempo muito pequena ocasionam falta de generalização (a rede decora os dados de treinamento e não acerta na avaliação).

Para determinar o início, vários testes foram realizados. Para consumo foram testados: 5 s; 50 s; 100 s; 200 s; 300 s; 400s; 500 s; 1000s. E para capacidade: 5 s; 50 s; 100 s; 250 s; 500 s; 750 s; 1000 s; 1250 s; 1500 s; 2000 s; 2500 s. Os menores valores que obtiveram os melhores resultados foram 300 s (consumo) e 1250 s (capacidade).

Na determinação do tempo final das leituras foram realizados testes semelhantes. Para consumo: 1500 s; 2000 s; 2500 s; 3000 s; 3500 s; 4000 s; 5000 s; 7000 s. Para capacidade: 2000 s; 3000 s; 4000 s; 4500 s; 5000 s; 6000 s; 7000 s. Os melhores resultados indicaram 3500 s (consumo) e 4500 s (capacidade). As janelas de tempo finais podem ser vistas nas figuras seguintes (Figura 6.1 e Figura 6.2).

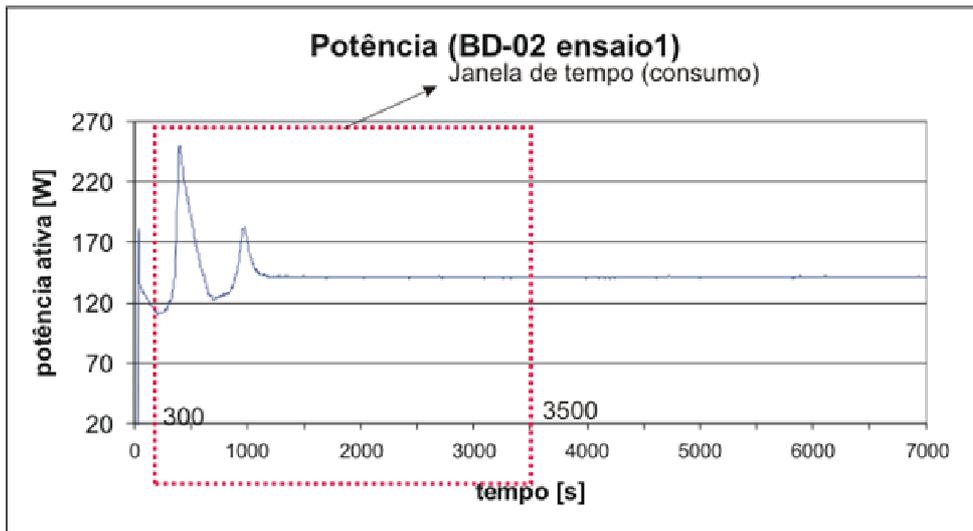


Figura 6.1 – Janela de tempo para o treinamento da rede de consumo.

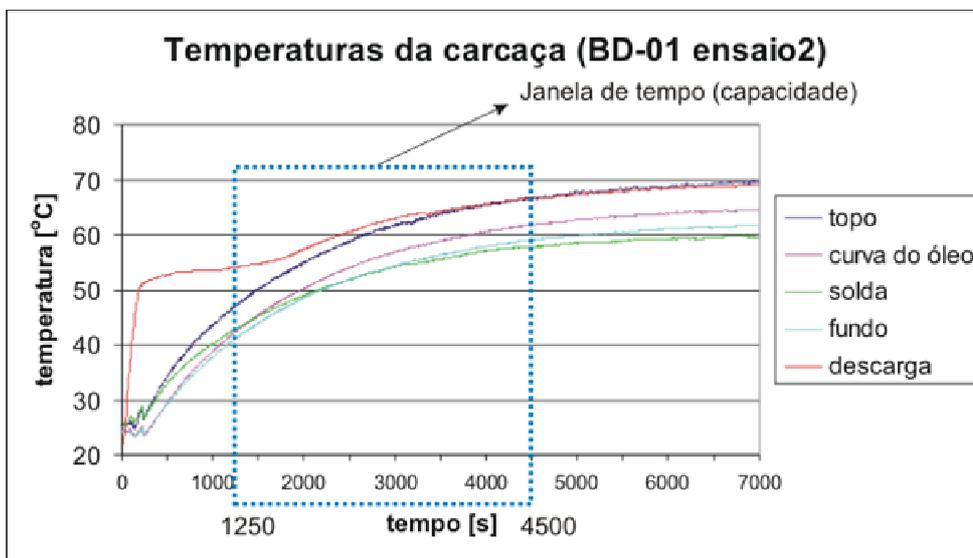


Figura 6.2 – Janela de tempo para o treinamento da rede de capacidade.

Acredita-se que com a automação completa da bancada e uma base de dados com um número maior de ensaios o tempo inicial possa ser reduzido, produzindo resultados em um tempo ainda menor.

6.1.2 Parâmetros das RNA

No item 5.3 foram expostos quais os parâmetros que devem ser definidos para as RNA, porém não existem regras bem definidas para o estabelecimento desses. Assim, novamente foram realizados testes e escolhidos os valores que apresentaram as melhores performances.

O vetor de atrasos tem grande influência na generalização dos resultados e no tempo de treinamento. Um número elevado de atrasos faz com que o erro e o tempo sejam altos e um número reduzido faz com que o erro de treinamento seja baixo e o erro de avaliação alto (falta de generalidade). Os testes variaram de cinco amostras anteriores até trinta e espaçamentos de uma amostra até cinco. Por exemplo : ID= [1, 2, 3, 4, 5]; ID= [1, 2, 3, 4, 5, 6, 7, 8, 9,10]; ID= [5, 10, 15, 20, 25, 30].

Os vetores de atrasos escolhidos foram ID= [1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15] para capacidade e ID= [1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12] para consumo.

A definição do número de camadas escondidas baseou-se nos testes realizados e no esforço computacional exigido. Durante o treinamento foi observado uma demora excessiva e erros de falta de memória no computador, ocasionados pelo grande número de neurônios na primeira camada escondida. A partir disto, partiu-se para a opção de duas ou mais camadas escondidas. As melhores performances ocorreram com duas camadas intermediárias para ambas as redes.

No transcorrer dos testes, foi observado que o número de neurônios em cada camada nesta aplicação obedecia a uma regra geral. Um número muito alto em relação ao número de entradas pecava na generalização e um número baixo não alcançava o erro de treinamento almejado. Foram executadas várias experiências, destacando-se dez e cinco neurônios nas duas camadas para a rede de consumo e sete e três para a de capacidade.

Foram utilizados três tipos de funções de transferência para os neurônios, linear para a camada de entrada, tangente sigmóide (com limites de -1 a 1) para a primeira camada escondida, linear pra a segunda camada escondida e sigmóide logarítmica (com limites de 0 a 1) para a camada de saída.

O número de operações realizados no treinamento é muito alto, pois em cada ensaio têm-se nove ou seis entradas, com aproximadamente quinze atrasos e 700 amostras para cada grandeza. Assim, com o esforço computacional alto, foram testadas três funções de treinamento, recomendadas pelo MATLAB [55] para o algoritmo da retropropagação:

- quasi-Newton backpropagation;
- Levenberg-Marquardt backpropagation;
- resilient backpropagation.

A função Levenberg-Marquadt atingiu bons resultados, mas consome muita memória, produzindo um tempo de treinamento elevado e erros de falta de memória. A função quasi-Newton foi a melhor opção com um tempo de treinamento intermediário e baixo erro de treinamento. O número de ciclos de treinamento (critério de parada) utilizado foi na maioria das vezes em torno de 500.

Depois de todos os parâmetros estabelecidos é possível montar as configurações finais para as redes. A configuração final da RNA de capacidade de refrigeração é mostrada na figura 6.3.

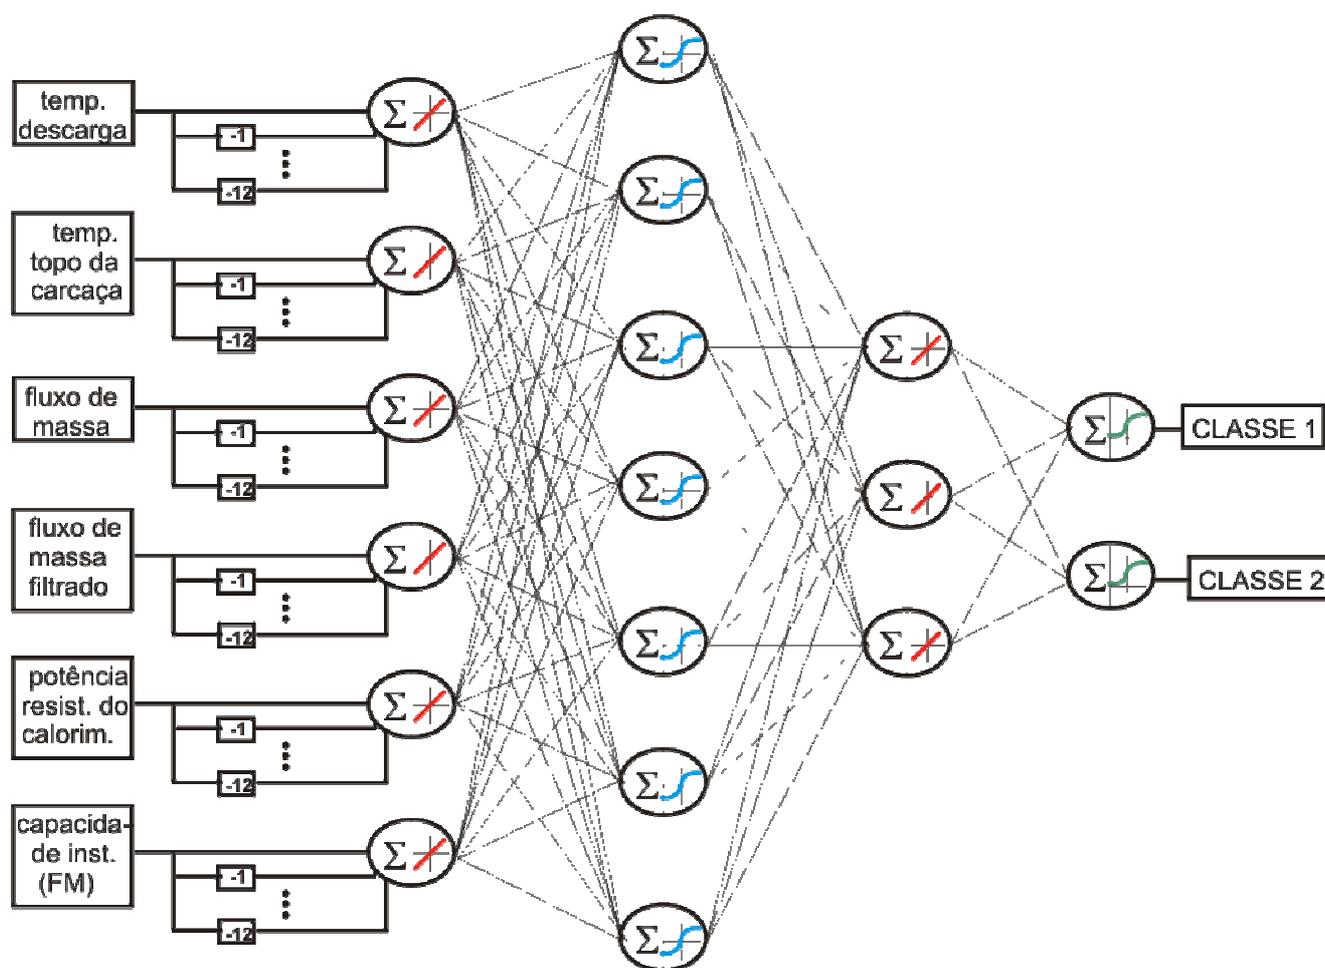


Figura 6.3 – Configuração final da rede de capacidade.

É possível identificar na figura 6.3 a maior parte dos parâmetros estabelecidos para esta rede, como as variáveis de entrada, número de atrasos na primeira camada, número de camadas, número de neurônios, funções de transferência e número de classes de saída. De maneira semelhante, na figura 6.4 é mostrada a configuração final para a rede de consumo de potência ativa.

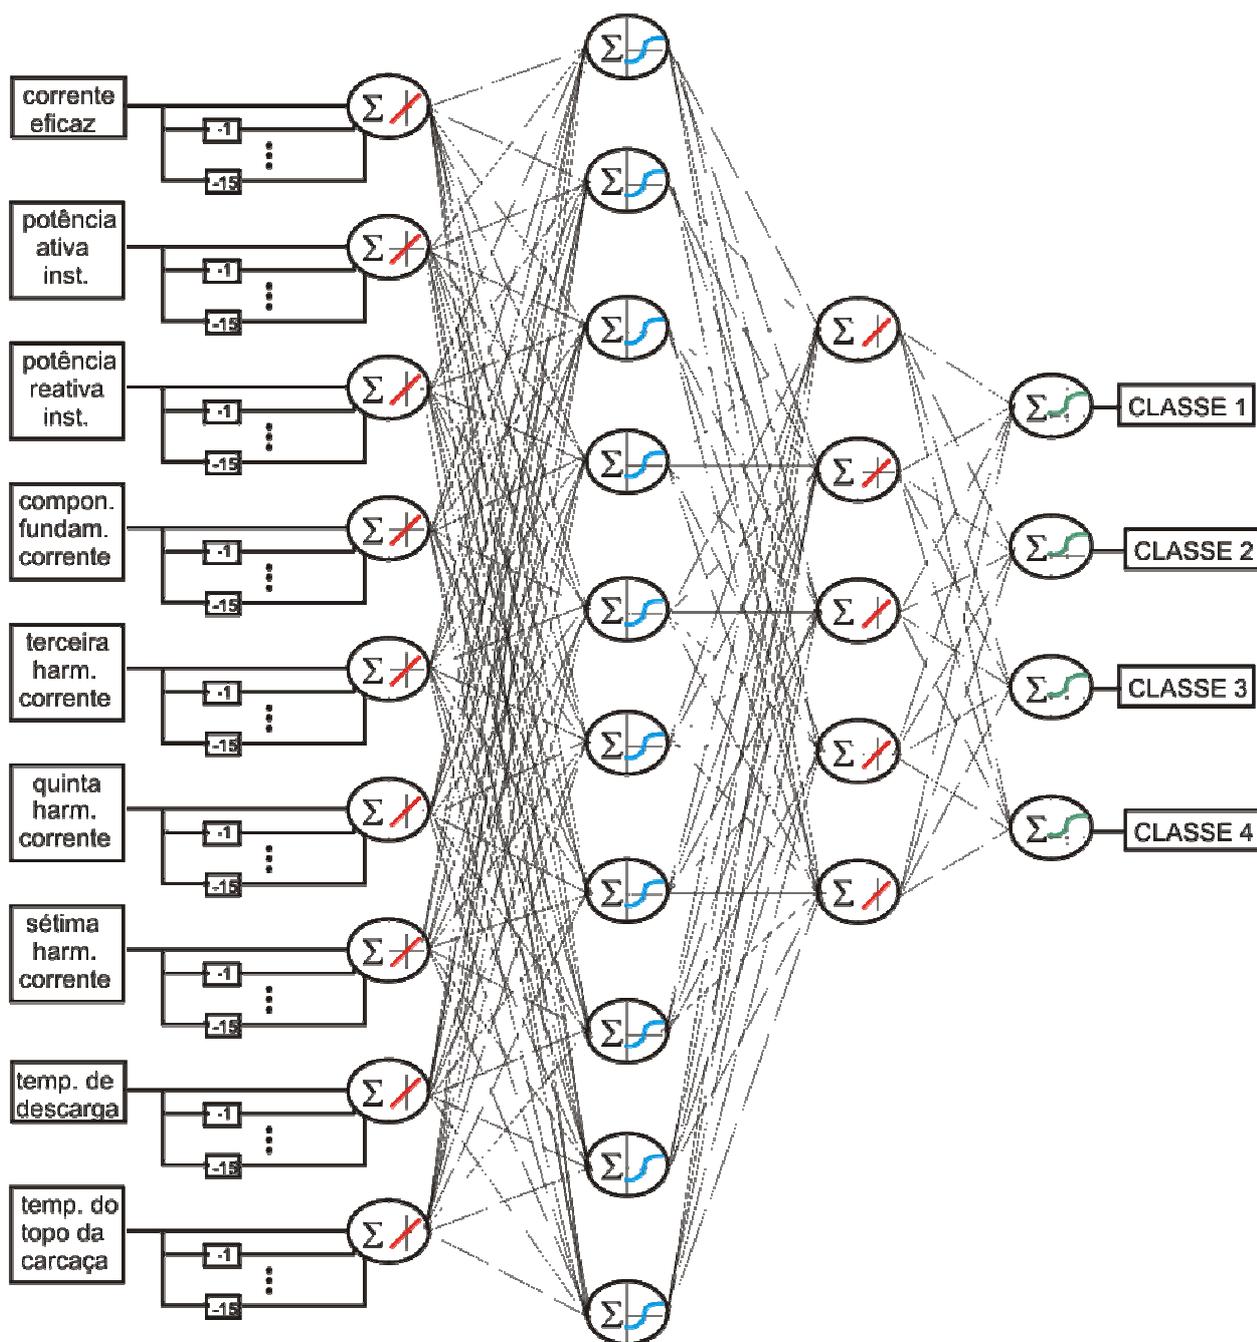


Figura 6.4 – Configuração final da rede de consumo.

6.2 AVALIAÇÃO DO SISTEMA NEURAL DE ENSAIOS

Para este estudo científico tornar-se uma aplicação industrial é imprescindível uma validação estatística com um grande número de ensaios, abrangendo vários lotes e peças diferentes durante um longo período de tempo. Esse processo fornecerá subsídios para a correta avaliação do novo sistema de ensaios quanto a características

como robustez, confiabilidade, incerteza de classificação, quantidade de erros, entre outras [56], [57], [58].

A fim de justificar a viabilidade da aplicação do sistema neural de ensaios e demonstrar o seu desempenho, foi aplicada uma avaliação menos abrangente e plausível às limitações de tempo da dissertação.

6.2.1 Ensaios para avaliação

É desejável que o sistema neural de ensaios acerte tanto ensaios que foram utilizados no treinamento quanto novos ensaios apresentados. Para a avaliação deste sistema foram realizados sete novos ensaios completos, com os dados do transitório e os resultados de regime permanente para capacidade de refrigeração e consumo de potência ativa. Mesmo com uma amostra limitada, buscou-se avaliar dois tipos de situações apresentadas ao sistema, uma delas na qual é apresentado um ensaio de um compressor não utilizado no treinamento e na outra um ensaio novo de um compressor já utilizado no treinamento.

Quando é apresentado um ensaio novo de um compressor já utilizado no treinamento avalia-se a capacidade de generalização do sistema em frente à variabilidade do processo de medição e controle da bancada e das condições iniciais do ambiente, incluindo as temperaturas de início do compressor e da bancada. Em outras palavras, existem diferentes transitórios para um mesmo resultado de regime permanente e o sistema deve ser robusto a este fato. Quando são apresentados ensaios de um compressor não utilizado no treinamento avalia-se a capacidade de generalização do sistema quanto à variabilidade das peças (compressores), da medição, controle e condições iniciais.

Do lote de oito amostras disponíveis, quatro foram usadas somente no treinamento (BD-02, BD-04, BD-05 e BD-07), uma somente na avaliação (BD-03) e três utilizadas em ambos os processos (BD-01, BD-06 e BD-08). Quatro ensaios foram realizados com o compressor BD-03 e um ensaio para os compressores BD-01, BD-06 e BD-08, totalizando sete ensaios. Os resultados desses ensaios encontram-se na tabela 6.1.

Tabela 6.1 – Resultados dos ensaios de avaliação.

Resultados dos ensaios de validação						
Compressor	número do ensaio	Capacitor permanente	Capacidade [W]		Consumo [W]	COP
			Calorímetro	Fluxo de massa		
BD-01	4	COM	198,703	197,127	140,123	1,412
BD-03	1	COM	196,898	195,269	139,186	1,409
	2	COM	196,842	194,979	139,414	1,405
	3	COM	197,972	195,863	139,19	1,415
	4	SEM	196,824	195,643	148,939	1,318
BD-06	4	COM	203,023	201,32	143,572	1,408
BD-08	4	COM	204,179	202,317	144,656	1,405

Mais uma vez foi retirado o capacitor permanente em um dos ensaios para simular um aumento no consumo de potência ativa. Os resultados obtidos para esses ensaios estão posicionados em praticamente todas as classes de classificação. A classificação final de todos os ensaios realizados é apresentada no item 6.2.2.

6.2.2 Classificação

Para realizar a avaliação, comparando a saída da rede com o resultado de regime permanente, é necessário anteriormente estabelecer a classificação de todos os ensaios já realizados. Para isso é utilizado o processo descrito no item 5.2 (utilização de Lógica Nebulosa). Diante dos vinte e oito ensaios (vinte e um para treinamento e sete para avaliação) e da incerteza de medição correspondente são traçados gráficos para a classificação (Figura 6.5 e Figura 6.6). Para facilitar a exposição os ensaios são mostrados como BD-0X.Y, em que X é o compressor e Y o número do ensaio (exemplo BD-03.1).

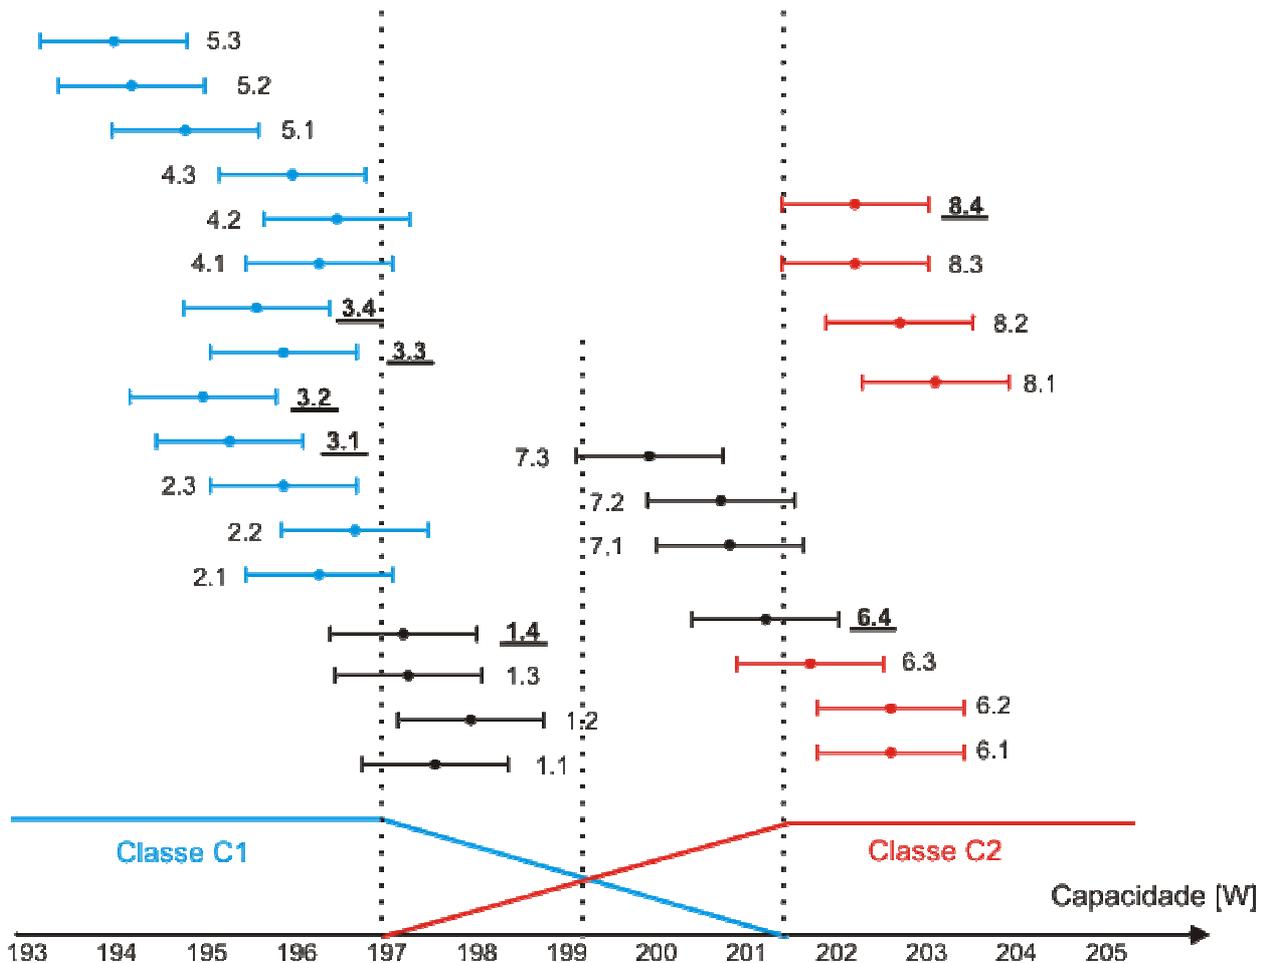


Figura 6.5 – Classificação dos resultados de capacidade de refrigeração.

Na figura 6.5 estão expostos os valores dos resultados de regime permanente para capacidade de refrigeração calculada a partir do medidor de fluxo de massa com as incertezas de medição deste método ($\pm 0,94$ W). A classificação é feita a partir do valor central, correspondente ao resultado de regime permanente. A incerteza é mostrada para ajudar a perceber o quão difícil é a tarefa do sistema neural de ensaio uma vez que somente alguns ensaios têm seus resultados, considerando a incerteza, totalmente dentro de uma classe.

Foram realizados testes com um número maior de classes para capacidade, porém a rede obteve um número menor de acertos. Com o aumento do número de casos de treinamento provavelmente mais classes poderiam ser utilizadas.

Para a classificação do consumo de potência ativa usa-se a mesma lógica e considerações, porém, como existem quatro concentrações de resultados bem definidas, os ensaios situam-se nas classes e não nas regiões de transição. A incerteza para medição do consumo é de $\pm 0,58$ W (Figura 6.6).

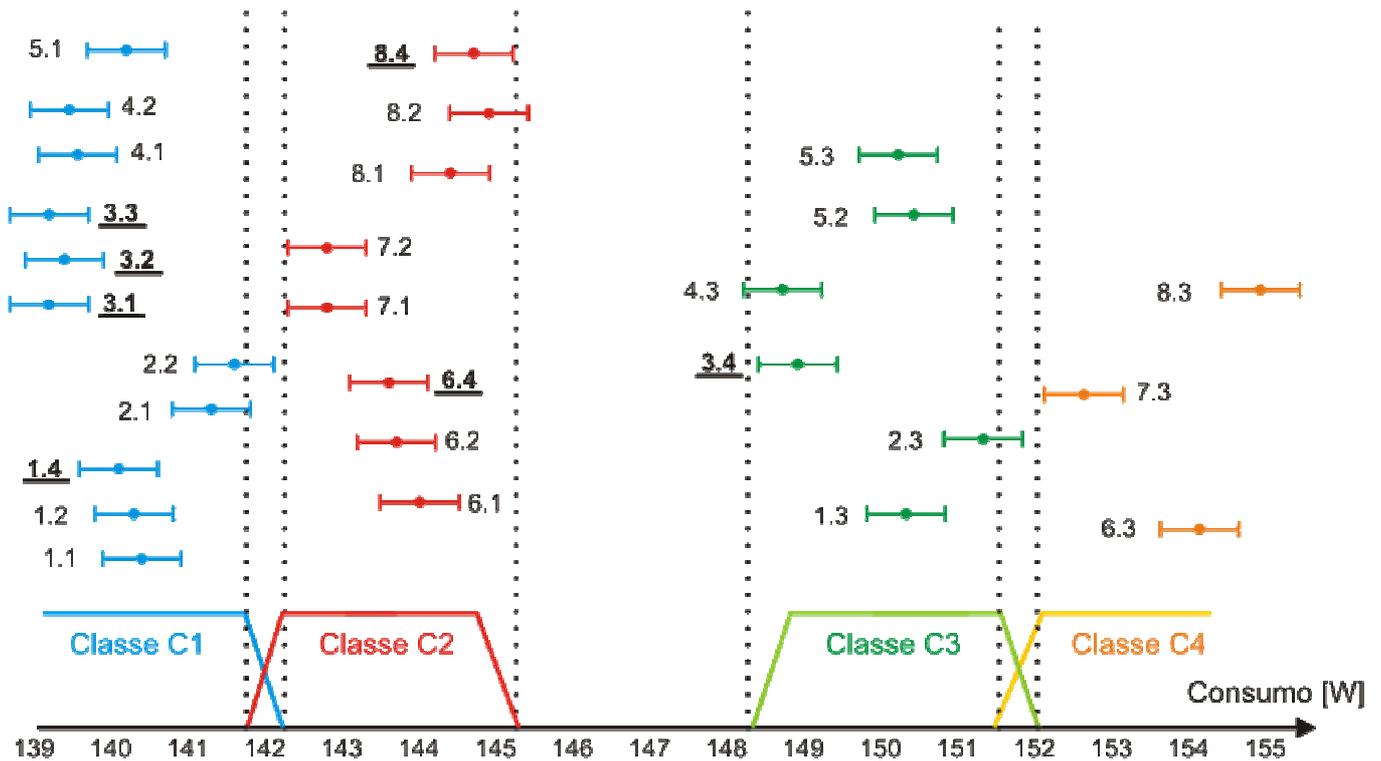


Figura 6.6 – Classificação dos resultados de consumo de potência ativa.

6.2.3 Análise dos dados obtidos e avaliação numérica

Neste item são descritos os resultados obtidos com as RNA e o sistema neural de ensaios e feitas as comparações com os resultados de regime permanente. Pelo caráter resumido deste documento, é impossível detalhar a explicação dos resultados obtidos para todos os ensaios de avaliação e de treinamento. Assim, é realizada uma análise mais aprofundada para o segundo ensaio do compressor BD-03 (BD-03.2 – avaliação) e uma explanação mais abrangente para todos os ensaios.

Primeiramente são descritos as saídas do sistema neural de ensaios para capacidade, posteriormente para consumo e no final um levantamento do sistema como um todo. Na figura 6.7 estão mostradas as duas classes de saída da RNA de capacidade (C1 e C2) para o ensaio BD-03.2:

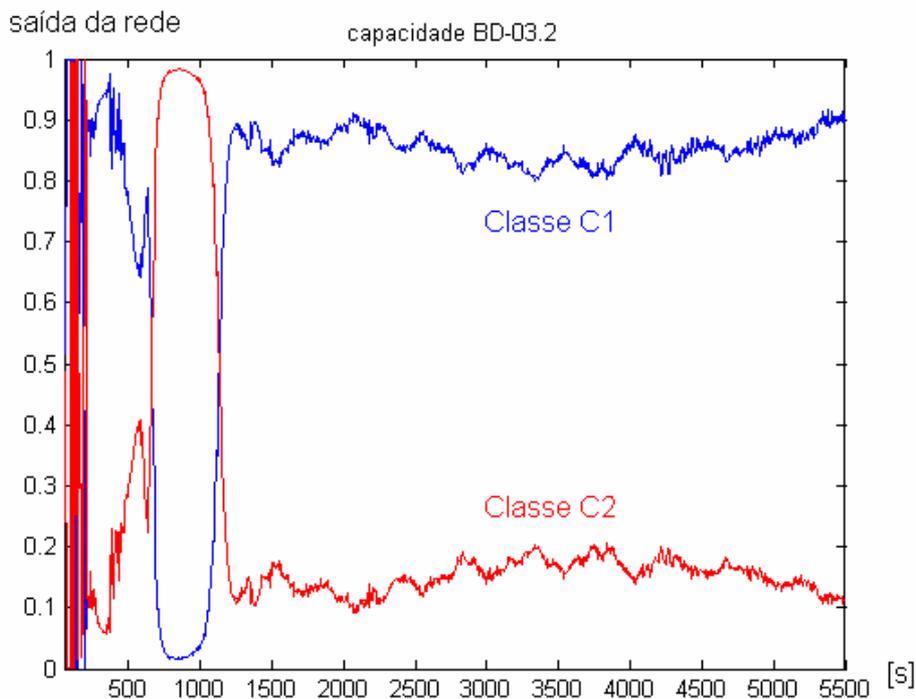


Figura 6.7 – Saída da RNA de capacidade para o ensaio BD-03.2.

Na figura 6.7, a linha azul representa a classe C1 e a vermelha C2. Até aproximadamente 1200 s (tempo de início do treinamento) identifica-se um período transitório das saídas da rede, seguido por uma estabilidade até o final do ensaio.

Em alguns ensaios podem ocorrer variações indesejáveis em algumas medições causados por fatores não esperados, como bolhas passando pelo medidor de fluxo de massa. Somado a isto na execução normal percebe-se um pequeno “ruído” na saída da rede (Figura 6.7). Para solucionar estes dois problemas as saídas são filtradas com um filtro de média móvel (40 amostras), como visto na figura 6.8 [59], [60] .

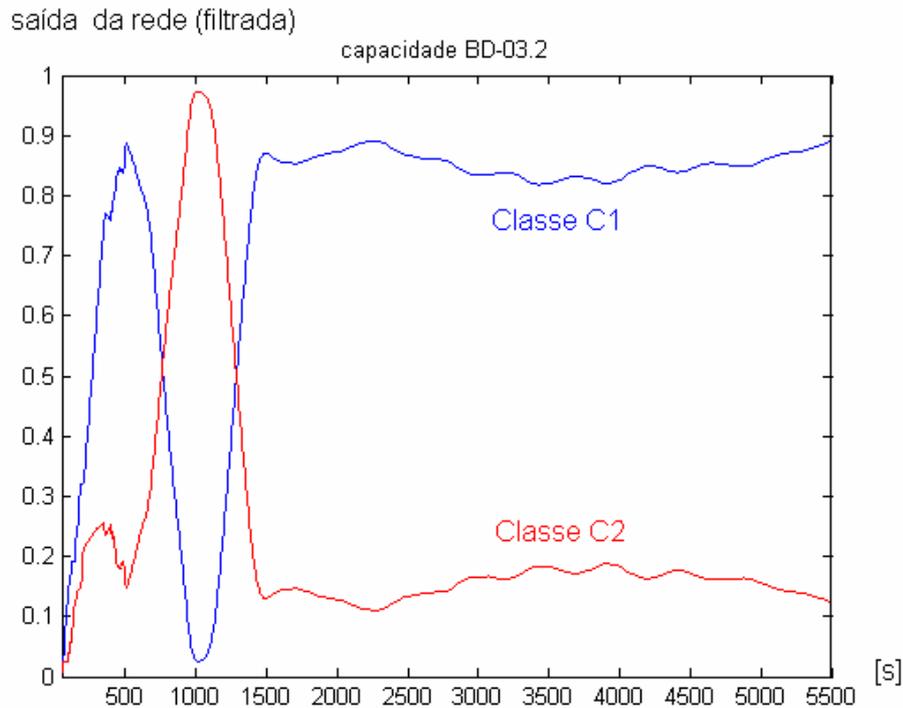


Figura 6.8 - Saída filtrada da RNA de capacidade para o ensaio BD-03.2.

Os padrões de saída de treinamento para as classes variam de 0,1 (menor pertinência) a 0,9 (maior pertinência). Fica claro neste caso que o ensaio pertence à classe C1 com pertinência de 94% à esta classe e 6% à classe C2. Essa conclusão foi retirada a partir do gráfico, porém posteriormente é realizado um processo de decisão automático (denebulização), mostrado na figura 6.9.

A pertinência em porcentagem é calculada tomando o valor médio da saída no período estável, diminuindo do limite de referência inferior (0,1) e dividindo o resultado pela diferença entre os limites superior e inferior de referência ($0,9 - 0,1 = 0,8$). Para o caso acima o valor médio de C1 é 0,85 e de C2 é 0,15, assim :

$$Pertinência(\%) = \frac{(0,85 - 0,1)}{0,8} = 0,9375 \times 100 = 93,75\% \quad (11)$$

$$Pertinência(\%) = \frac{(0,15 - 0,1)}{0,8} = 0,0625 \times 100 = 6,25\% \quad (12)$$

Até agora, na figura 6.7 e figura 6.8, foram indicadas as saídas da RNA, porém para indicar a classe de capacidade em que o compressor se enquadra (saída do sistema neural de ensaios) automaticamente as saídas da rede passam pelo denebulizador que fornece a resposta com base na tabela 5.3 (Figura 6.9). A saída zero (0) representa uma inconsistência no julgamento do resultado por parte da base

de regras, provavelmente causado por graus de pertinências muito altos para duas classes próximas ou graus de pertinência médios para classes não vizinhas (sem região de transição comum).

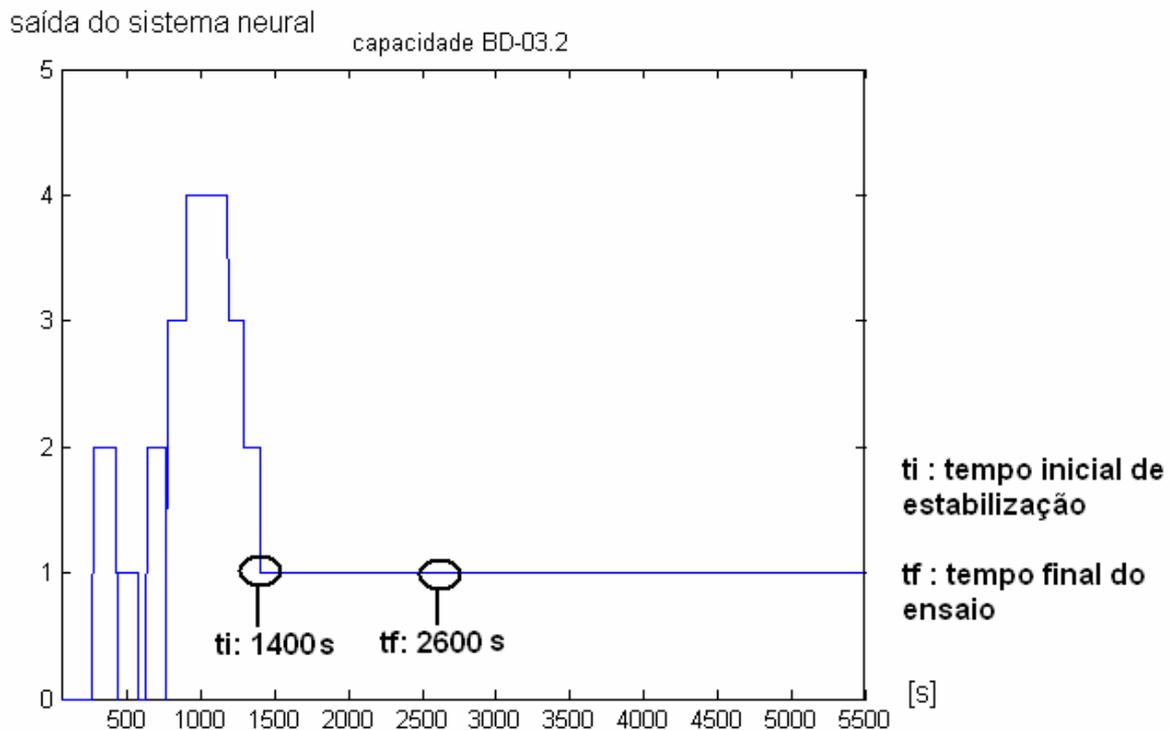


Figura 6.9 – Saída do sistema neural para a capacidade do ensaio BD-03.2.

O sistema fornece uma resposta para todos os instantes de aquisição dos dados e execução da RNA (cinco em cinco segundos) e para calcular o resultado final de capacidade de refrigeração foi arbitrado que a saída se mantenha estável (inalterada) por 1200 s (20 min). Esse período arbitrado é necessário para que a rede indique somente uma saída correta e que essa seja a resposta definitiva. Na figura 6.9 estão apontados t_i (tempo inicial), que é o tempo no qual se inicia a estabilização, e t_f (tempo final), tempo final do ensaio pelo método proposto. No gráfico a saída continua a ser traçada além de t_f para demonstrar a continuidade da estabilização.

Enquanto a saída do sistema não atingir o período mínimo de estabilização (1200 s) o ensaio prossegue e na pior das hipóteses o resultado para o ensaio irá ser o resultado de regime permanente, calculado pelos métodos tradicionais propostos pela norma ISO 917. Se o período mínimo de estabilização é atingido um comando é enviado para o programa principal e o ensaio é encerrado automaticamente.

O resultado final fornecido pelo sistema neural de ensaios no tempo t_f para BD-03.2 é o número 1, pertence à classe de capacidade de refrigeração C1 (193W a 197W) com 94% de pertinência a esta classe. O resultado de regime permanente de capacidade calculada pelo fluxo de massa para o ensaio BD-03.2 é 194,979 W (Tabela 6.1). Nesta situação os resultados estão em acordo.

Para demonstrar a atuação da rede para todos os ensaios (treinamento e avaliação) é apresentada a figura 6.10. Nesses gráficos encontram-se as saídas não filtradas para as classes C1 e C2.

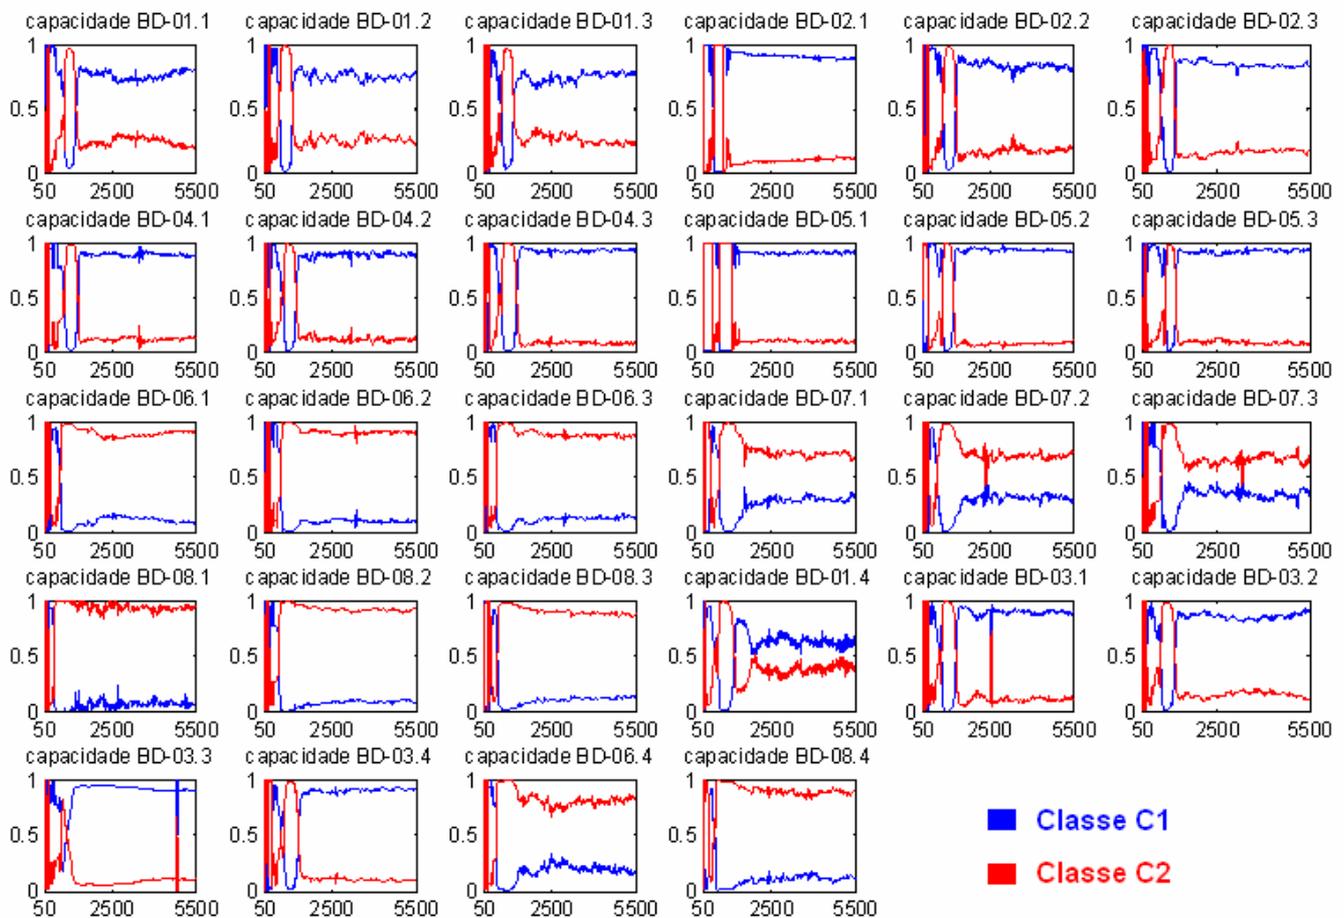


Figura 6.10 – Saídas da RNA de capacidade para todos os ensaios.

Os primeiros vinte e um ensaios são de treinamento e os últimos sete de avaliação, todos eles seguindo a terminologia já indicada, BD-0X.Y. É possível perceber que em ensaios como BD-03.1 ocorre uma variação brusca na saída no tempo 2500 s, provavelmente causada por algum padrão de comportamento desconhecido pela rede ou um problema na medição de fluxo de massa. Para solucionar estes acontecimentos é aplicado o filtro de média móvel (Figura 6.11).

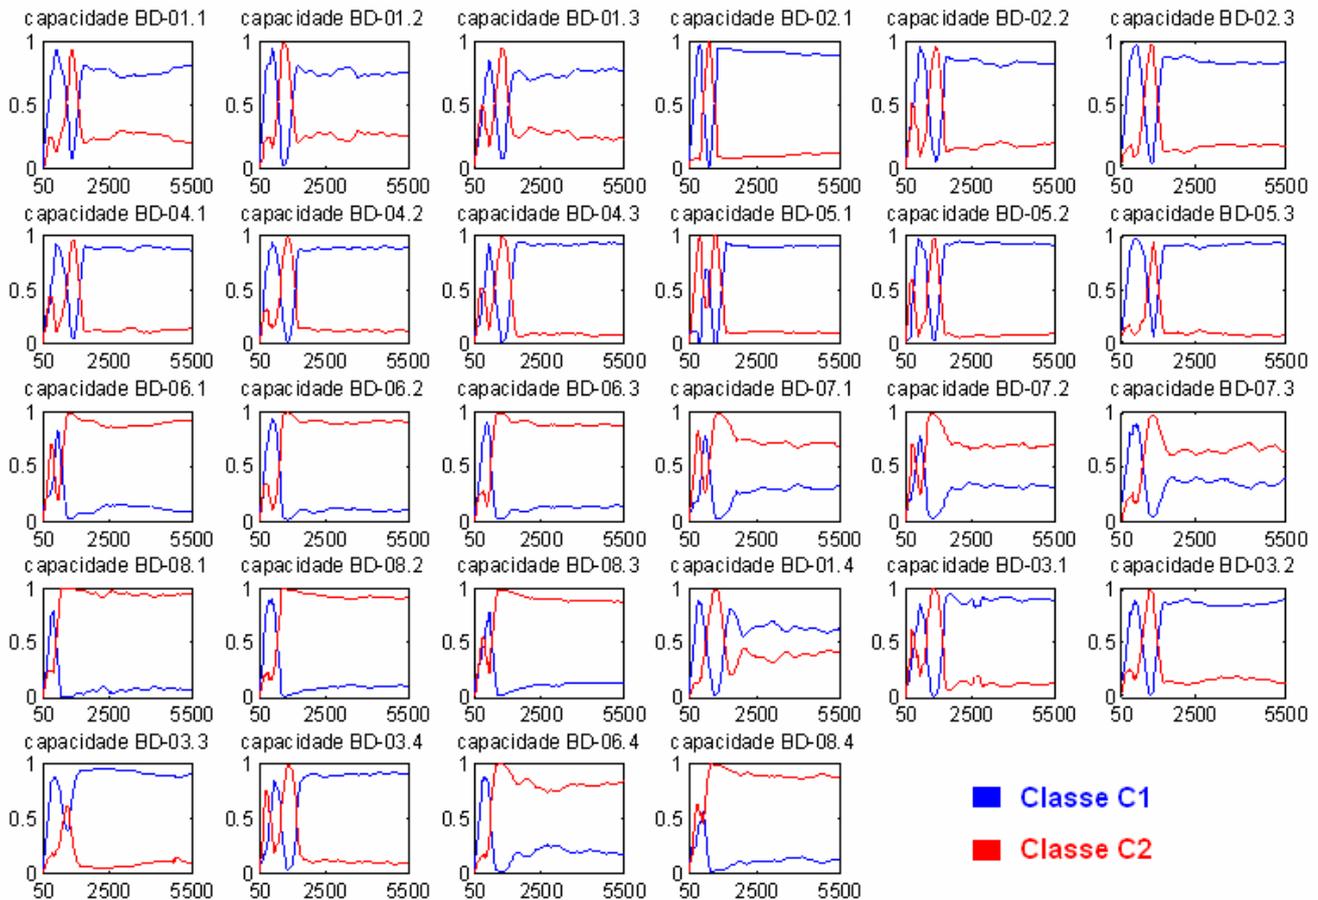


Figura 6.11 – Saída filtrada da RNA para todos os ensaios.

Os traços estão mais limpos e sem os “ruídos” ou variações bruscas, facilitando o processo de tomada de decisão e indicação da resposta do sistema. Em alguns ensaios a superioridade é da classe C1 (azul) e em outros da classe C2 (vermelho). Já em alguns deles as duas curvas se aproximam indicando uma região de transição entre as classes (por exemplo, BD-01.4).

Os dados expostos na figura acima são interpretados e um resultado para cada ensaio e cada instante de tempo é indicado na figura 6.12. Da mesma forma como explicado no item 5.2.2, cada número representa uma saída para o sistema e somente após um período mínimo de estabilização em uma única saída é que o ensaio é encerrado e o resultado final é obtido.

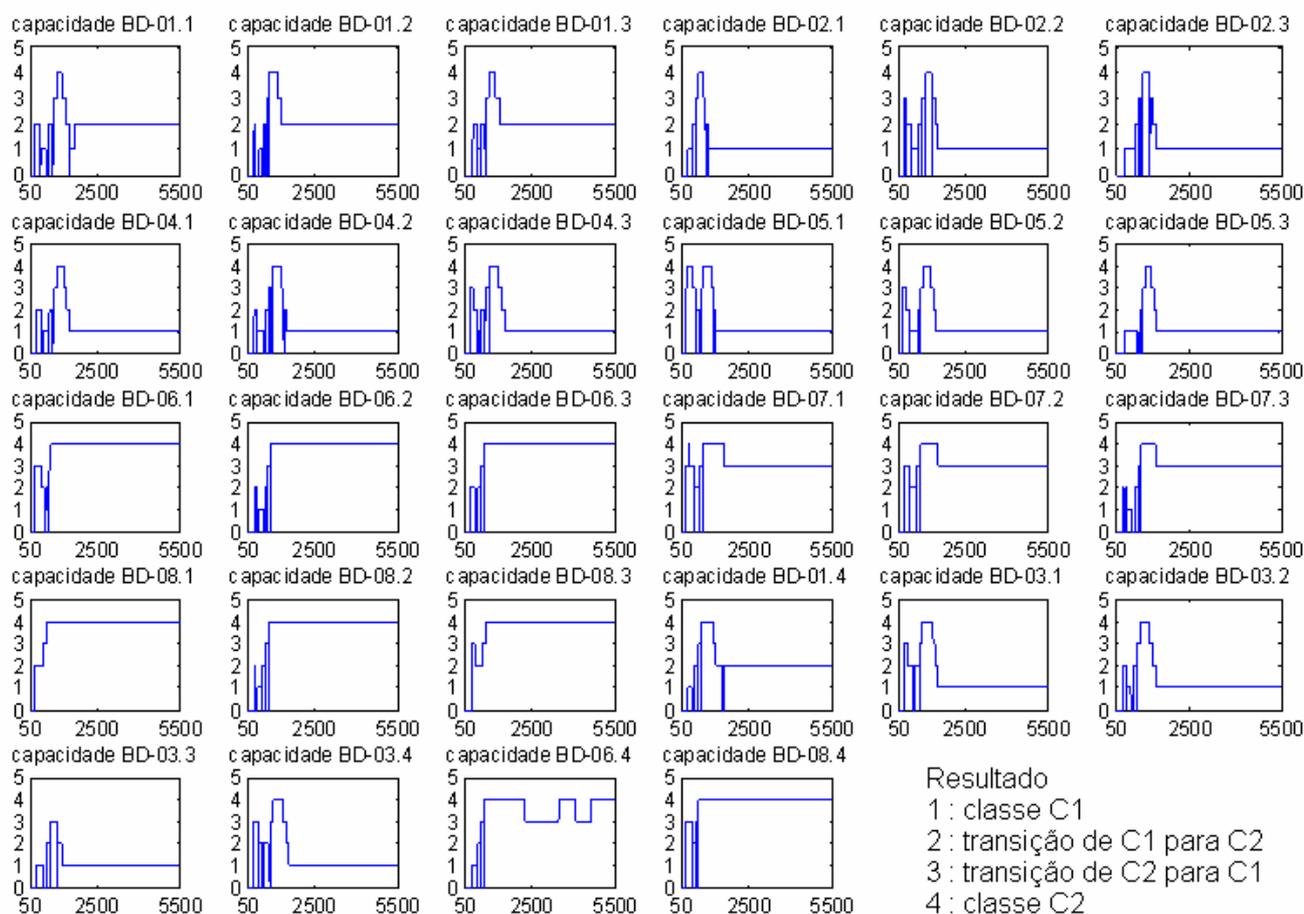


Figura 6.12 – Saídas do sistema neural para todos os ensaios.

Os ensaios possuem diferentes tempos iniciais de estabilização (t_i), mas a média é 1100 s. Para comparar os resultados da classificação do sistema neural de ensaios com os resultados de regime permanente é mostrada a tabela 6.2 .

Tabela 6.2 – Resultados da classificação para capacidade de refrigeração.

Ensaio	Classificação (capacidade de refrig.)		Ensaio	Classificação (capacidade de refrig.)	
	sist. neural de ensaio	regime permanente		sist. neural de ensaio	regime permanente
BD-01.1	2	2	BD-06.3	4	4
BD-01.2	2	2	BD-07.1	3	3
BD-01.3	2	2	BD-07.2	3	3
BD-02.1	1	1	BD-07.3	3	3
BD-02.2	1	1	BD-08.1	4	4
BD-02.3	1	1	BD-08.2	4	4
BD-04.1	1	1	BD-08.3	4	4
BD-04.2	1	1	BD-01.4	2	2
BD-04.3	1	1	BD-03.1	1	1
BD-05.1	1	1	BD-03.2	1	1
BD-05.2	1	1	BD-03.3	1	1
BD-05.3	1	1	BD-03.4	1	1
BD-06.1	4	4	BD-06.4	não estabilizou	3
BD-06.2	4	4	BD-08.4	4	4

No ensaio BD-06.4 o resultado do sistema neural de ensaio não atingiu o período mínimo de estabilização, permanecendo menos de 1200 s em um só resultado continuamente (Figura 6.13). A justificativa para tal resposta é que a capacidade de refrigeração do ensaio (201,32 W), como vista na figura 6.5 que mostra a classificação dos ensaios, está muito próxima do limite da região de transição e da classe C2 (201,5 W). Considerando a incerteza da medição ($\pm 0,8$ W) e que o resultado alternou entre a região de transição e a classe C2 (resultados 3 e 4 respectivamente) é aceitável esse tipo de atitude do sistema.

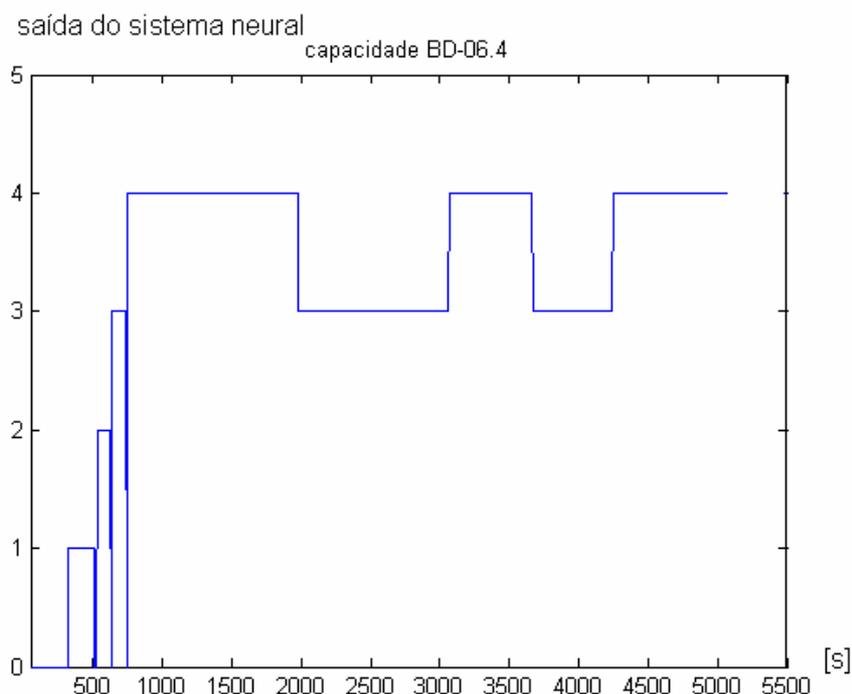


Figura 6.13 – Saída do sistema neural para o ensaio BD-06.4.

Na execução normal o ensaio seria levado até o período de regime permanente e o resultado considerado seria dado pelos métodos tradicionais instalados na bancada (método C e F). Esta ação não é considerada como um erro, somente como uma demora no encerramento do ensaio (atitude conservadora). Com um número maior de ensaios para treinamento possivelmente esse problema possa ser solucionado.

A análise dos resultados obtidos para o consumo de potência ativa é feita de modo semelhante, porém para não repetir informações são expostos somente os fatores relevantes e não citados na análise feita anteriormente. Na figura 6.14 estão

traçados os comportamentos das quatro classes de saída (C1, C2, C3 e C4) para o consumo do ensaio BD-03.2.

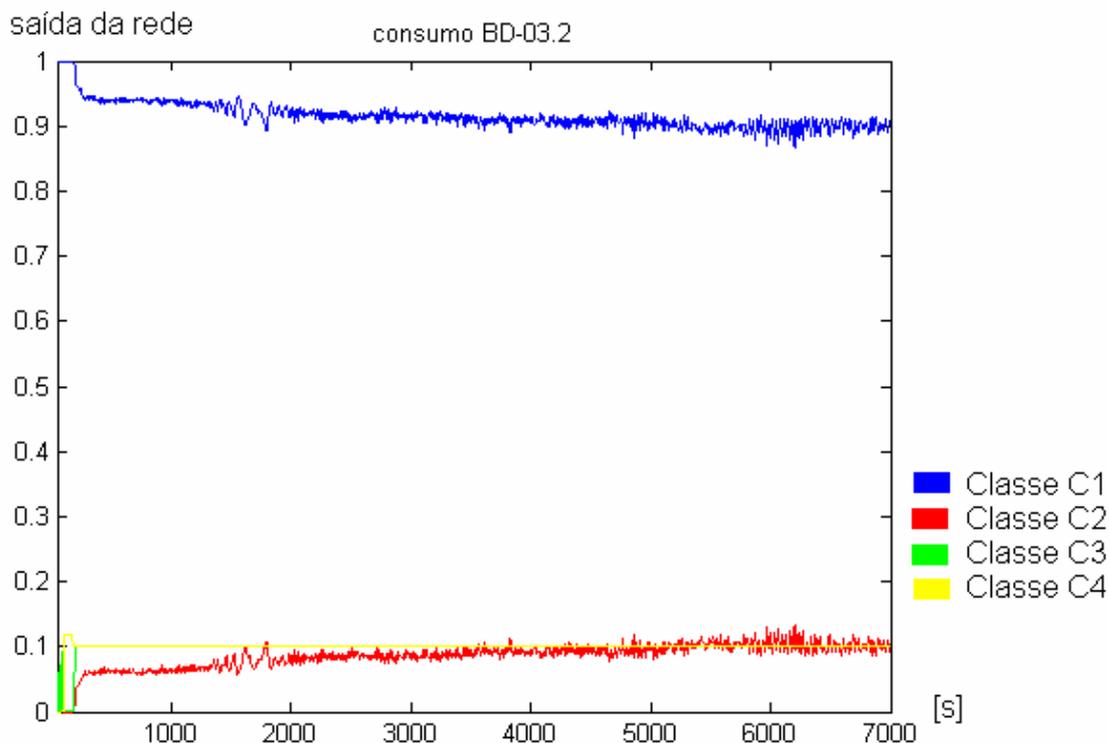


Figura 6.14 – Saída da RNA de consumo de potência ativa para o ensaio BD-03.2.

A linha azul representa as saídas da RNA para a classe C1, vermelha para C2, verde para C3 e amarela para C4. O período transitório nestas saídas é bem menor que para as saídas de capacidade, atingindo uma estabilização aparente em 100 s.

Um filtro de média móvel também é aplicado nesta situação e depois as pertinências são calculadas. Os padrões de saída de treinamento para as classes também variam de 0,1 a 0,9, mas neste caso como o valor médio é um pouco maior que 0,9 para a classe C1, é considerado pertinência de 100%. Para as outras classes a pertinência é de aproximadamente 0%. A resposta final do sistema neural é fornecida após a passagem dos dados filtrados pela base de regras (denebulizador) (Figura 6.15).

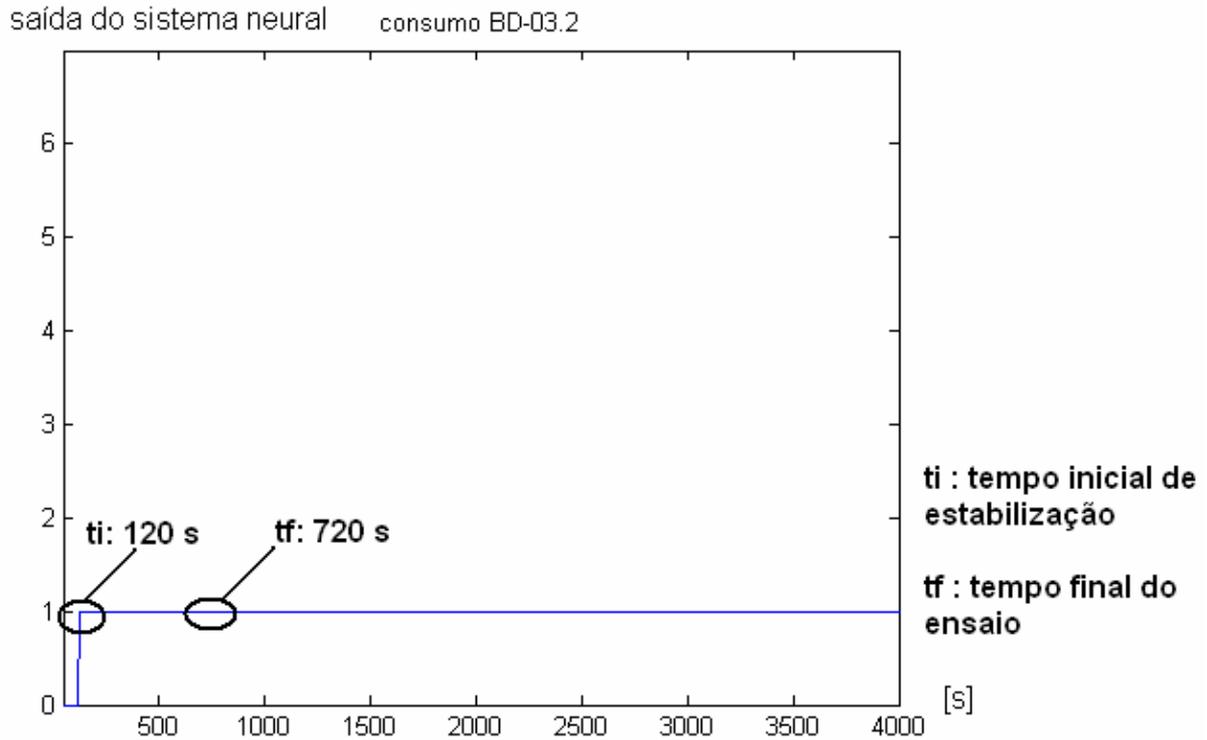


Figura 6.15 – Saída do sistema neural para consumo do ensaio BD-03.2.

Para calcular o resultado final de consumo de potência ativa é necessário que a saída se mantenha estável por 600 s (10 min). A diferença neste período mínimo em relação à rede anterior é consequência da rápida estabilização das grandezas elétricas, da maior dispersão nos ensaios de treinamento e da melhor resposta desta RNA. No gráfico acima estão apontados t_i como 120 s e t_f como 720 s, porém a estabilização continua até o final do ensaio.

O resultado final fornecido pelo sistema neural de ensaios no tempo t_f para BD-03.2 é o número 1, pertence à classe de consumo de potência ativa C1 (139 W a 141,75 W) com 100% de pertinência a esta classe. O resultado de regime permanente para o ensaio BD-03.2 é 139,414 W (Tabela 6.1), início da faixa. Nessa situação os resultados também estão em acordo.

Para expor todas as saídas da RNA de todos os ensaios é construída a figura 6.16, na qual encontram-se os dados sem filtragem correspondentes às quatro classes.

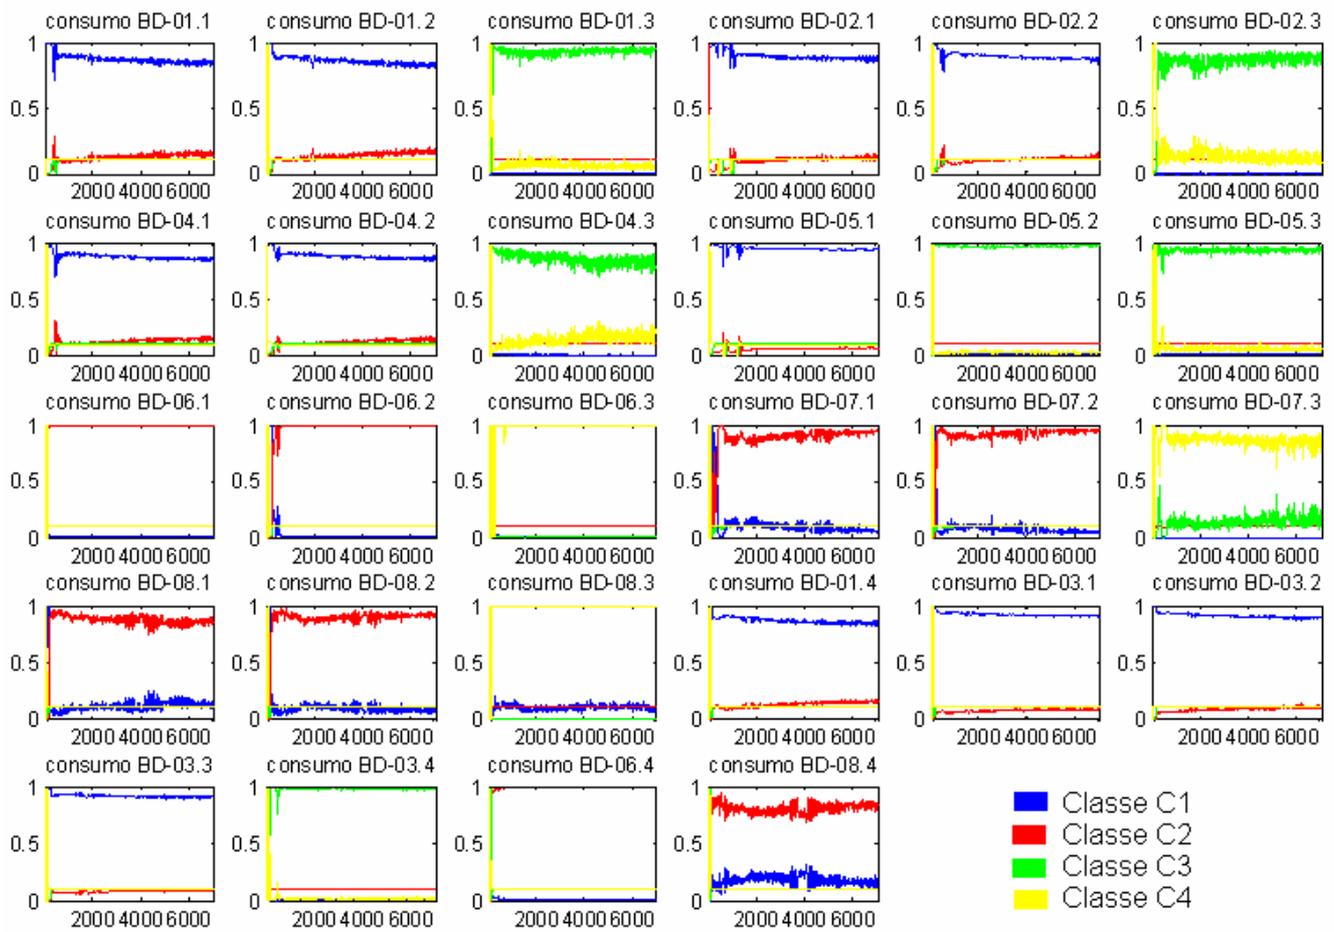


Figura 6.16 – Saídas da RNA de consumo para todos os ensaios.

Os primeiros vinte e um ensaios são de treinamento e os últimos sete de avaliação. Para solucionar o problema de “ruído”, mais uma vez os dados são filtrados (média móvel de 30 amostras) (Figura 6.17).

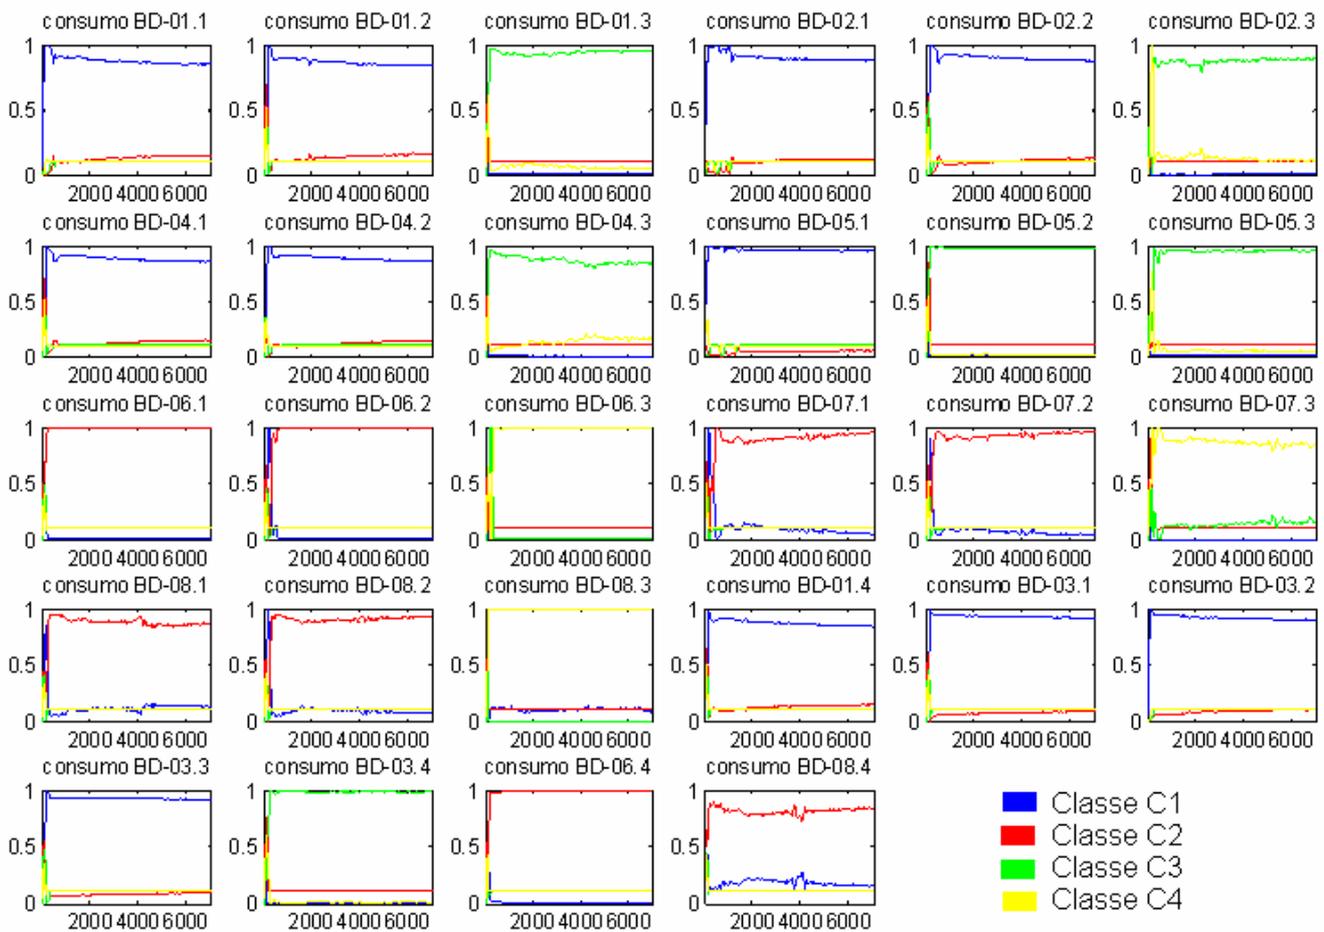


Figura 6.17 – Saídas filtradas da RNA de consumo para todos os ensaios.

Os resultados estão distribuídos nas quatro classes estabelecidas. Os valores das saídas são processados pela base de regras de consumo e os resultados finais para cada ensaio e cada instante de tempo são determinados (Figura 6.18). Cada número representa uma saída para o sistema (1 a 6) e somente após um período mínimo de estabilização em uma única saída é que o ensaio é encerrado e o resultado final é obtido.

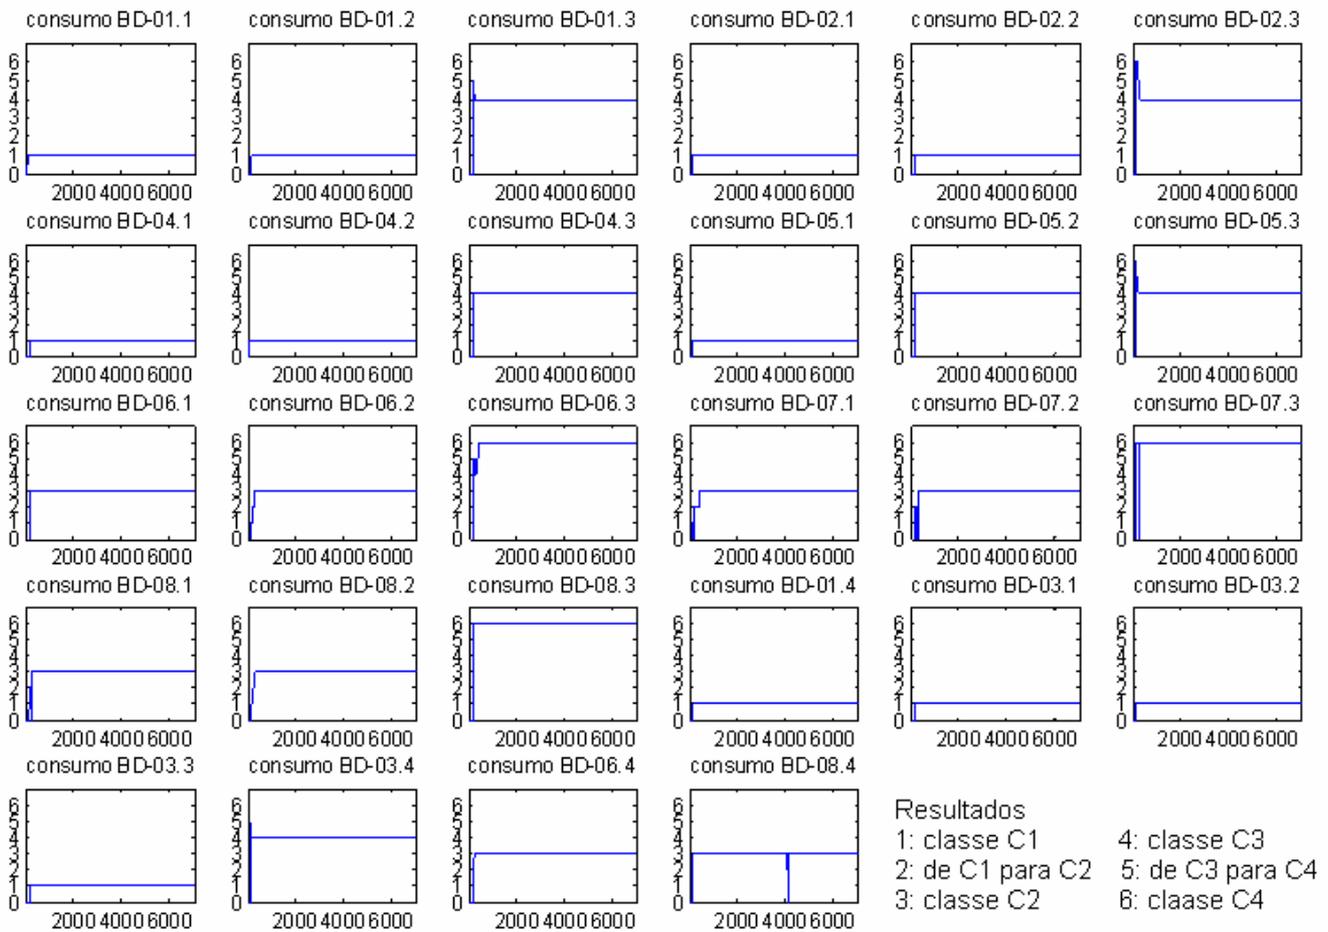


Figura 6.18 – Saídas do sistema neural de consumo para todos os ensaios.

O valor médio para os tempos iniciais de estabilização dos resultados de consumo dos ensaios é de 240 s. Para comparar os resultados da classificação do sistema neural de ensaios com os resultados de regime permanente é mostrada a tabela 6.3:

Tabela 6.3 - Resultados da classificação para consumo de potência ativa.

Ensaio	Classificação (consumo de pot. ativa.)		Ensaio	Classificação (consumo de pot. ativa.)	
	sist. neural de ensaio	regime permanente		sist. neural de ensaio	regime permanente
BD-01.1	1	1	BD-06.3	6	6
BD-01.2	1	1	BD-07.1	3	3
BD-01.3	4	4	BD-07.2	3	3
BD-02.1	1	1	BD-07.3	6	6
BD-02.2	1	1	BD-08.1	3	3
BD-02.3	4	4	BD-08.2	3	3
BD-04.1	1	1	BD-08.3	6	6
BD-04.2	1	1	BD-01.4	1	1
BD-04.3	4	4	BD-03.1	1	1
BD-05.1	1	1	BD-03.2	1	1
BD-05.2	4	4	BD-03.3	1	1
BD-05.3	4	4	BD-03.4	4	4
BD-06.1	3	3	BD-06.4	3	3
BD-06.2	3	3	BD-08.4	3	3

O desempenho do sistema neural de ensaios como um todo pode ser sintetizado na tabela 6.4.

Tabela 6.4 – Desempenho do sistema.

Ensaio	Acertos			
	Capacidade de refrig.		Consumo de pot. ativa	
treinamento (21)	21	100%	21	100%
validação (7)	6*	85,7%	7	100%
todos (28)	27*	96,40%	28	100%
tempo médio de ensaio	2300 s (38,3 min)		840 s (14 min)	
	1100 s - início da estabilização da rede + 1200 s - período de estabilização da rede		240 s - início da estabilização da rede + 600 s - período de estabilização da rede	

* ensaio BD-06.4

É considerado que o sistema neural de ensaios não acertou no ensaio BD-06.4, pois não identificou o resultado final do ensaio (não atingiu a estabilização). Isso não representa um erro de classificação, mas uma “falha” no objetivo de reduzir o tempo de ensaio.

O tempo médio de ensaio obtido pelo sistema neural de ensaios para os dois parâmetros (principalmente para capacidade de refrigeração) pode ser reduzido com a automação completa da bancada e o aumento do número de ensaios para treinamento da RNA. Acredita-se que com estas medidas a redução seja significativa.

Os resultados obtidos neste trabalho foram expressivos, uma vez que a redução do tempo de ensaio, com confiabilidade nos resultados, foi grande. Para o parâmetro consumo de potência ativa do compressor a diminuição do tempo de ensaio foi maior, em função da estabilização mais rápida das variáveis elétricas e da melhor caracterização do parâmetro pelas medições realizadas. A capacidade de refrigeração é dependente da temperatura do corpo do compressor e possui estabilização mais demorada que as variáveis elétricas, assim o tempo final de ensaio foi maior.

O número de acertos do sistema foi alto e a única falha na inferência durante o transitório, ensaio BD-06.4, não comprometeu a classificação do ensaio. Mesmo com um tempo maior o valor obtido em regime permanente seria correto para este caso.

Em uma comparação direta entre o método da norma ISO 917 (cálculo das características em regime permanente) e o método proposto por esta dissertação

(inferência das características durante o transitório) dois fatores se destacam: tempo de ensaio; resolução dos resultados. O tempo de ensaio é claramente menor no método proposto. Porém, por classificar os resultados em um faixa de valores (classes), a resolução dos resultados é pior com o SNE. A resolução do método de regime permanente é melhor e é limitada apenas pela incerteza de medição deste método. Este último fator não tira o mérito da pesquisa, uma vez que a proposta de trabalho era a redução do tempo de ensaio através de um enfoque mais qualitativo, aplicados a ensaios rotineiros.

7 CONCLUSÕES

O trabalho desenvolvido atingiu resultados muito importantes e interessantes tanto do ponto de vista de pesquisa científica e tecnológica quanto de aplicação industrial. Envolveu uma série de áreas de conhecimentos distintas: refrigeração, inteligência artificial, ensaios de produtos, eletrônica, metrologia, entre outras. Para cada uma dessas áreas é possível obter conclusões que podem ser aplicadas a problemas semelhantes ao apresentado neste documento.

Um dos principais méritos desta pesquisa foi o caráter investigativo, que forneceu indicações gerais e específicas de um método de desenvolvimento de sistemas de ensaios.

O objetivo principal de diminuir o tempo de ensaios de desempenho de compressores herméticos com um bom índice de acertos foi alcançado, mostrando que é viável a aplicação do método proposto.

Para facilitar o entendimento das conclusões este capítulo é dividido em cinco itens.

7.1 TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

As técnicas de inteligência artificial têm demonstrado cada vez mais o seu potencial de aplicação na metrologia e na indústria em geral. Há alguns anos era desacreditado o uso prático dessas técnicas, situação que está se revertendo em função de trabalhos como este, em que a prática valida a teoria.

A decisão da utilização de redes neurais artificiais baseou-se na dificuldade de análise dos transitórios dos ensaios e por esses serem dinâmicos e não lineares. A falta de regras explícitas de classificação no período anterior ao regime permanente e

de conhecimento desse assunto direcionou ao uso de uma RNA dinâmica com treinamento supervisionado.

A RNA perceptron multicamadas direta utilizando neurônios dinâmicos na camada de entrada e com emprego do algoritmo de treinamento da retropropagação conseguiu realizar as tarefas de inferência e classificação mesmo na presença de poucos exemplos de treinamento.

Por se tratar de muitas medições, um número grande de atrasos e uma janela de tempo extensa (número alto de aquisições), o treinamento das redes exige muito esforço computacional. Para que essa exigência computacional não resultasse em um tempo muito grande de treinamento uma função de treinamento simplificada foi utilizada, segundo indicações do manual do software utilizado [55]. É importante salientar que os tempos de treinamento e de execução das redes são diferentes, o primeiro pode durar horas, porém o segundo é praticamente instantâneo.

A transição abrupta no estabelecimento das classes de consumo de potência ativa e de capacidade de refrigeração e a incerteza de medição dos parâmetros fizeram com que as redes não conseguissem um treinamento efetivo e robustez na execução. Assim, para auxiliar as RNA, foi essencial o emprego de lógica nebulosa, atribuindo graus de pertinência dos ensaios a cada classe de classificação, por meio das funções de pertinência trapezoidais. Após a implementação dessa técnica os resultados obtidos melhoraram muito e a robustez adquirida pelo sistema reforça ainda mais a aplicação do método.

7.2 GRANDEZAS MEDIDAS E ADEQUAÇÃO DO SISTEMA

Foi essencial para o desenvolvimento deste trabalho a fase de pesquisa e estabelecimento das medições que serviram de entradas para as RNA. Devido à falta de informações a respeito do transitório dos ensaios de desempenho, a dificuldade de análise individual e de correlações dos parâmetros do compressor foi muito grande.

A ausência de um histórico de ensaios fez com que a estratégia seguida partisse de um breve estudo teórico, para indicar as medições que possivelmente poderiam ser utilizadas, passando pela implementação dos sistemas de medição, pelos ensaios iniciais e finalizando na seleção das grandezas.

Com o objetivo de identificar informações durante o transitório que permitissem inferir o comportamento de regime do compressor foram feitas diversas medições de temperatura, vibração, pressão, corrente, tensão e fluxo de massa. Para que as informações não ficassem mascaradas em incertezas de medição a análise metrológica foi intensa e as incertezas foram mantidas em valores aceitáveis.

Os sistemas atuais de ensaios de desempenho não foram desenvolvidos direcionados à utilização do método proposto nesta dissertação; assim algumas adequações fizeram-se necessárias. O desenvolvimento e instalação dos novos sistemas de medição foram feitos com sucesso, exceto em relação à medição da quantidade de óleo no separador, fato ocasionado pela ausência de repetitividade do separador. As melhorias na automação da bancada minimizaram a influência do operador sobre os ensaios, diminuíram o período de transitório e permitiram que as variáveis controladas apresentassem padrões semelhantes em ensaios diferentes.

O software Labview foi utilizado com sucesso no programa principal e permitiu o armazenamento de todos os dados do ensaio, bem como a integração com o módulo neural de ensaio programado em Matlab. O Labview foi escolhido em função das características de aquisição e comunicação com os sistemas de medição e de controle da bancada. O Matlab foi utilizado porque fornece, através do *toolkit* de redes neurais, facilidades de programação das redes, próprio para um trabalho de pesquisa.

A classificação e seleção das grandezas após os ensaios iniciais identificaram insensibilidades de algumas variáveis com relação a mudanças de consumo de potência ativa e capacidade de refrigeração. Além disto, as variáveis controladas não contribuíram com informações sobre o desempenho do compressor e as medições de vibração somente conseguem identificar diferenças entre lotes de fabricação, mas não diferenças dentro desses lotes. As grandezas utilizadas como entradas para as RNA, descritas no item 6.1.1, apresentaram os melhores desempenhos na tarefa de inferência das características de regime permanente.

7.3 ENSAIOS REALIZADOS

Os ensaios realizados representam toda a informação adquirida do processo industrial em análise e serviram para definir os parâmetros do sistema neural de ensaios, bem como para o treinamento das RNA. Em razão de limitações do projeto

não foi possível realizar um número grande de ensaios com resultados distintos, porém, mesmo com um número reduzido, o método mostrou-se eficaz e viável.

A utilização do artifício de retirada do capacitor permanente para simular um aumento da potência ativa consumida conseguiu aumentar a dispersão dos dados e facilitou o treinamento da RNA. A princípio os dados obtidos nos ensaios são válidos, porém é possível que esta situação não tenha correlação com as situações reais de aumento do consumo.

A análise do transitório dos ensaios realizados foi muito interessante e permitiu a obtenção de conclusões a respeito das variáveis medidas, tais como tempo de estabilização, tipo de oscilação (exponencial, senoidal, oscilatória etc.) e sensibilidade a mudanças de capacidade e consumo.

A utilização de vinte e um ensaios para treinamento das RNA e sete para avaliação do sistema neural de ensaios foi eficiente e apresentou bons resultados, porém cobriu uma faixa pequena de operação de um modelo de compressor. O consumo variou entre $(139,45 \pm 0,58)$ W e $(155,35 \pm 0,58)$ W e a capacidade entre $(193,94 \pm 0,94)$ W e $(203,15 \pm 0,94)$ W pelo método F e entre $(195,60 \pm 2,10)$ W e $(204,73 \pm 2,10)$ W pelo método C. As incertezas de medição dos parâmetros do compressor influenciam diretamente na largura da faixa de diagnóstico; quanto menor a incerteza mais estreita é a faixa. Para uma avaliação mais abrangente, outros modelos de compressores devem ser analisados e a quantidade de ensaios aumentada.

7.4 AVALIAÇÃO DO SISTEMA NEURAL DE ENSAIOS E REDUÇÃO DO TEMPO DE ENSAIO

Para a validação direcionada à aplicação industrial do sistema neural de ensaios (SNE) é necessário que um número muito grande de ensaios seja feito com uma amostra heterogênea e durante um período longo de tempo. Porém, para avaliar o método proposto na dissertação e demonstrar a viabilidade da técnica, a amostra atual, com poucos ensaios, foi suficiente.

O SNE não atende alguns requisitos das normas de ensaios de desempenho, como o tempo em regime permanente, por isso ele deve ser utilizado para testes internos da empresa. As normas devem ser seguidas caso seja necessário

comparação com outros fabricantes e exposição de dados em catálogos. Este fato não prejudica a aplicação do trabalho, pois grande parte dos ensaios são internos.

Considerando o parâmetro consumo de potência ativa do compressor, o SNE acertou 100% dos resultados de regime permanente a partir de dados do transitório. Foram 7 ensaios de avaliação e 21 ensaios de treinamento, com a faixa de valores de consumo dividida em 4 classes. O tempo médio de ensaio para a determinação desse parâmetro foi de 840 s, com uma economia de 3 h e 46 min em relação ao tempo médio de ensaio atual (histórico da Embraco para ensaios de desempenho com calorímetro de fluido secundário).

As variáveis selecionadas para comporem as entradas da rede para a análise do consumo conseguiram fornecer informações suficientes para a inferência desse parâmetro. Dentre essas variáveis destacaram-se as de análise da corrente do compressor (harmônicas, valor eficaz etc.).

Para capacidade de refrigeração, o SNE reduziu o tempo (com classificação correta) de 6 dos 7 ensaios de avaliação (85,7%) e 21 ensaios de treinamento (100%). Em um dos ensaios de avaliação o SNE não conseguiu inferir o resultado durante o transitório, o que resultou em um tempo normal de ensaio (4 h), porém com resultado correto. A causa deste acontecimento, como explicado no item 6.2.3, é a proximidade do valor de capacidade de refrigeração deste ensaio do limite de separação de duas classes, o que resultou em uma indecisão do SNE (não estabilização da resposta).

O tempo médio de ensaio para obtenção da capacidade de refrigeração utilizando o SNE foi de 2300 s, aproximadamente um sexto do tempo médio de ensaio com o procedimento atual que é de 14400 s (3 h e 20 min de redução de tempo). Dentre as variáveis de entrada desta rede destacaram-se em importância o fluxo de massa e a potência dissipada nos resistores de aquecimento do calorímetro.

Em uma análise direta entre a inferência dos dois parâmetros fica claro que para o consumo o tempo médio de ensaio é menor e os resultados de acertos melhores. Tal fato ocorre porque as medições utilizadas para o cálculo da capacidade de refrigeração possuem tempos de estabilização maiores que as variáveis para o cálculo do consumo. Além disto, as variáveis selecionadas para entrada da rede de consumo demonstraram maior sensibilidade a mudanças no parâmetro. As variáveis mais importantes de entrada da rede de capacidade (fluxo mássico e potência dissipada nos resistores) são altamente dependentes da temperatura do corpo e as outras variáveis

possuem uma sensibilidade muito pequena a mudanças de capacidade, atribuindo pouca informação ao processo de inferência.

A melhoria na base de dados de treinamento das RNA, resultado da realização de um número maior de ensaios com uma dispersão de resultados superior, tem grande possibilidade de diminuir os tempos médios de ensaios e aumentar os índices de acertos.

Nesta dissertação não foi realizada a avaliação da incerteza do sistema neural de ensaios por não ser técnica dominada no atual estado-da-arte. Porém isso agregaria confiabilidade aos resultados e é proposto como oportunidade futura.

A diminuição do tempo médio de ensaios representa um grande avanço na aplicação das técnicas de IA em processos industriais e um ganho enorme para a empresa, uma vez que o número de ensaios realizados pode aumentar, melhorando a análise estatística para controle de qualidade e diminuindo o tempo de identificação de melhorias em atividades de pesquisa e desenvolvimento.

7.5 OPORTUNIDADES FUTURAS

Como em todos os trabalhos científicos, ainda existem oportunidades para continuar e aprofundar o estudo realizado por esta dissertação. Três frentes de trabalho são propostas: melhorias no treinamento e avaliação do sistema neural de ensaios; avaliação da incerteza associada ao sistema; adequação do método à indústria.

Em relação à primeira frente, a base de dados de ensaios deve ser melhorada (número e dispersão) e o treinamento refeito, estabelecendo a relação entre o aumento da amostra, o tempo médio de ensaio e o índice de acertos. Em função disto, alguns itens do método podem ser reavaliados e substituídos ou modificados. Os parâmetros da rede, tais como número de neurônios, funções de treinamento e variáveis de entrada devem ser refinados. As classes de saída do sistema, que devido às limitações da amostra foram estabelecidas após a realização dos ensaios e ajustadas aos dados obtidos, podem ser redefinidas de acordo com a necessidade da aplicação.

Na segunda frente, uma análise metrológica é estabelecida em busca da definição da incerteza do processo de inferência e classificação dos parâmetros do compressor, assegurando a confiabilidade dos resultados.

Na última frente, adequações de hardware e software seriam realizadas para instalar o sistema neural de ensaios paralelamente ao sistema de ensaio atual. Nessa configuração, todos os ensaios seriam executados até o final e o resultado de regime permanente registrado e comparado ao resultado do SNE. Após um longo período de ensaios, de acordo com os resultados obtidos, o SNE poderia ser validado para aplicação na rotina industrial.

Outra tarefa a ser implementada por necessidade direta da indústria é a elaboração de uma rede para a inferência direta do coeficiente de desempenho (COP). A explicação para isso deve-se ao fato de que em alguns casos não é necessário o conhecimento da capacidade de refrigeração ou do consumo de potência ativa separadamente, e sim a relação entre eles. O tempo de ensaio na utilização de uma rede pode ser menor que o resultante do cálculo a partir das duas redes (como proposto no trabalho).

Como última opção para diminuir o tempo de ensaio, propõe-se a integração do sistema neural de ensaios com um método de diminuição do transitório (aceleração da estabilização).

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Curso de aplicação de compressores. Material de treinamento da EMBRACO. Joinville, 1987.
- [2] STOECKER, W.F.; SAIZ JABARDO J.M. *Refrigeração Industrial*. 2ª ed. Edgard Blücher Ltda, São Paulo, 2002. 371p.
- [3] SERRANO, J. R. *Numerical simulation and experimental validation of hermetic reciprocating compressors. Integration in vapour compression refrigerant system*. Tese de doutorado. Centro tecnológico de transferência de calor, máquinas e motores térmicos. Universidade Politécnica da Catalunha, 2002.
- [4] ISO 917: *Testing of refrigerant compressors*. 2 ed. Genève (Switzerland), 1989. 31 p.
- [5] MARRIOT, L. W. *Control of a refrigerant compressor calorimeter for a minimum testing time*. Tese de doutorado. Universidade de Michigan, 1973.
- [6] ISO – INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. *Accuracy (trueness and precision) of measurement methods and results – Part 2: Basic method for the determination of repeatability and reproducibility of a standard measurement method*. ISO 5725-2. Genève (Switzerland), 1994b. 41p.
- [7] NAMAS – NATIONAL ACCREDITATION OF MEASUREMENT AND SAMPLING. *The expression of uncertainty and confidence in measurement for calibrations*. NIS 3003. National Physical Laboratory, England: NAMAS, 1995.
- [8] HECKMANN, J. R. *Identificação de potenciais aplicações da inteligência artificial na metrologia*. Florianópolis, 1999. 142p. Dissertação (Mestrado em Metrologia Científica e Industrial) – Orientador: Carlos Alberto Flesch. Curso de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.
- [9] Compressores Herméticos. Material de treinamento da EMBRACO. Joinville, 1988.

- [10] Compressores Herméticos – aspectos gerais. Material de treinamento da EMBRACO. Joinville, 1990.
- [11] KOERICH, G. B. *Medição de perdas termodinâmicas em compressores herméticos para refrigeração*. Monografia de projeto de fim de curso. Departamento de Engenharia de Controle e Automação. Universidade Federal de Santa Catarina. Florianópolis, 2004.
- [12] HANSEN, L. D.; HART, R. M. *The art of calorimetry*. Departamento de Química e Bioquímica. Universidade Brigham Young. EUA, 2003.
- [13] INMETRO – INSTITUTO NACIONAL DE METROLOGIA, NORMALIZAÇÃO E QUALIDADE INDUSTRIAL. *Vocabulário internacional de termos fundamentais e gerais de metrologia – Versão Brasileira do "Vocabulary of basic and general terms in metrology"* publicado em 1993 pela ISO/IEC/OIML/BIPM. Rio de Janeiro: INMETRO, mar. 1995.
- [14] KIM, T.; LI, C. J. *Feedforward neural networks for fault diagnosis and severity assessment of a screw compressor*. Mechanical systems and signal processing symposium, vol. 9, 1995, pp 485-496.
- [15] ALIPPI C. et al. New trends in intelligent system design for embedded and measurement applications. IEEE Instrumentation and Measurement Magazine, v.2, n.6, p.36-44, June 1999.
- [16] BARRETO, J. M. *Inteligência Artificial: no limiar do século XXI*. 2 ed. Florianópolis, 1997.
- [17] ALIPPI, C.; FERERO A.; PIURI, V. *Artificial intelligence for instruments and measurement applications*. IEEE Instrumentation and Measurement Magazine, v.1, n.6, p.9-17, June 1998.
- [18] HECKMANN, J. R.; FLESCHE, C. A. Minimização de incertezas em circuitos de linearização de transdutores através de algoritmos genéticos. In: III SEMETRO – Seminário Internacional de Metrologia Elétrica. Anais em CDROM. Rio de Janeiro, 15 a 17 set. 1998.

- [19] FAUSETT, L. V. *Fundamentals of neural networks architectures, algorithms, and applications*. Prentice Hall International. New Jersey, 1994.
- [20] BUTLER, K. L.; MOMOH, J. A.; SOBAJIC, D. J. *Field studies using a neural-net-based approach for fault diagnosis in distribution networks*. IEEE Transactions, Vol. 144, No. 5 (Sept.), 1997, p. 429-436.
- [21] LEFÉVRE, M. A. P. *Sistemas inteligentes e sua aplicação na operação de Itaipu Binacional*. Eletroevolução, No. 7 (Out.), 1996, p. 54-58.
- [22] De AZEVEDO, F. M. *Uma proposta de modelos formais de neurônios e redes neurais artificiais*. Anais do III Congresso Brasileiro de Redes Neurais, Florianópolis, 1997, p: 503-514.
- [23] KOVACS, Z. L. *Redes neurais artificiais, fundamentos e aplicações*. Ed. Acadêmica, São Paulo, 1996.
- [24] SPECHT, D. A. *A general regression neural network*. IEEE Transactions on Neural Networks, Vol. 2, No. 6 (Nov.), 1991, p. 568-576.
- [25] CARDOSO JR, G. *Estimação da seção em falta em sistemas elétricos de potência via redes neurais e sistemas especialistas realizada em nível de centro de controle*. Tese de doutorado. Programa de pós-graduação em Engenharia Elétrica. Universidade Federal de Santa Catarina. Florianópolis, 2003.
- [26] Tafner, M. A.; Xerez, M.; Rodrigues Filho, I. W. *Redes neurais artificiais: introdução e princípios de neurocomputação*. Ed. da FURB, 1996.
- [27] RANAWEERA, D. K. *Comparison of neural network models for fault diagnosis of power systems*. Electric Power Systems Research 29, 1994, p. 99-104.
- [28] MENDEL, J. M.; MOUZOURIS, G. C. *Designing fuzzy logic systems*. IEEE Transactions on Circuits and Systems – II: Analog and Digital Signal Processing, v.44, n.11, p.885-894, Nov. 1997.
- [29] DRAGOMIR-DAESCU, D.; AL-KHALIDY, A. A.; OSAMA, M.; KLIMAN, G. B. *Damage detection in refrigerator compressors using vibration and current*

diagnosis. SDEMPED – Symposium on diagnostics for electric machines, power electronics and drives. Atlanta, GA, USA, 24-26 August 2003.

- [30] FLESCHE, C. A.; CAMARANO, D. M. *Proposta de metodologia de seleção dos módulos físicos e lógicos de um processo de medição automatizado de temperatura com transdutores dos tipos termopar, termorresistor e termistor*. In: XII Congresso Brasileiro de Engenharia Mecânica. Anais. v.3., p.269-274. Brasília, dez. 1993a.
- [31] ANDERSON, K. F. *Current loop signal conditioning: practical applications*. NASA – NATIONAL AERONAUTICS AND SPACE ADMINISTRATION, *Technical Memorandum*. NASA-TM-4636. Edwards, California, 1995.
- [32] ANDERSON, K. F. *NASA's Anderson loop*. IEEE Instrumentation and Measurement Magazine, v.1, n.3, p.5-15, Mar. 1998.
- [33] ANDERSON, K. F. *A successor to the Wheatstone bridge: NASA's Anderson loop*. CAL LAB – The International Journal of Metrology, v.5, n.5, p.23-32, Sept./Oct. 1998.
- [34] ANDERSON, K. F. *The new current loop: an instrumentation and measurement circuit topology*. IEEE Transactions on Instrumentation and Measurement, v.46, n.5, p.1061-1067, Oct. 1997.
- [35] ONNEY, C. D.; COLLURA, J. V. *A limited in-flight evaluation of the constant current loop strain measurement method*. NASA – NATIONAL AERONAUTICS AND SPACE ADMINISTRATION, *Technical Memorandum*. NASA-TM-104331. Edwards, California, Aug. 1997. 32p.
- [36] HILL, G. M. *High accuracy temperature measurements using RTD with current loop conditioning*. NASA – NATIONAL AERONAUTICS AND SPACE ADMINISTRATION, *Technical Memorandum*. NASA-TM-107416. Cleveland, Ohio, 1996.
- [37] BARP, A.; FLESCHE, C. A. *Avaliação da incerteza de medição durante o projeto de cadeias de medição*. In: III SEMETRO – Seminário Internacional de Metrologia Elétrica. Anais em CD-ROM. Rio de Janeiro, 15 a 17 set. 1998.

- [38] BLANK, M.; FLESCH, C. A. *Análise comparativa entre erros metrológicos decorrentes da multiplexação automatizada obtidos em análise teórica e experimental*. In: XV Congresso Brasileiro de Engenharia Mecânica. Anais em CDROM. Bauru, dez. 1997b.
- [39] FLESCH C. A.; BARP A. M. Avaliação a priori da incerteza em sistemas modulares de medição de temperatura. In: IV Congreso Iberoamericano de Ingeniería Mecánica CIDIM/99. Anais em CDROM. Santiago de Chile, 23 a 26 nov. 1999b.
- [40] SANGOI, R. *Estudo da identificação de fontes de ruído e vibrações em um compressor hermético*. Dissertação de mestrado. Departamento de Engenharia Mecânica. Universidade Federal de Santa Catarina. Florianópolis, 1983.
- [41] DENCKER, F. A. *Detecção de falha na montagem de compressores herméticos por redes neurais artificiais*. Dissertação de mestrado. Departamento de Engenharia Mecânica. Universidade Federal de Santa Catarina. Florianópolis, 2002.
- [42] TSE, P.; WANG, D. D. *A hybrid neural network based machine condition forecaster and classifier by using multiple vibration parameters*. IEEE Transactions on Neural Networks, Vol. 10, no 1, 2000.
- [43] GUSTAFSON, S. C.; LITTLE, G. R.; RATTRAY, F. *Correlation of transient and steady state compressor performance using neural networks*. AutoTest Con'92 Advanced Technologies Session, Daytona - Ohio, 1992.
- [44] LI, C. J.; YU, X. *High pressure air compressor valve fault diagnosis using feedforward neural networks*. Mechanical systems and signal processing symposium, vol. 9, 1995, pp 527-536.
- [45] YANG, B.; HWANG, W.; KIM, D.; TAN, A. C. *Condition classification of small reciprocating compressor for refrigerators using artificial neural networks and support vector machines*. Mechanical systems and signal processing symposium, vol. 19, 2005, pp 371-390.
- [46] HABTOM, R. *Modeling a compression plant using recurrent neural networks*. Institute of Process Automation, Universidade de Kaiserslautern. Kaiserslautern,

Germany. Disponível em: <habtomoe-technik.uni-kl.de>. Acesso em: maio de 2005.

- [47] KOSTYLA, P.; LOBOS, T.; WACLAWEK, Z. Neural networks for real time estimation of signal parameters. *IEEE Transactions on Power Systems*, vol. 11, no. 2, 1996, pp 380-385.
- [48] POLETTTO, E. L. *Aprimoramento de uma bancada de ensaios de desempenho de compressores herméticos visando reduzir incertezas de medição*. Dissertação (Mestrado em Metrologia Científica e Industrial) – Orientador: Carlos Alberto Flesch. Curso de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina. Florianópolis, 2006
- [49] SINGLAS – SINGAPORE INSTITUTE OF STANDARDS AND INDUSTRIAL RESEARCH. Guidelines on the evaluation and expression of the measurement uncertainty – Technical Guide 1, Singapore Laboratory Accreditation Scheme, Singapore, 1995.
- [50] TAYLOR, B. N.; KUYATT, C. E. Guías para la evaluación y expresión de la incertidumbre de los resultados de las mediciones de NIST. Spanish Translation of NIST Technical Note 1297. National Institute of Standards and Technology, Gaithesburg, 1994.
- [51] AKHMETOV, D. F.; DOTE, Y.; OVASKA, S. J. *Fuzzy neural network with general parameter adaptation for modeling of nonlinear time-Series* *IEEE Transactions on Neural Networks*, Vol. 12, no 1, 2001.
- [52] ZHANG, D.; PAL, S. K. *A fuzzy clustering neural networks system design methodology*. *IEEE Transactions on neural networks*, vol. 11, no. 5, September 2000 pp 1174-1177.
- [53] HENNING, H.; GERLACH, T.; TRYBA, V. *A backpropagation algorithm for fuzzy systems*. In: World Automation Congress – Soft Computing with Industrial Applications. Proceedings, v.5, p.301-306, Montpellier (France), May 28-30, 1996.

- [54] GEDEON, T. D. Fuzzy-neural interpolation for numeric data. In: World Automation Congress – Soft Computing with Industrial Applications. Proceedings, v.5, p.237-242, Montpellier (France), May, 28-30, 1996.
- [55] MATLAB user manual - Neural network toolkit. MATLAB, versão 7.0.
- [56] FLESCHE, C. A.; SCAVONE, R. *Aplicación de sistemas expertos para determinar intervalos de calibración de instrumentos de medición en bancos de ensayo*. Revista Información Tecnológica, ISSN 0716-8756. v. 9, n.2, p.169-176, 1998.
- [57] FLESCHE, C. A.; SOARES JR, L. *A methodology for unification in the treatment of metrological aspects in the quality assuring systems*. In: Congresso Brasileiro de Engenharia Mecânica (COBEM 99). Anais em CD-ROM. Águas de Lindóia: 22 a 26 nov. 1999a.
- [58] SOARES JR. L.; FLESCHE C. A. *Aplicação do ISO-GUM em sistemas da qualidade ISO 9000*. In: IV Congreso Iberoamericano de Ingeniería Mecánica CIDIM/99. Anais em CDROM. Santiago de Chile, 23 a 26 nov. 1999b.
- [59] OPPENHEIM, A. V.; WILLSKY, A. S. Signal & systems. 2. ed. UPPER saddle River, New Jersey: Prentice Hall, 1997.
- [60] CHEN, W. K. *The circuit and filters handbook*. New York: CRC Press, 1995.
- [61] FLESCHE, C. A. *Metrologia. Apostila da disciplina Metrologia e Eletrônica para Experimentação do Programa de Pós-graduação em Engenharia Mecânica da UFSC*. Florianópolis: Laboratório de Metrologia e Automatização da UFSC, 2002.