

**Análise e Implantação de Ferramentas  
de Inteligência Artificial para Inferência  
e Prognóstico em Ensaios de  
Desempenho de Compressores  
Herméticos**

*Relatório submetido à Universidade Federal de Santa Catarina  
como requisito para a aprovação na disciplina  
DAS 5511: Projeto de Fim de Curso*

**Bernardo Barancelli Schwedersky**

Florianópolis, agosto de 2015



**Análise e Implantação de Ferramentas  
de Inteligência Artificial para Inferência  
e Prognóstico em Ensaios de  
Desempenho de Compressores  
Herméticos**

**Bernardo Barancelli Schwedersky**

Esta monografia foi julgada no contexto da disciplina  
**DAS5511: Projeto de Fim de Curso**  
e aprovado na sua forma final pelo  
**Curso de Engenharia de Controle e Automação**

**Prof. *Rodolfo César Costa Flesch, Dr. Eng.***

---

Assinatura do orientador

Banca Examinadora:

Cesar Alberto Penz, Dr. Eng.  
*Orientador na Empresa*

Prof. Rodolfo César Costa Flesch, Dr. Eng.  
*Orientador no Curso*

*Avaliador*

*Debatedores*

## *Agradecimentos*

*Agradeço primeiramente aos meus pais Werner e Rosa pelo constante apoio e compreensão durante toda minha formação, aos meus irmãos Mateus e Maurício pelo companheirismo e ajuda e à minha namorada Patricia pela compreensão, apoio e carinho.*

*Ao professor Rodolfo César Costa Flesch pela orientação e ajuda.*

*Ao Cesar Alberto Penz pela supervisão e auxílio na execução desse trabalho.*

*À toda equipe do Labmetro / LIAE pelo suporte e companheirismo, em especial ao Bernardo e Emanuel.*

*À Embraco pela oportunidade e pelo fomento.*

*Aos meus amigos Gabriel, Guilherme, Luiz Henrique e Léo por me acompanharem durante toda a graduação, auxiliando na formação acadêmica e principalmente na formação pessoal.*

Universidade Federal de Santa Catarina

## *Resumo*

Centro Tecnológico

Departamento de Automação e Sistemas

**Análise e Implantação de Ferramentas de Inteligência Artificial para  
Inferência e Prognóstico em Ensaios de Desempenho de Compressores  
Herméticos**

por BERNARDO BARANCELLI SCHWEDERSKY

Inteligência Artificial (IA) tem sido usada na mais variada gama de aplicações. Uma aplicação proeminente é a inferência de valores de regime permanente usando valores de regime transitório em ensaios de desempenho energético de compressores de refrigeração. Esses ensaios são usados para medir variáveis de desempenho como a capacidade de refrigeração, potência consumida e coeficiente de desempenho, os quais são usados para pesquisa e desenvolvimento, controle de qualidade e geração de dados de catálogo. Pesquisas recentes mostraram que abordagens usando comitês de redes neurais para a inferência de regime permanente e posterior prognóstico de capacidade de refrigeração são apropriadas para a resolução do problema, sendo possível uma redução no tempo médio de ensaio por compressor, que de quatro a cinco horas passa para cerca de uma hora. Este projeto mostra a implementação de um conjunto de ferramentas para a melhoria da qualidade das inferências de regime permanente e prognóstico de capacidade de refrigeração para utilização em software supervisor de uma bancada de ensaios de desempenho. As contribuições deste trabalho foram: implementação do suporte a um banco de dados contendo valores típicos das variáveis de desempenho; desenvolvimento de comitês de redes neurais para a tarefa de inferência e prognóstico; proposição de uma metodologia para avaliação da dinâmica da resposta do comitê de redes neurais para inferência; proposição de metodologia para a atualização online de ferramentas de IA para inferência.

Federal University of Santa Catarina

## *Abstract*

Technological Center

Department of Automation and Systems

### **Analysis and Implementation of Artificial Intelligence Tools for Prediction and Prognosis in Performance Tests of Refrigeration Compressors**

by BERNARDO BARANCELLI SCHWEDERSKY

Artificial Intelligence (AI) has been used in a wide range of applications., one of the most promising is the steady-state value prediction of refrigeration compressor performance tests using unsteady-state data analysis. These tests are used for measuring performance characteristics like the refrigerant capacity, the power consumption and the performance coefficient, which are mainly used for research and development (R&D), determination of catalog parameters, and quality control. Recent research shows that neural networks committee machines are suitable for steady-state prediction and refrigerant capacity prognosis, being able to reduce average test duration of five hours to about one hour. This project presents the improvement of a set of tools for steady-state prediction and refrigerant capacity prognosis, used in supervisory software of a test rig. The main contributions of this work are: implementation of a typical performance characteristics database and a neural network committee machine for prediction and prognosis of refrigerant capacity; proposal of a method for rating the committee's dynamic response; proposal of a method for online update of AI tools.





# Sumário

<b>Lista de Figuras</b>	<b>xi</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Objetivos . . . . .	4
1.1.1 Objetivo Geral . . . . .	4
1.1.2 Objetivos Específicos . . . . .	4
1.2 Relação do Projeto com a Engenharia de Controle e Automação . . . . .	4
1.3 Estrutura do Documento . . . . .	5
<b>2 Ensaios de Desempenho de Compressores Herméticos de Refrigeração</b>	<b>7</b>
2.1 Compressores Herméticos para Refrigeração e Circuito de Refrigeração . . . . .	7
2.2 Ensaios de Desempenho Energético para Compressores Herméticos . . . . .	9
2.3 Características de Desempenho . . . . .	10
2.4 Bancada de Ensaio de Desempenho . . . . .	11
<b>3 Redes Neurais Artificiais</b>	<b>15</b>
3.1 Inteligência Artificial e Aprendizado de Máquina . . . . .	15
3.2 Redes Neurais Artificiais . . . . .	17
3.2.1 Modelo Geral do Neurônio . . . . .	18
3.2.2 Arquitetura das Redes Neurais . . . . .	19
3.2.3 Aprendizado em Redes Neurais . . . . .	20
3.2.4 Retreinamento . . . . .	22
3.2.5 Comitê de Redes Neurais . . . . .	23
<b>4 Implementação de Ferramentas para Geração de Inferências e Prognósticos</b>	<b>25</b>
4.1 Sistema de Inferência e Prognóstico de Capacidade de Refrigeração . . . . .	26
4.2 Caracterização do Sistema Original . . . . .	27
4.2.1 Rede Neural para Inferência de Regime Permanente . . . . .	30
4.2.2 Rede Neural para Prognóstico da Capacidade de Refrigeração . . . . .	31
4.2.3 Análise de Resultados . . . . .	32
4.3 Implementação de Ferramentas Para Incremento da Confiabilidade . . . . .	33
4.3.1 Implementação da Consulta por Valores Típicos . . . . .	34
4.3.2 Implementação dos Comitês de Redes Neurais . . . . .	36
4.3.3 Análise do Comportamento do Comitê de Redes . . . . .	39
4.4 Resultados . . . . .	43
<b>5 Análise de Métodos para Atualização das Ferramentas</b>	<b>45</b>

---

5.1	Propostas de Método para Atualização de Redes Neurais . . . . .	46
5.2	Estratégia de Retreinamento . . . . .	49
5.3	Resultados . . . . .	53
<b>6</b>	<b>Considerações Finais</b>	<b>57</b>

# Lista de Figuras

1.1	Resultados obtidos na redução de tempo de ensaio. Fonte [1]	2
2.1	Circuito de refrigeração	8
2.2	Compressor alternativo hermético. Adaptado de [2].	9
2.3	Diagrama esquemático da bancada de ensaio disponível. Adaptado de [1]	12
3.1	Problemas do aprendizado supervisionado. Fonte: Adaptada de [3]	16
3.2	Modelo geral do neurônio. Fonte [4]	18
3.3	Funções de ativação comuns. Adaptado de [5]	19
3.4	Exemplos de topologias de redes neurais	20
4.1	Sistema neural original. Adaptado de [6]	27
4.2	Exemplo do comportamento da rede de inferência de regime.	28
4.3	Diagrama de blocos do módulo neural capacidade.	29
4.4	Entradas da rede de inferência de regime da capacidade.	31
4.5	Entradas da rede para prognóstico da capacidade.	32
4.6	Erro percentual.	33
4.7	Diagrama de blocos do sistema com consulta a valores típicos.	35
4.8	Erro percentual.	36
4.9	Diagrama de blocos do comitê de redes neurais para inferência de regime.	38
4.10	Erro percentual.	39
4.11	Comportamento do comitê de redes neurais.	40
4.12	Análise do comportamento do comitê de redes neurais.	41
4.13	Resposta da ferramenta de monitoramento do comitê.	42
4.14	Erro percentual.	42
4.15	Erro percentual de prognóstico para o sistema original e o sistema com as ferramentas propostas.	43
5.1	Diagrama de blocos para o sistema de retreinamento.	48
5.2	Algoritmo de treinamento das redes neurais.	50
5.3	Experimentos para avaliação do retreinamento de redes neurais.	52
5.4	Histograma do erro percentual para a avaliação do retreinamento de redes neurais.	54



# Capítulo 1

## Introdução

O processo de internacionalização da produção provoca transformações nos planos tecnológico, organizacional e financeiro, intensificando a concorrência em escala global. A disputa por posições de destaque mundial acarreta a incessante busca por melhora na qualidade, aumento da produtividade e redução de custos. Nesse cenário, a garantia da qualidade do produto, aliada ao seu aprimoramento tecnológico, passa a ser fundamental no enfrentamento dos desafios impostos pelo mercado [7].

O controle da qualidade do processo produtivo faz uso de grandezas, as quais são, tipicamente, obtidas através de métodos normatizados. São buscados ensaios com medições confiáveis, para garantir que o produto fabricado tenha as características de projeto que são esperadas pelo cliente. O aprimoramento tecnológico do produto, tarefa principal dos setores de pesquisa e desenvolvimento, é obtido, em muitos casos, através de evoluções incrementais e de pouco impacto nas características de desempenho do sistema. Devido a isso, os ensaios para verificação desses aprimoramentos necessitam apresentar incerteza de medição compatível [1].

Nesse contexto, a avaliação do desempenho de compressores herméticos, utilizados em sistemas de refrigeração, apresenta importância fundamental nas empresas fabricantes desses produtos. É esse processo que fornece os resultados acerca das variáveis de interesse, tanto para os setores de pesquisa e desenvolvimento, quanto para os responsáveis pelo controle de qualidade do produto [6].

Ensaio de avaliação de desempenho energético de compressores de refrigeração apresentam, usualmente, duração média de 4 h. Esse longo período de execução é

provocado principalmente pelo longo regime transitório, o qual dura aproximadamente 3 horas, tempo esse causado, entre outros fatores, pela alta inércia térmica das bancadas de ensaio e do compressor. A 1 h restante corresponde ao tempo definido pela norma ISO 917 [8] para realização das medições com o sistema em condição de regime permanente [2].

Em busca da redução do tempo necessário para a execução e melhora nas características de incerteza de medição desses ensaios, a Whirlpool S.A. - Unidade Embraco, maior fabricante mundial de compressores de refrigeração, estabeleceu parceria com o Labmetro - Laboratório de Metrologia e Automatização da Universidade Federal de Santa Catarina.

Na figura 1.1 é mostrada a redução de tempo médio de ensaio, obtida pelos trabalhos desenvolvidos no Labmetro desde o início da parceria [9–14]. A redução média de tempo de ensaio é de aproximadamente 50%. Essa melhora decorreu de aperfeiçoamentos da bancada de ensaio, realização de processos de medição no estado-da-arte e da utilização de técnicas modernas de controle.




FIGURA 1.1: Resultados obtidos na redução de tempo de ensaio. Fonte [1]

Outra abordagem, visando a redução do tempo de ensaio, fundamenta-se na utilização de técnicas para estabelecer prognósticos e inferências de valores ou estado das características de interesse dos compressores herméticos [1]. Busca-se, através da análise do comportamento das grandezas nos ensaios durante o período transitório, estimar um valor ou o estado das variáveis sob ensaio do compressor. Nessa abordagem, técnicas de inteligência artificial se mostram promissoras.

A utilização de redes neurais na solução desse problema foi apresentada no trabalho de Henklein [2], que demonstrou o potencial dessa técnica, aliada à lógica *fuzzy*, na tarefa do prognóstico do desempenho energético dos compressores. O trabalho de

Steinbach [15] aplicou redes neurais para avaliar a entrada em regime permanente e realizar o prognóstico dos valores das três principais variáveis medidas em um ensaio de desempenho energético de compressores de refrigeração: capacidade de refrigeração, potência elétrica ativa consumida e coeficiente de desempenho. No trabalho de Lima [6] foi desenvolvida e implantada em bancadas de avaliação de desempenho de compressores a primeira versão de um conjunto de ferramentas de inferência e prognóstico para capacidade de refrigeração, potência elétrica ativa consumida e coeficiente de desempenho.

A utilização de redes *fuzzy*-bayesianas para análise do grau de assentamento do ensaio a partir do instante de entrada em regime permanente da capacidade de refrigeração foi avaliada por Casella [16]. Por fim, Penz [1] estudou a utilização de comitês de redes neurais, associadas a uma rede *fuzzy*-bayesiana, para aumento da confiabilidade na tarefa de geração de inferências e prognósticos.

Essa série de trabalhos mostrou a adequação das redes neurais e redes *fuzzy*-bayesianas nas tarefas de geração de inferências e prognósticos, possibilitando novos ganhos significativos de tempo. Esses ganhos podem contribuir com o controle de qualidade, evitando avaliações tardias de amostras de lotes, e possibilitar maior eficiência nas tarefas de pesquisa e desenvolvimento, reduzindo o esforço experimental na validação de ganhos.

Para a efetivação desses ganhos, as ferramentas de inteligência artificial precisam ser implantadas no *software* supervisor da bancada de ensaios. Um *software*, contendo as ferramentas de inteligência artificial desenvolvidas à época, foi desenvolvido por Lima [6] e testado na bancada de ensaios. Esse *software* necessita diversas atualizações, para incorporar as ferramentas disponíveis, e estar preparado para a utilização na rotina da empresa.

Além dessa atualização do *software*, é importante explorar métodos para a melhoria contínua das respostas do sistema, através do monitoramento da mesma e atualização automática das ferramentas.

## 1.1 Objetivos

### 1.1.1 Objetivo Geral

Desenvolver soluções em *software* para implantação de ferramentas de inteligência artificial de inferência e prognóstico de características de desempenho, aplicadas a ensaios de compressores de refrigeração, em bancadas de avaliação de desempenho energético.

### 1.1.2 Objetivos Específicos

- Atualizar o módulo de inteligência artificial aplicado à bancada de ensaios de compressores. Essa atualização possibilitará: integração de soluções já desenvolvidas, incluindo o suporte a comitês de redes neurais e o suporte a banco de dados contendo valores típicos de variáveis de interesse para diversas condições de ensaio.
- Estudar métodos de atualização de redes neurais através de retreinamento e conceber algoritmos para retreinamento e avaliação dos métodos propostos.

## 1.2 Relação do Projeto com a Engenharia de Controle e Automação

A formação de um Engenheiro de Controle e Automação abrange ampla gama de conhecimentos, aprofundados nas áreas de Controle de Processos, Informática Industrial e Automação da Manufatura [17]. O projeto apresentou estreita relação com os conhecimentos das áreas de Controle de Processos e principalmente de Informática Industrial.

Da área de Informática Industrial foram utilizados conceitos avançados em inteligência artificial, tanto na implementação das ferramentas quanto no aprimoramento das mesmas. Conceitos da área de Controle de Processos também foram empregados, com destaque para os relacionados à instrumentação para controle e automação, fundamentais no escopo do projeto, e conceitos de sinais e sistemas lineares, usados no processamento de sinais digitais.



### **1.3 Estrutura do Documento**

No capítulo 2 são apresentados os conceitos básicos acerca de ensaios de desempenho de compressores herméticos e suas particularidades. No capítulo 3 são apresentados conceitos básicos de inteligência artificial e as particularidades da ferramenta rede neural, a mais fortemente utilizada neste trabalho. No capítulo 4 é apresentado o software de geração de inferências e prognósticos, a implementação de ferramentas para a melhoria da qualidade das inferências e prognósticos e os progressos alcançadas através dessa implementação. No capítulo 5 são apresentados os algoritmos para o retreinamento de redes neurais e uma avaliação dos resultados obtidos pelos mesmos. No capítulo 6 são apresentadas as considerações finais deste trabalho e as propostas para sua continuidade.



## Capítulo 2

# Ensaio de Desempenho de Compressores Herméticos de Refrigeração

Neste capítulo são abordados alguns conceitos sobre o ciclo de refrigeração e acerca dos compressores herméticos tratados no trabalho. São discutidos os ensaios de desempenho energético, em especial as características de desempenho dos compressores herméticos, os procedimentos para o ensaio de desempenho energético e é descrita a bancada de ensaios.

### 2.1 Compressores Herméticos para Refrigeração e Circuito de Refrigeração

A refrigeração é definida como o processo de extrair calor de uma fonte de calor, substância ou meio a baixa temperatura e transferi-lo a um ambiente de temperatura superior, operando de maneira contrária ao comportamento natural da transferência de calor. Por esse motivo é necessária uma fonte externa de energia, que tipicamente é a rede elétrica [6, 18].

Um circuito de refrigeração tem por objetivo a transferência de calor de um ambiente de controle para outro, ocasionando uma diferença de temperatura entre os dois

ambientes. Para essa tarefa, é necessário um arranjo de equipamentos, chamado de circuito de refrigeração [19].

O circuito é composto por cinco elementos: compressor, condensador, dispositivo de expansão, evaporador e a tubulação, mostrados na figura 2.1. O compressor tem participação na compressão e na movimentação da massa de refrigerante através do circuito, sendo o próprio refrigerante o meio de transporte de energia entre os trocadores de calor [12].

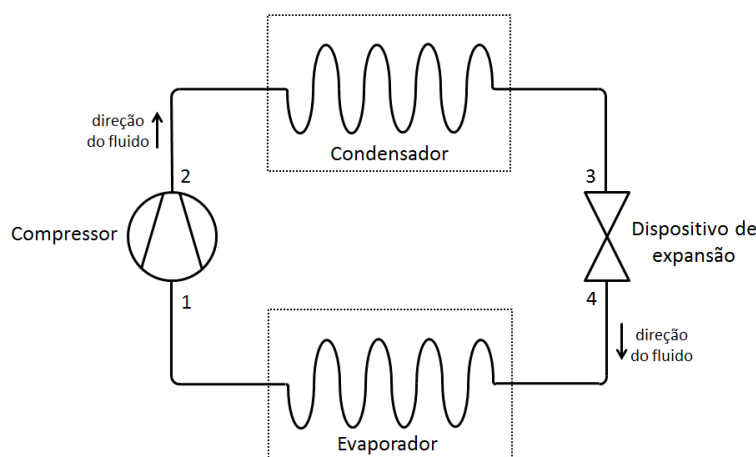


FIGURA 2.1: Circuito de refrigeração

Para o circuito da figura, o fluido é impelido no sentido 1-2-3-4-1. Ele, na forma de vapor superaquecido, no ponto 1, é succionado pelo compressor e descarregado em condição de alta temperatura e pressão, ainda na forma de vapor superaquecido, no ponto 2. O fluido então, atravessa o condensador, onde perde calor, passando do estado de vapor superaquecido para líquido saturado ou sub-resfriado, no ponto 3. A seguir, o fluido passa pelo dispositivo de expansão, no qual a pressão é diminuída, fazendo com que no ponto 4 o fluido esteja na condição de líquido saturado. Com isso, qualquer acréscimo de energia provoca evaporação, sendo essa energia, na forma de calor, retirada do ambiente no qual encontra-se o evaporador. Ao passar pelo evaporador, o fluido já terá voltado para a condição de vapor superaquecido, voltando para o ponto 1, onde será succionado novamente pelo compressor [12].

Os compressores herméticos disponíveis para pequenas capacidades e, geralmente, usados em sistemas de pequeno porte (refrigeradores domésticos, *freezers* e condicionadores de ar) possuem o motor e demais partes constituintes hermeticamente seladas

numa carcaça soldada. O refrigerante e óleo de lubrificação ocupam o mesmo invólucro [6].

Neste trabalho, os compressores são herméticos de estágio simples, com apenas um pistão e um cilindro, do tipo deslocamento positivo. Na figura 2.2 tem-se uma imagem em corte deste modelo de compressor.




FIGURA 2.2: Compressor alternativo hermético. Adaptado de [2].

## 2.2 Ensaio de Desempenho Energético para Compressores Herméticos

Diversos tipos de ensaios podem ser utilizados para a determinação das características de compressores herméticos. Este trabalho aborda os métodos de testes descritos na norma “ISO 917 - *Testing of refrigerant compressors*” [8]. Segundo [2, p. 26], “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”.

Ensaio de desempenho energético de compressores objetivam determinar valores para variáveis de interesse sob certas condições predeterminadas. Dentre essas variáveis destacam-se a capacidade de refrigeração, a potência elétrica ativa consumida e o coeficiente de desempenho. A determinação desses valores através de ensaios ocorre por diversas razões, merecendo destaque: [2]:

- permite a correta aplicação do compressor no sistema de refrigeração;

- possibilita a identificação e quantificação de melhorias construtivas no compressor;
- contribui no fornecimento de dados para projeto de elementos de um sistema de refrigeração;
- auxilia o controle de qualidade durante o processo de fabricação;
- viabiliza a comparação entre dados de fabricantes.

## 2.3 Características de Desempenho

Capacidade de refrigeração de um compressor, expressa em watt, é o produto entre três termos: a vazão mássica de refrigerante através do compressor; a razão entre os volumes específicos do refrigerante entrando no compressor, durante o ensaio e o estabelecido anteriormente ao ensaio; e a diferença entre as entalpias específicas do refrigerante entrando no compressor nas condições básicas específicas do ensaio e do refrigerante líquido saturado na temperatura correspondente à pressão de descarga na saída do compressor. Uma representação matemática da capacidade de refrigeração é apresentada na equação (2.1), porém ela pode ser interpretada como a capacidade de um compressor refrigerar um ambiente quando aplicado a um circuito de refrigeração ideal [20].

$$\phi_0 = q_{mf} \frac{V_{ga}}{V_{gl}} (h_{g1} - h_{f1}) \quad (2.1)$$

Onde:

$\phi_0$	capacidade de refrigeração do compressor	[W]
$q_{m,f}$	vazão mássica de refrigerante	[kg/s]
$V_{ga}$	volume específico do fluido refrigerante (gás) entrando no compressor, durante o ensaio	[m <sup>3</sup> /kg]
$V_{gl}$	volume específico do fluido refrigerante (gás) entrando no compressor, estabelecido anteriormente ao ensaio	[m <sup>3</sup> /kg]
$h_{g1}$	entalpia específica do fluido refrigerante (gás) entrando no compressor nas condições básicas específicas de ensaio	[kJ/kg]
$h_{f1}$	entalpia específica do fluido refrigerante líquido na pressão correspondente à descarga do compressor nas condições básicas específicas para o ensaio	[kJ/kg]

Potência elétrica ativa consumida, grandeza expressa em watt, é a potência nos terminais do compressor, composta pela potência consumida pelo motor e pelos elementos auxiliares necessários para manter o compressor em operação [8]. Coeficiente de desempenho é calculado pela razão entre a capacidade de refrigeração e a potência ativa consumida pelo compressor, sendo assim adimensional [8].

## 2.4 Bancada de Ensaio de Desempenho

Os ensaios de desempenho devem ser executados em bancadas capazes de reproduzir diferentes condições de operação e realizar diversas medições, existindo, portanto, duas tarefas principais envolvidas: as operações de controle e as operações de medição. Quanto às tarefas de controle, busca-se aplicar uma condição padronizada de ensaio, sendo assim necessário que a malha de controle seja eficiente, com o intuito de levar as variáveis controladas dentro dos limites estabelecidos pela norma. Na figura 2.3 é apresentado o diagrama simplificado da bancada de ensaios disponível [2].

Os procedimentos para o teste são gerais para todas as condições de operação. Uma condição de operação específica as pressões absolutas de sucção e descarga, bem como a temperatura na sucção e a frequência rotacional [6]. Para a execução de um

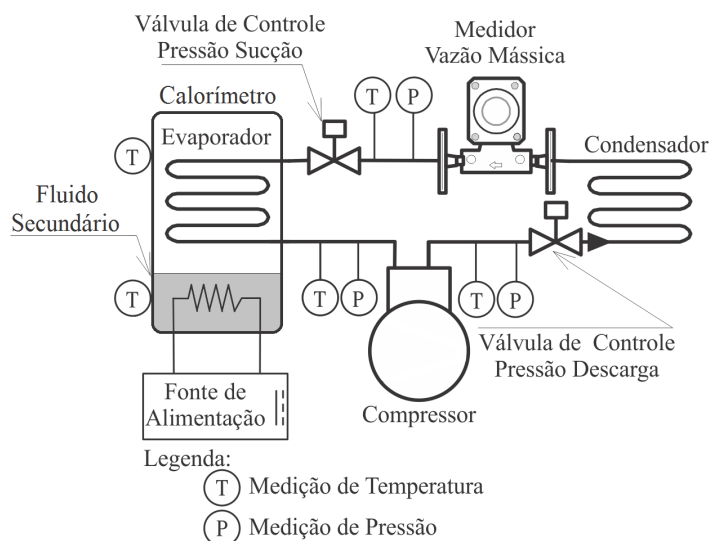


FIGURA 2.3: Diagrama esquemático da bancada de ensaio disponível. Adaptado de [1]

ensaio em algum determinado modelo de compressor é necessário, então, estabelecer as condições de temperatura de condensação e evaporação padronizadas, as quais irão definir os valores de pressão absoluta de descarga e sucção, respectivamente [1].

Para a medição da capacidade de refrigeração é necessário o conhecimento da entalpia do fluido refrigerante na entrada do compressor e da entalpia específica de líquido saturado na temperatura correspondente à pressão de descarga na saída do compressor. É necessário adicionalmente a medição da vazão mássica que circula pelo compressor, a qual pode ser estimada ou medida diretamente [1]. A norma sugere nove métodos de avaliação de vazão mássica, sendo que devem ser executados simultaneamente dois deles [8]. Os dois métodos usados na bancada são apresentados na sequência [8]:

- Método A - calorímetro com fluido secundário: nesse método a vazão mássica é estimada a partir da medição do calor trocado no interior do calorímetro, mostrado na figura 2.3. A pressão de descarga é controlada por uma válvula situada imediatamente após o compressor e a de controle da pressão de sucção é localizada na entrada do calorímetro, desempenhando o papel de válvula de expansão. Esse calorímetro possui em seu interior uma serpentina, no interior da qual o gás sofre evaporação após deixar a válvula. O calor normalmente é cedido através de um conjunto de resistências elétricas, sendo as fontes que cedem calor posicionadas no fundo, mergulhadas num fluido de homogeneização denominado de fluido



secundário, cuja condição termodinâmica é de saturação. A vazão mássica é calculada então, através do fluxo de calor cedido pela fonte externa, das perdas para o ambiente e das entalpias de entrada e saída do calorímetro e das temperaturas externa e interna ao calorímetro [8].

- Método F - medição direta da vazão mássica na fase líquida: nesse método um medidor de vazão mássica é conectado na linha de líquido entre o reservatório de líquido e a válvula de expansão, mostrados na figura 2.3. Para correta medição, o fluido refrigerante deve estar totalmente sub-resfriado no ponto de medição.

Para ambos os métodos de ensaio, além das medições necessárias para o cálculo da capacidade de refrigeração, outras variáveis são medidas para a completa caracterização do compressor. Dentre essas variáveis de interesse, destacam-se [2]:

- temperatura de descarga do compressor;
- potência elétrica ativa consumida pelo compressor;
- corrente elétrica que alimenta o compressor;
- temperatura da carcaça do compressor;
- frequência rotacional do compressor;
- resistência de enrolamento do motor elétrico do compressor (final do ensaio).

Após a partida do compressor, o ensaio deve ocorrer continuamente, enquanto não for atingido regime permanente, ou seja um período no qual os valores de todas as variáveis encontrem-se dentro de limites estabelecidos e não apresentem tendência a mover-se para fora desses limites de forma definitiva. Enquanto essas condições não se confirmarem, diz-se que o sistema encontra-se no transitório [8].

Os limites de variação impostos pela norma, numa determinada condição de ensaio são [8]:

- 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 do que  $\pm 3$  K em relação ao valor de referência;

- a frequência rotacional não pode ter variação maior que  $\pm 1\%$  do valor de referência: limite de variação da tensão de alimentação do compressor é de  $\pm 3\%$  e da frequência  $\pm 1\%$  dos valores nominais da placa;
- no método A, no qual o aquecimento elétrico é utilizado, a potência fornecida aos resistores de aquecimento deve ser mantida constante com variação máxima de  $\pm 1\%$  do valor médio da última hora;
- no método F, o valor lido no medidor de vazão mássica não pode exceder o limite de  $\pm 1\%$  do valor médio da última hora.

Os valores de capacidade de refrigeração, potência ativa consumida pelo compressor e coeficiente de desempenho são calculados tomando como base a média aritmética dos valores medidos consecutivamente na última hora de ensaio operando em regime permanente [8]. Os limites de variação da capacidade de refrigeração, da potência ativa consumida pelo compressor e da temperatura do corpo do compressor não são especificados em norma, porém esses limites são definidos por especialistas em compressores e ensaios de desempenho da seguinte forma [1]:

- capacidade de refrigeração:  $\pm 2\%$  do valor final de ensaio;
- potência elétrica ativa consumida:  $\pm 2\%$  do valor final de ensaio;
- temperatura do corpo:  $\pm 1$  K do valor final de ensaio.

## Capítulo 3

# Redes Neurais Artificiais

Neste capítulo são abordados diversos conceitos fundamentais para a compreensão do trabalho, entre eles os conceitos básicos de inteligência artificial e aprendizado de máquina, com um aprofundamento em redes neurais artificiais, especialmente sobre a problemática do seu treinamento.

### 3.1 Inteligência Artificial e Aprendizado de Máquina

A inteligência artificial (IA) engloba não apenas a tarefa de perceber, compreender, prever e manipular um universo complexo, mas também a construção de entidades inteligentes, que emulem a capacidade do ser humano nessas tarefas. A IA envolve uma variedade grande de aplicações, partindo do geral, como o aprendizado e a percepção, até os específicos, como provar teoremas matemáticos [21], jogar xadrez [22], dirigir um carro [23] ou diagnosticar doenças [24]. Devido a isso, a IA caracteriza-se como um campo universal [25].

Dentre as diversas tarefas em que a IA é aplicada, uma das mais proeminentes é o reconhecimento de padrões, que preocupa-se com a descoberta automática de padrões através do uso de algoritmos de computador, a partir dos quais, podem ser tomadas decisões como a classificação dos dados em categorias diferentes. O subcampo da IA que explora a construção e o estudo dos algoritmos capazes de aprender e fazer previsões através do reconhecimento de padrões em conjuntos de dados é o aprendizado de máquina [26].

Uma abordagem de aprendizado de máquina geralmente utiliza-se de um conjunto de treinamento e um vetor de alvos, os quais são usados para ajustar os parâmetros de um modelo adaptativo. Essa fase é definida como a fase de treinamento, ou também como fase de aprendizado. Subsequentemente, o modelo treinado poderá ser usado para compreender novos exemplos, que irão compor o conjunto de testes. Segundo Bishop [26, p. 2], “a habilidade de categorizar corretamente novos exemplos que difiram daqueles usados no treinamento é conhecida como generalização.” Em aplicações práticas, a variabilidade do vetor de entradas do sistema abrangerá apenas uma fração de todos os possíveis vetores de entrada, fazendo com que a capacidade de generalização torne-se um dos objetivos centrais de qualquer algoritmo de reconhecimento de padrões.

Problemas nos quais o conjunto de dados de treinamento inclui vetores de entrada juntamente com vetores alvo são conhecidos como problemas de aprendizado supervisionado. Esse tipo de aprendizado requer a existência de uma entidade externa, na figura de um supervisor, que identifique em qual classe do vetor alvo cada exemplo do conjunto de treinamento é corretamente classificado [26]. Os problemas de aprendizado supervisionado podem ser divididos em duas classes: a classificação e a regressão.

A classificação é provavelmente o problema mais estudado dentro do aprendizado de máquina. Na sua forma mais simples, se reduz à questão: dado o padrão  $x$  extraído de um domínio  $X$ , qual será o valor estimado para a variável  $y \in \{\pm 1\}$ ? Por exemplo, dado um conjunto de fotos de maçãs e laranjas, identificar se o objeto em questão é uma maçã ou uma laranja. Esse é um problema binário, que pode ser estendido facilmente para a classificação multiclasse, na qual agora  $y \in \{1, \dots, n\}$  pode assumir diferentes valores. Na figura 3.1.(a) apresenta-se um exemplo de classificação em 3 classes. Nesse caso, a habilidade de distinguir estrelas de losangos não é suficiente para para identificar ambas corretamente, já que é necessário saber também diferenciar ambos de triângulos [3].




FIGURA 3.1: Problemas do aprendizado supervisionado. Fonte: Adaptada de [3]

O outro problema básico do aprendizado de máquina é a regressão. Nela, o objetivo é estimar o valor real da variável  $y \in \mathbb{R}$  dado um padrão  $x$ . Um exemplo de regressão pode ser visto na figura 3.1(b), onde dado um número de instâncias, indicadas pelos pontos pretos, busca-se uma representação que seja capaz de mapear as próximas observações de  $x$ , seguindo a tendência apresentada pelas instâncias conhecidas[3].

## 3.2 Redes Neurais Artificiais

A IA apresenta duas grandes linhas de pesquisa: a simbólica e a conexionista. A linha simbólica se baseia na lógica, na qual a manipulação simbólica de um grande número de fatos especializados sobre um domínio restrito é o paradigma para a construção de sistemas inteligentes do tipo simbólico[27]. Acerca da linha conexionista, segundo Bittencourt[27, p. 309], “o conexionismo é uma das duas grandes linhas de pesquisa da IA e tem por objetivo investigar a possibilidade de simulação de comportamentos inteligentes através de modelos baseados na estrutura e funcionamento do cérebro humano”. A linha conexionista surgiu nos primórdios da IA e teve seu renascimento na década de 80 do século XX devido a diversos fatores, entre eles, o melhor conhecimento da estrutura real do cérebro, melhores algoritmos de treinamento e disponibilidade de computadores poderosos.

Dentro dessa linha, as redes neurais apresentam características interessantes no âmbito da solução de problemas, podendo destacar-se[27, 28]:

- robustez, devido à imunidade ao ruído. Apesar de ter seu desempenho afetado pela presença de informações falsas ou a ausência de informações verdadeiras, não entra em colapso como é o caso de programas convencionais;
- capacidade de aprender através de exemplos e de generalizar esse aprendizado;
- bom desempenho em tarefas mal definidas, nas quais porventura falte conhecimento explícito sobre como encontrar uma solução;
- não requerem conhecimento de modelos matemáticos dos domínios de aplicação;
- possibilidade de simulação de raciocínio *a priori* e impreciso, através da associação com a lógica *fuzzy*, bayes e outros.

Devido a essas características, as redes neurais apresentam aplicações em domínios como o reconhecimento de padrões, processamento de sinais, prognóstico de variáveis, diagnóstico de falhas, identificação e controle de processos, dentre outros.

### 3.2.1 Modelo Geral do Neurônio

A unidade fundamental de processamento de informação para a operação de uma rede neural é o neurônio. O modelo neural apresenta três elementos básicos: um conjunto de pesos sinápticos, um somador e uma função de ativação, mostrados na figura 3.2 [4].

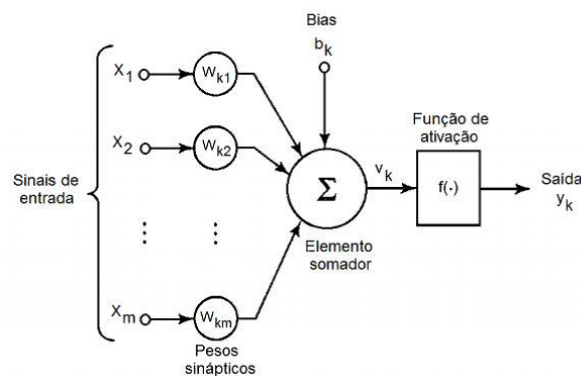


FIGURA 3.2: Modelo geral do neurônio. Fonte [4]

Os pesos sinápticos armazenam grande parte do conhecimento do neurônio. Esses pesos sinápticos são responsáveis por ponderar as informações que entram no neurônio, que serão somadas no elemento somador. O parâmetro bias, aplicado externamente, é obtido durante a fase de aprendizado da rede. A função de ativação  $f(\cdot)$  determina o grau de ativação do neurônio.

É possível descrever um neurônio  $k$ , matematicamente, pelas equações (3.1) e (3.2):

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.1)$$

$$y_k = f(u_k + b_k) \quad (3.2)$$

onde:

- $x_1, x_2, \dots, x_m$  são os sinais de entrada;

- $w_{k1}, w_{k2}, \dots, w_{km}$  são os pesos sinápticos do neurônio  $k$ ;
- $u_k$  é o resultado da soma das entradas, ponderadas pelos pesos sinápticos;
- $b_k$  é o bias;
- $v_k$  é a saída do elemento somador, contendo a soma das entradas ponderadas e o bias  $b_k$ ;
- $f(\cdot)$  é a função de ativação;
- $y_k$  é o sinal de saída do neurônio.

A função de transferência  $f(\cdot)$ , presente em todos os neurônios, é usada para limitar a saída do neurônio a um valor adequado ao problema. Existem diversas funções que podem ser utilizadas, sendo algumas mais adequadas à classificação e outras adequadas à regressão. Na figura 3.3 são mostradas as funções de ativação geralmente usadas. A função linear é usada geralmente na camada de saída em problemas de regressão, nos quais a saída pode apresentar valores contínuos. Já a função logística e tangente hiperbólica são usadas nas demais camadas, em problemas de regressão, e em todas as camadas na classificação.

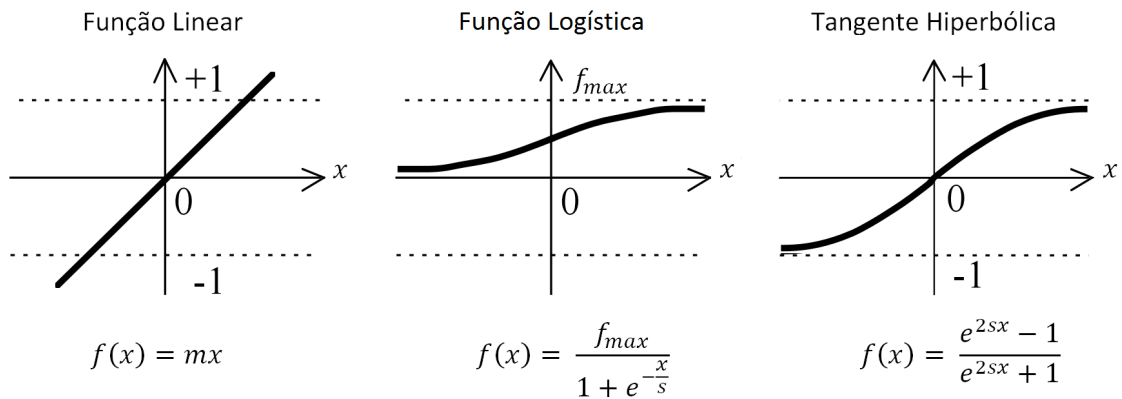


FIGURA 3.3: Funções de ativação comuns. Adaptado de [5]

### 3.2.2 Arquitetura das Redes Neurais

As estruturas de redes são, em geral, divididas em três classes de arquiteturas fundamentalmente diferentes: rede *feedforward* de camada única, rede *feedforward* multicamadas e rede recorrente. Elas se diferem pela existência de camadas que não são

de entrada nem saída, denominadas camadas ocultas, e pela alimentação, para adiante (*feedforward*) ou recorrente. Na figura 3.4 são apresentadas as arquiteturas dessas três classes de redes.

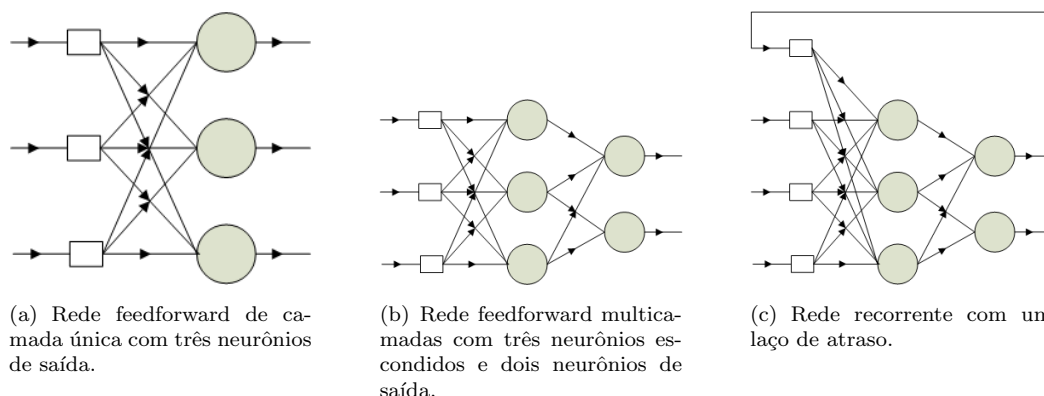


FIGURA 3.4: Exemplos de topologias de redes neurais

A estrutura mais simples é a rede *feedforward* de camada única, mostrada na figura 3.4(a), a qual não apresenta realimentações, sendo então acíclica, e apresentando apenas uma camada, a camada de saída. A segunda classe consiste em redes *feedforward* multicamadas (*multilayer perceptron*), apresentada na figura 3.4(b), as quais são alimentadas para frente e apresentam uma ou mais camadas ocultas. A presença de camadas ocultas confere a habilidade de síntese de informações de maior complexidade. A terceira classe fundamental consiste nas redes recorrentes, que diferente das anteriores possui algum laço de realimentação. Essa realimentação pode partir tanto de uma camada oculta quanto da camada de saída. Tal realimentação confere à rede a habilidade de modelar sistemas dinâmicos, em contraste com as redes alimentadas para frente, as quais são capazes de modelar, tipicamente, apenas sistemas estáticos [4].

### 3.2.3 Aprendizado em Redes Neurais

A habilidade de sintetizar conhecimentos a partir do seu ambiente e de melhorar o seu desempenho, de importância primordial para uma rede neural, se dá através da aprendizagem. Segundo Haykin [4, p. 75], “aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida”. O que irá diferenciar os tipos de aprendizagem é a forma na qual a modificação dos parâmetros ocorrerá.



O aprendizado de uma rede neural acerca de seu ambiente ocorre através de um processo iterativo de ajustes aplicado a seus pesos sinápticos e bias. Inicialmente, a rede neural recebe um estímulo do ambiente e através do processo de ajuste de pesos, modifica seus parâmetros livres. Como resultado, a rede passa a responder de uma maneira nova ao ambiente, em decorrência das modificações ocorridas na sua estrutura interna[4].

Essa modificação interna em resposta aos estímulos do ambiente é obtida através de algoritmos de treinamento, os quais, através de um conjunto pré-definido de regras, solucionam o problema de aprendizagem. Os métodos comuns de aprendizagem são: por correção de erro, baseada em memória, hebbiana, competitiva e de Boltzmann. No contexto deste trabalho será dada ênfase ao aprendizado por correção de erro, em especial ao algoritmo de retropropagação (*backpropagation*), o qual foi utilizado no treinamento das redes empregadas[4].

O algoritmo da retropropagação, apresentado em detalhes em [29], se dá através de várias etapas. Na primeira, inicializa-se a rede com pesos iniciais aleatórios e então apresenta-se à mesma um exemplo, com o qual é calculada a saída da rede, que é comparada à saída desejada para a obtenção do erro. Na etapa subsequente, são atualizados os valores sinápticos de forma a minimizar o erro, podendo ser usados diversos algoritmos de minimização do erro. A seguir, calcula-se o erro da saída para a penúltima camada e assim por diante, propagando o erro para trás. Por fim, apresenta-se um novo exemplo do conjunto de treinamento e repete-se todo o processo até que uma condição de parada seja alcançada. Podem ser usados como critério de parada o tamanho do erro, o gradiente do método de minimização ou também o desempenho da rede para um conjunto de validação [29].

Esse algoritmo pode realizar o aprendizado por época, no qual ele passa por parte, ou todo o conjunto de treinamento, antes de realizar a atualização dos pesos. Para essa forma de treinamento é necessário que todos os dados de treinamento estejam disponíveis ao mesmo tempo, para serem usados em um número de épocas, até a obtenção do desempenho desejado. Outra forma de aprendizado é o por padrão, no qual cada propagação do erro é seguida imediatamente por uma atualização dos pesos, e o conjunto de padrões é estático e apresentado de forma aleatória, com o objetivo de reduzir a chance de o algoritmo ficar preso em um mínimo local[4].

### 3.2.4 Retreinamento

O problema de sintetizar conhecimento em um ambiente dinâmico representa uma grande dificuldade para sistemas baseados no aprendizado. Questões envolvendo deriva conceitual (o conceito a ser aprendido varia com o tempo) e aprendizado sequencial (a informação é obtida em episódios separados no tempo) estão diretamente associadas ao dilema da estabilidade/plasticidade, no qual ambas as características são desejadas, mas encontram-se em conflito direto. Isso decorre do fato que, idealmente, o modelo desenvolvido pelo aprendizado deveria ser estável o suficiente para preservar informações importantes durante novos aprendizados, mas suficientemente plástico para incorporar novas informações[30].

Esse problema é descrito como uma limitação fundamental do tipo de arquitetura distribuída das redes neurais e leva a uma manifestação radical conhecida como esquecimento catastrófico. Nesse fenômeno, o processo de aprendizado de novos padrões corrompe e até elimina subitamente o conhecimento previamente aprendido pela rede. Tal manifestação acontece pelo fato de o conhecimento estar armazenado e compartilhado em um conjunto singular de pesos sinápticos. O uso deles, como um meio para codificar informações, leva a maioria dos modelos de redes neurais à excessiva plasticidade. Esse problema é uma das razões que faz com que os algoritmos típicos de treinamento de redes neurais sejam baseados no aprendizado concorrente, no qual toda a população de exemplos de treinamento é apresentada e treinada como uma entidade única e completa. Esse treinamento é realizado em apenas uma etapa e então finalizado [31].

Diversas abordagens visando reduzir ou até eliminar o problema do esquecimento catastrófico foram desenvolvidas. Dentre as técnicas existentes, podem-se citar os que buscam a redução da sobreposição do conhecimento, por meio da separação entre o novo aprendizado de aprendizados antigos ou de modelos distribuídos, e os que realizam um reaprendizado de padrões antigos[31]. Quanto ao reaprendizado, vários autores já estudaram diversas abordagens, entre elas várias formas de mistura entre padrões antigos e novos, que, como esperado, resultam numa redução do esquecimento catastrófico. Outra abordagem notável é a técnica de pseudopadrões (*pseudopatterns*) para reaprendizado, a qual é útil quando nenhum dos padrões originais se encontra disponível. Nela, através

da alimentação da rede com entradas escolhidas seguindo alguma distribuição de probabilidade, são gerados pseudopadrões, os quais, junto ao novo padrão, são usados no retreinamento da rede neural[30].

### 3.2.5 Comitê de Redes Neurais

Segundo Haykin[4, p. 385], “de acordo com o princípio de dividir e conquistar, uma tarefa computacional complexa é resolvida dividindo-a em um número de tarefas computacionais simples e, então, combinando as soluções destas tarefas”. Essa estratégia é implementada, na aprendizagem supervisionada, através da distribuição da tarefa de aprendizagem entre um conjunto de ferramentas de inteligência artificial, denominados *especialistas*. Essa combinação de especialistas é denominada Máquina de Comitê.

As máquinas de comitê são aproximadores universais, podendo ser classificadas em duas grandes categorias: as estáticas e as dinâmicas. As estruturas estáticas correspondem às máquinas de comitê cuja resposta dos vários previsores é combinada por um mecanismo que não envolve o sinal de entrada. Essa combinação pode ser obtida através da *média de ensemble*, na qual as saídas dos previsores são combinadas linearmente, ou através do reforço (*boosting*), em que um algoritmo fraco de aprendizagem é convertido em um algoritmo que alcança alta precisão. Já as estruturas dinâmicas apresentam o envolvimento do sinal de entrada no mecanismo que integra as saídas dos especialistas[4].

A melhora no desempenho final, obtida por meio da combinação das saídas dos especialistas, advém das diferenças de tipo, parâmetros, representações, conjuntos de treinamentos, algoritmos, entre outras. Essas variações fazem com que o problema de aprendizagem seja resolvido de maneiras diferentes, resultando em soluções distintas para o mesmo problema. Ao combinarmos essas soluções, as deficiências individuais podem se compensar, resultando em um especialista melhor[4].

Na *média de ensemble*, a integração das respostas dos especialistas é obtida pela média simples dos especialistas, em exemplos de regressão, ou pela votação simples, em exemplos de classificação. Em [32], é mostrado o erro quadrático do comitê, mesmo para especialistas correlacionados, obtido por *média de ensemble*, é sempre igual ou menor que o erro quadrático pior dos membros do comitê. Em outras palavras, mesmo que os membros do comitê tenham um desempenho bom, uma máquina de

comitê terá um desempenho, no pior dos casos igual ao desempenho do pior especialista. Adicionalmente, é mostrado que a partir da redução na correlação entre os especialistas, a capacidade de generalização do sistema combinado é melhorado, justificando a busca por métodos que reduzam a correlação entre os especialistas.

As máquinas estáticas treinadas a partir do reforço (*boosting*) têm como característica o treinamento de especialistas fracos (com desempenho pouco superior a 50%), mas que são complementares, por base no treinamento do especialista considerando o erro dos especialistas anteriores. Existem três métodos para a implementação dessa estratégia: filtragem, subamostragem e reponderação. Na filtragem, é utilizada uma grande fonte de exemplos que podem ser usados ou descartados durante o treinamento. Na subamostragem, um conjunto de treinamento de tamanho fixo é reamostrado durante o treinamento, de acordo com uma distribuição de probabilidade. Por fim, na reponderação, os exemplos do conjunto de treinamento são ponderados por um algoritmo de aprendizado fraco[32].

## Capítulo 4

# Implementação de Ferramentas para Geração de Inferências e Prognósticos

No presente capítulo é apresentada a implementação de ferramentas para a inferência de regime permanente e prognóstico da capacidade mais confiáveis em software de bancada para ensaios de desempenho de compressores herméticos. Essas ferramentas compõem um conjunto de atualizações do software de geração de inferências e prognósticos baseadas em algoritmos de inteligência artificial, que foram desenvolvidas e validadas em trabalhos anteriores[1, 6]. Para a utilização dessas ferramentas na bancada de ensaios são necessárias a implementação e integração das ferramentas no *software* supervisor da mesma.

O capítulo inicia com a caracterização geral das ferramentas de inferência de regime permanente e prognóstico previamente desenvolvidas. Na seção 4.2 é caracterizado o software original e são apresentadas as redes neurais projetadas para o prognóstico da capacidade de refrigeração, bem como uma análise do desempenho do sistema. Na seção 4.3 é apresentada a implementação de ferramentas e métodos para a melhoria da confiabilidade do sistema. Inicialmente é abordado o banco de dados com valores típicos das variáveis de interesse para compressores em diversas condições de ensaio. Na seção 4.3.2 é discutida a implementação do comitê de redes neurais e na seção 4.2.3 a ferramenta de análise do comportamento do comitê de redes. Por fim, na seção 4.4 é

apresentado um quadro comparativo da evolução do desempenho do sistema durante as diversas etapas de implementação do software.

## 4.1 Sistema de Inferência e Prognóstico de Capacidade de Refrigeração

A tarefa de inferir regime permanente e, posteriormente, gerar um prognóstico acerca das variáveis sob ensaio foi fonte de diversos trabalhos na linha de pesquisa do Labmetro. Abordagens que utilizam redes neurais foram apresentadas por Henklein [2], Steinbach [15] e Lima [6]. Uma abordagem que utiliza redes *fuzzy*-bayesianas para a inferência de regime foi apresentada por Casella [16]. O trabalho de Penz [1] definiu métodos e procedimentos para melhoria e garantia de confiabilidade dos resultados.

Nos trabalhos que exploraram a utilização de redes neurais foram consolidados diversos aspectos do projeto dessas ferramentas, como o tipo da rede, variáveis de entrada e seu pré-processamento, arquitetura da rede e algoritmos de treinamento. Com isso, obteve-se ao final do trabalho de Lima [6] uma ferramenta completa, composta por duas redes neurais para análise de cada variável de interesse (capacidade de refrigeração, potência elétrica ativa consumida e coeficiente de desempenho), a qual é explicada em detalhes na seção 4.2.

Essa ferramenta foi implantada no software da bancada de ensaios de desempenho, com a finalidade de gerar resultados, os quais foram utilizados na avaliação da ferramenta. A partir dessa implementação, foi possível gerar relatórios de ensaios realizados de forma completa, os quais apresentam: identificação completa do compressor e condições de teste; valores finais das grandezas de interesse; tempos relativos às inferências de regime; prognósticos e respectivos erros para cada uma das grandezas.

Através desses dados gerados pelos relatórios dos ensaios completos, foram apresentados por Penz[1] métodos e procedimentos capazes de integrar as informações de inferência e prognóstico e agregar confiabilidade às ferramentas.

No escopo deste trabalho, foi realizada a adaptação da ferramenta de inferência e prognóstico de capacidade de refrigeração que integra o software da bancada de ensaios, com o objetivo de implementar os métodos e procedimentos apresentados por Penz[1].

## 4.2 Caracterização do Sistema Original

A ferramenta original, consolidada por Lima[6], consiste em um sistema composto por vários módulos neurais, com o objetivo de integrar o software supervisor de uma bancada de ensaios de desempenho. Essa ferramenta foi desenvolvida em Labview, linguagem de programação visual, modularizada, orientada a fluxo de dados[33]. Cada módulo é responsável por gerar inferências de regime e, posteriormente, um prognóstico, para cada variável de interesse (capacidade de refrigeração, potência elétrica ativa consumida e coeficiente de desempenho). Na figura 4.1 é apresentado um diagrama esquemático da estrutura do sistema.

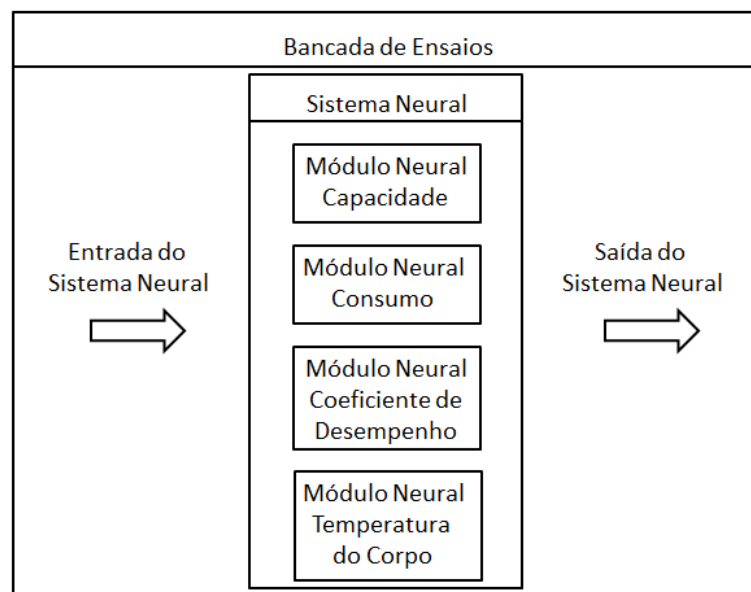



FIGURA 4.1: Sistema neural original. Adaptado de [6]


Cada módulo neural é composto por duas redes neurais, sendo a primeira responsável pela inferência do regime permanente da variável e a segunda responsável pelo prognóstico do valor final do ensaio.

A ferramenta de inferência do regime é responsável por diferenciar o período de regime transitório do período de regime permanente. É importante ressaltar que os valores finais de ensaio não são previamente conhecidos, dado que para cada grandeza de interesse o valor final é calculado pela média das medidas da última hora de ensaio, assim como os limites que definem se o valor está em regime permanente. Na figura 4.2 é apresentado um exemplo do comportamento da variável capacidade de refrigeração, com o valor final do ensaio e os limites de avaliação de regime permanente ( $\pm 2\%$ ), obtidos

através do valor final. O comportamento desejado para a ferramenta de inferência é mostrado na figura 4.2, que consiste na mudança de estado no momento exato de entrada de regime.



(a) Capacidade de Refrigeração



(b) Resposta Desejada

FIGURA 4.2: Exemplo do comportamento da rede de inferência de regime.

A ferramenta de prognóstico entra em execução no instante em que é inferido o regime permanente. Ela é responsável por gerar um prognóstico do valor final da variável de interesse, a partir dos valores conhecidos no instante em que foi inferido o regime permanente. No exemplo mostrado na figura 4.2, a ferramenta seria acionada no minuto 43, instante em que a ferramenta de inferência de regime troca de estado, e deveria retornar um prognóstico, o mais próximo possível do valor final do ensaio (200,2 W) para a capacidade de refrigeração.

O módulo responsável pela variável capacidade de refrigeração é mostrado no diagrama de blocos da figura 4.3. Nele é possível observar o fluxo de informação entre as operações principais do módulo. Ele é executado para cada amostra adquirida pelo software supervisor da bancada de ensaios, retornando, para cada amostra, se foi



inferido o regime e o prognóstico da capacidade de refrigeração, caso tenha sido inferido regime.

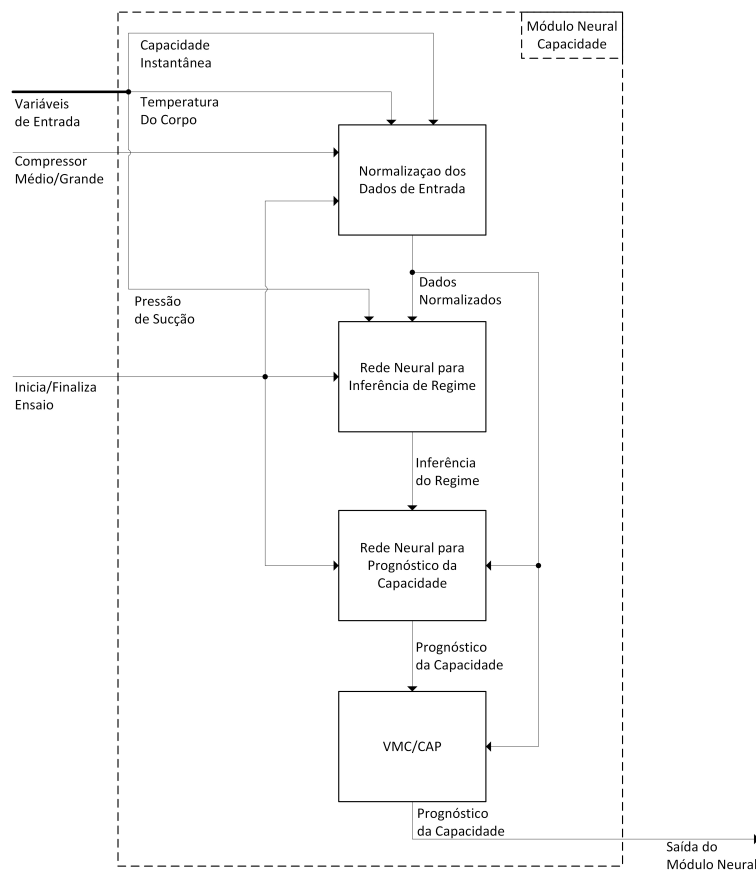


FIGURA 4.3: Diagrama de blocos do módulo neural capacidade.

O início do funcionamento é controlado pelo software supervisor, através da entrada de controle “Inicia/Finaliza Ensaio”. Tal informação é essencial para limpar os *buffers* dos módulos neurais e estabelecer os tempos de início e fim de ensaio.

As variáveis de entrada são obtidas através das variáveis adquiridas do processo e enviadas ao sistema neural via computador supervisor. São adquiridas do processo a potência elétrica ativa consumida, a pressão de sucção, a vazão mássica e a temperatura do corpo do compressor. Já a capacidade de refrigeração é calculada de acordo com os métodos implementados na bancada.

No bloco normalização das variáveis de entrada, os valores de capacidade instantânea e temperatura de corpo são convertidos para valores normalizados. Tal normalização busca inserir robustez ao sistema, ao eliminar a variabilidade decorrente do modelo de compressor. A variação absoluta das variáveis do ensaio para compressores de 200 W é mais acentuada que para um modelo de 50 W, sendo interessante, para

o sistema, abstrair as diferenças inerentes ao tamanho do compressor, usando valores relativos. Esse procedimento é feito em relação a valores típicos das variáveis. Para isso, os compressores são divididos em três grupos, inspirados na divisão definida pela fabricante de compressores. São eles:

- compressores grandes: 175 W a 265 W (valor médio = 220,0 W);
- compressores médios: 100 W a 175 W (valor médio = 137,5 W);
- compressores pequenos: até 100 W (valor médio = 50,0 W).

Nas subseções 4.2.1 e 4.2.2 são caracterizadas as redes neurais para inferência de regime e para o prognóstico da capacidade de refrigeração.

#### 4.2.1 Rede Neural para Inferência de Regime Permanente

A rede neural para inferência de regime apresenta a arquitetura mostrada na tabela 4.1. O treinamento foi realizado pelo algoritmo de otimização *Levenberg-Marquardt* e a função de erro avaliada no treinamento foi a soma quadrática dos erros. Em todas as etapas do processo de treinamento foi utilizado o *toolbox* de redes neurais do software *Matlab*[5].

Camada	Número de neurônios	Função de ativação
Entrada	16	-
1ª escondida	15	Tangente hiperbólica
2ª escondida	10	Tangente hiperbólica
3ª escondida	10	Tangente hiperbólica
Saída	2	Logística

TABELA 4.1: Arquitetura das redes neurais para inferência de regime.

As entradas da rede são mostradas na figura 4.4. Elas são geradas pelo pré-processamento das variáveis de entrada do módulo, sendo elas a capacidade de refrigeração, a temperatura do corpo do compressor e a pressão de sucção. São utilizadas várias médias e derivadas, com o objetivo de capturar os aspectos dinâmicos do sistema. É importante lembrar que essas variáveis passam por um processo de normalização, antes do pré-processamento do conjunto de entradas da rede.

Variável	Entrada da Rede	Entradas
Capacidade de Refrigeração	1	Desvio padrão de 15 amostras da variável precedentes ao instante atual(Std1).
	2	Média de 15 amostras da variável precedentes ao instante atual(M1).
	3	Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras(M2).
	4	Média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras(M3).
	5	Derivada entre 2ª e 3ª entrada(D1).
	6	Derivada entre 3ª e 4ª entrada(D2).
	7	Derivada entre 2ª e 4ª entrada(D3).
	8	Derivada entre 5ª e 6ª entrada(D4).
Temperatura do corpo	9	Média de 15 amostras da variável precedentes ao instante atual.
	10	Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras.
	11	Derivada entre 9ª e 10ª entrada.
	12	Derivada entre a 9ª entrada e a média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras.
Pressão de sucção	13	Média de 15 amostras da variável precedentes ao instante atual.
	14	Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras.
	15	Derivada entre a 13ª e a 14ª entrada.
	16	Derivada entre a 13ª entrada e a média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras.

FIGURA 4.4: Entradas da rede de inferência de regime da capacidade.

A saída da rede, típica de uma tarefa de classificação binária, varia entre os valores zero e um. O nível zero é atribuído para o período transitório, já o nível um para o período de regime permanente.

#### 4.2.2 Rede Neural para Prognóstico da Capacidade de Refrigeração

A rede neural para prognóstico da capacidade de refrigeração apresenta a arquitetura mostrada na tabela 4.2. Assim como a rede anterior, o treinamento foi realizado pelo algoritmo de otimização *Levenberg-Marquardt* e a função de erro avaliada no treinamento foi a soma quadrática dos erros. Em todas as etapas do processo de treinamento foi utilizado o *toolbox* de redes neurais do software *Matlab*[5].

Camada	Número de neurônios	Função de ativação
Entrada	8	-
1ª escondida	20	Tangente hiperbólica
Saída	1	Linear

TABELA 4.2: Arquitetura da rede para prognóstico da capacidade.

Para o prognóstico da capacidade de refrigeração são usadas pela rede as entradas mostradas na figura 4.5. Para constituir o conjunto de entradas são empregados apenas os valores pré-processados da própria capacidade de refrigeração, já normalizada. Esse pré-processamento sintetiza o comportamento dinâmico do ensaio nos instantes próximos

à entrada em regime, fazendo com que a rede seja capaz de relacionar essa dinâmica ao valor final que o ensaio atingiria.

Variável	Entrada da Rede	Entradas
Capacidade de Refrigeração	1	Desvio padrão de 15 amostras da variável precedentes ao instante atual(Std1).
	2	Média de 15 amostras da variável precedentes ao instante atual(M1).
	3	Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras(M2).
	4	Média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras(M3).
	5	Derivada entre 2ª e 3ª entrada(D1).
	6	Derivada entre 3ª e 4ª entrada(D2).
	7	Derivada entre 2ª e 4ª entrada(D3).

FIGURA 4.5: Entradas da rede para prognóstico da capacidade.

A saída da rede, típica de uma tarefa de regressão, é um valor contínuo, já que a função de ativação do neurônio de saída é linear. Esse valor representa uma capacidade de refrigeração normalizada, devendo então ser convertido utilizando-se os valores referentes ao grupo do compressor, operação inversa à normalização.

Esse software apresenta ainda o bloco, apresentado no diagrama como VMC/CAP, responsável por monitorar o prognóstico da capacidade de refrigeração. Esse monitoramento faz com que o prognóstico seja aceito como válido apenas se ele estiver dentro de uma faixa, calculada a partir do valor instantâneo da capacidade de refrigeração. Essa tarefa pode ser entendida como uma verificação entre as respostas da rede de inferência e prognóstico, já que se o prognóstico apresentar um valor fora da faixa de 2%, acima ou abaixo da capacidade instantânea, ou a inferência de regime foi no instante errado, ou o prognóstico apresenta erro grande.

### 4.2.3 Análise de Resultados

Com o auxílio dos dados obtidos através dos relatórios gerados pelo software, em operação real, foi possível analisar a qualidade das inferências de regime e prognósticos da capacidade de refrigeração. Com um conjunto de 201 ensaios completos, contemplando uma ampla gama de compressores e condições termodinâmicas de ensaio, foram averiguadas diversas métricas para a caracterização da resposta, entre elas a quantidade de ensaios com inferência do regime e o histograma do erro percentual entre o prognóstico e o valor final do ensaio.

Quanto à quantidade de inferências, 171 ensaios apresentaram inferência, enquanto 30 não apresentaram, isto é, 14,9% dos ensaios. Como apenas nos ensaios em que ocorre a inferência do regime há o ganho de tempo, evidencia-se a importância da melhora na quantidade de inferências.

Na figura 4.6, é mostrado o histograma do erro percentual, calculado entre o prognóstico da capacidade e o valor final do ensaio, para os 171 ensaios válidos (que apresentaram inferência). É possível notar que uma quantidade significativa de ensaios apresentou prognóstico fora dos limites desejados, de  $\pm 2\%$ , equivalendo a 48 dos 171 ensaios, cerca de 30% dos ensaios válidos.




FIGURA 4.6: Erro percentual.

### 4.3 Implementação de Ferramentas Para Incremento da Confiabilidade

A análise do comportamento do software de geração de inferências e prognósticos através dos relatórios gerados pelo próprio software em testes reais possibilitou a avaliação da ferramenta e o desenvolvimento de ferramentas e métodos para o incremento da confiabilidade das técnicas usadas no software[1]. Foi constatada a necessidade de ocorrência de inferência numa quantidade significativa de ensaios, já que ela garante ganhos substanciais de tempo.

Quanto à qualidade das inferências, o trabalho de Penz[1] observou que uma quantidade significativa de ensaios apresenta inferência fora da região pretendida, de  $\pm 2\%$ .

Para melhorar os resultados obtidos e encaminhar confiabilidade foram propostas por Penz[1], e implementadas no software pelo autor, as seguintes estratégias:

- utilização de banco de dados para valores típicos de capacidade de refrigeração e temperatura de corpo para as diversas condições de ensaio;
- aperfeiçoamento das redes neurais artificiais, através da implementação de comitês de redes neurais.

Na seção 4.3.1 é detalhada a implementação da consulta ao banco de dados de valores típicos.

### 4.3.1 Implementação da Consulta por Valores Típicos

Uma das características desejadas para o sistema de geração de inferências e prognósticos é a robustez, já que a bancada de ensaios de desempenho é utilizada para o controle de qualidade dos lotes, para geração de informações de catalogação e para avaliação de melhorias em projetos de pesquisa e desenvolvimento. Isso, somado às variações no comportamento dinâmico entre as bancadas, decorrente principalmente das variações no ajuste do controle da mesma, resulta em um sistema cuja dinâmica pode apresentar sensíveis variações.

Uma das estratégias usadas para minimizar esse problema, no sistema original, foi a subdivisão dos modelos de compressores em três classes, utilizando a divisão usada pelo fabricante. Essa subdivisão tem como objetivo reduzir a influência associada à variação de modelos testados, decorrentes da variação do tamanho, na robustez do sistema. Ao usarmos essa subdivisão como parâmetro durante a normalização, o sistema retiraria do seu modelo os ganhos de capacidade e temperatura do corpo associados ao tamanho do compressor.

Em [1] foi elaborada uma estratégia para substituir essa subdivisão por uma opção que considere outros fatores, buscando utilizar na etapa de normalização valores referentes a cada modelo de compressor, nas diversas condições de ensaio. Para isso foi criado um banco de dados composto de valores típicos para a capacidade de refrigeração e temperatura do corpo de compressores em ensaios de desempenho. Esse banco de dados é

formado pela identificação desses valores típicos em um conjunto de ensaios disponíveis. Os ensaios foram divididos através das seguintes características: modelo do compressor, tensão de alimentação, frequência de alimentação; rotação (quando compressor de capacidade variável); condição termodinâmica de ensaio.

A consulta ao banco de dados foi implementada na etapa de normalização das variáveis de entrada, como mostrado em destaque na figura 4.7. O software, usando dados de cada compressor na condição específica do ensaio, passa a utilizar na entrada das redes neurais valores numa faixa bem estabelecida. Ao invés de variar entre 0 W e a capacidade final típica daquele modelo, o sistema passa a trabalhar, para um compressor típico do modelo, na faixa entre 0 W e 100 W. Com isso, cabe à rede apenas identificação da dinâmica do ensaio, abstraindo as peculiaridades inerentes aos modelos de compressores.

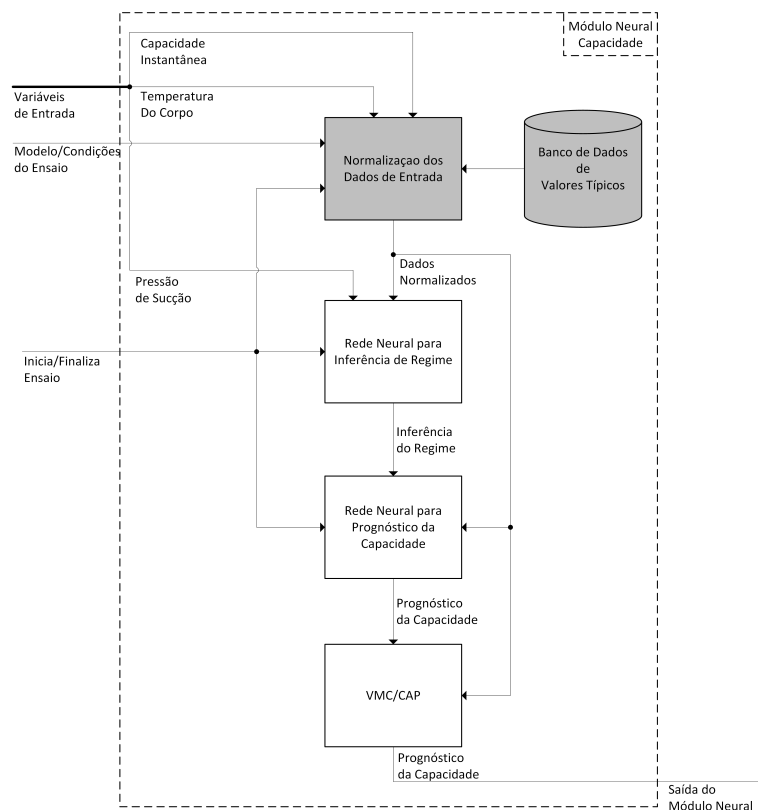


FIGURA 4.7: Diagrama de blocos do sistema com consulta a valores típicos.

Um conjunto de testes contendo 201 ensaios completos, de vários modelos de compressores em diversas condições de ensaio, foi usado para avaliar o desempenho do sistema. O histograma do erro percentual, entre o prognóstico da capacidade de refrigeração e a capacidade medida no ensaio, é mostrado na figura 4.8.




FIGURA 4.8: Erro percentual.

A distribuição do erro percentual apresentou melhora, sendo que a quantidade de ensaios dentro da faixa desejada, de  $\pm 2\%$ , aumentou de 71% para 90%. Houve uma melhora significativa no número de ensaios em que o sistema não apresenta inferência, diminuindo de 30 para 7 ensaios. Por sua vez, o tempo médio até a inferência aumentou de 41 minutos para 69 minutos, o que a primeira vista é indesejado, mas que justifica-se pelo fato do sistema original apresentar muitas inferências precoces que levam a erros em muitos casos.

### 4.3.2 Implementação dos Comitês de Redes Neurais

Com o intuito de melhorar a qualidade das inferências e prognósticos, foi explorada por Penz[1] uma estratégia baseada em comitês de redes neurais. Esse conjunto de redes apresenta a mesma arquitetura, porém cada rede é treinada com diferentes conjuntos de treinamento e a partir de diferentes parâmetros iniciais (pesos e bias). A justificativa para o uso de múltiplas redes repousa na consideração de que o uso desse conjunto possa gerenciar as limitações individuais de cada rede. Essa limitação decorre da discrepância entre o conjunto de treinamento usado e a abrangência dos exemplos que serão efetivamente encontrados no uso[4].

Um comitê de redes eficaz para a aplicação deve ser formado por um conjunto de redes que sejam ao mesmo tempo exatas e diversificadas. O meio para a garantia de diversidade utilizado por Penz[1] foi o treinamento com conjuntos de treinamento



distintos, obtidos a partir de uma base de dados de 50 ensaios. Essa base foi considerada representativa do comportamento típico do ensaio, sendo composta por ensaios de diversos modelos de compressores avaliados em diferentes condições termodinâmicas.

Do conjunto de 50 ensaios, para cada rede foi selecionado de forma aleatória, com reposição, um conjunto composto por 40 ensaios para treinamento e os restantes foram empregados para validação online, usada para parar o treinamento precocemente evitando a perda de desempenho decorrente do sobre-ajuste (*overfitting*). Pelo fato de os ensaios passarem por um processo de seleção com reposição, o conjunto de treinamento, em alguns casos, apresenta ensaios repetidos. Devido a isso, os conjuntos de validação online variaram em número de ensaios.

Para integração da resposta do comitê de redes foram definidas regras para a inferência do regime, projetadas buscando reduzir a o erro médio absoluto através de tempos de espera até inferência de regime pelo comitê. Essas regras, mostradas na tabela 4.3, possibilitaram maior robustez no processo de inferência, ao levar em conta não apenas a probabilidade de cada rede em indicar a entrada em regime permanente, mas também a probabilidade de ela não indicar, o que faz com que sejam necessárias as regras intermediárias.

Regra	Quantidade de redes	Tempo de espera
I	<15	40 minutos
II	$\geq 15$ e $< 20$	30 minutos
III	$\geq 20$ e $\leq 27$	10 minutos
IV	$> 27$	0 minutos

TABELA 4.3: Relação entre quantidade de redes e tempo de espera.

A estrutura da implementação de redes neurais teve de ser modificada para permitir o funcionamento do comitê de redes, fornecendo ao software a flexibilidade para a avaliação de conjuntos arbitrários de redes neurais. Para isso foi usado um banco de dados com conjuntos de redes neurais treinadas, visando maior facilidade em futuras atualizações do conjunto de redes. O diagrama de blocos, na figura 4.9, mostra a estrutura da implementação do comitê de redes neurais para inferência do regime permanente da capacidade de refrigeração, desenvolvida pelo autor.

O comitê apresenta três blocos de processamento principais: geração de dados de entrada; avaliação do comitê; avaliação das regras. Adicionalmente existe um banco de

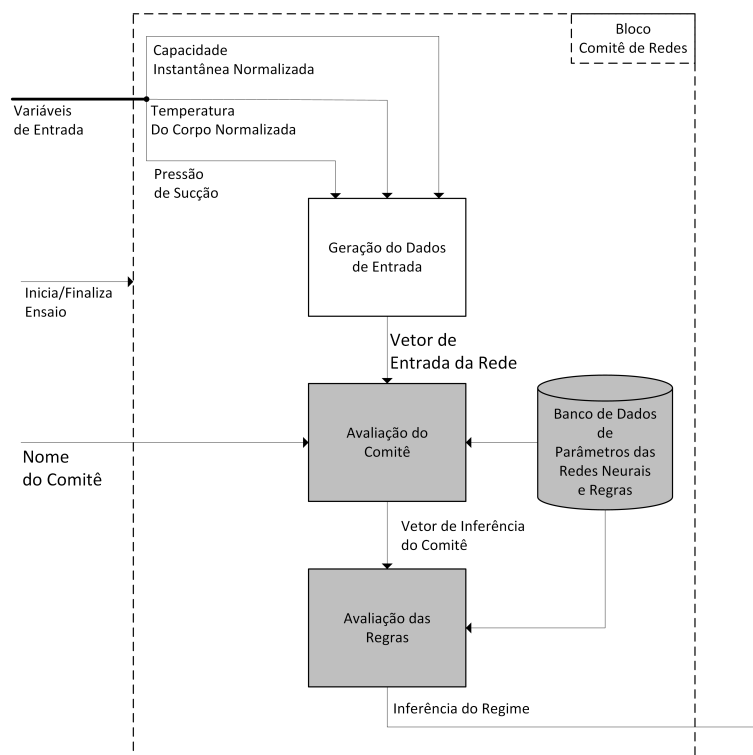


FIGURA 4.9: Diagrama de blocos do comitê de redes neurais para inferência de regime.

dados, contendo os parâmetros dos comitês, para flexibilizar a atualização dos comitês. Apenas o bloco de geração do vetor de dados de entrada foi mantido sem alterações. O bloco que avalia o conjunto de redes tem como entrada o nome do comitê a ser utilizado e carrega os parâmetros em memória no início do ensaio. A informação acerca do número de redes está contida nos próprios parâmetros carregados do banco de dados. Com isso, o software precisa tratar um número variável de redes, o qual será avaliado para cada vetor de entrada da rede. A resposta do vetor de redes é processado pelo bloco *Avaliação das Regras*, cujas regras a serem avaliadas são carregadas do banco de dados, já que o conjunto de regras pode variar entre os comitês treinados.

Desenvolvimento semelhante foi realizado para a rede de prognóstico, mantendo as diferenças na estrutura entre a de regime e a de prognóstico. A única diferença relevante concerne à integração das respostas do comitê, a qual consiste na média aritmética dos componentes do vetor de respostas das redes de prognóstico.

Avaliando o desempenho do sistema após as modificações propostas, para o conjunto de testes com 201 ensaios, foi obtido o histograma mostrado na figura 4.10. É sensível a melhora de desempenho geral do sistema, tanto no número de ensaios que apresentaram inferência - que agora passou de 194 para 200 dos 201 ensaios do conjunto

- quanto pela redução do número de ensaios fora do limite desejado, de  $\pm 2\%$ . Apenas 10 dos 200 ensaios válidos tiveram erro absoluto percentual fora da faixa desejada, o que equivale a 5% dos ensaios válidos.




FIGURA 4.10: Erro percentual.

### 4.3.3 Análise do Comportamento do Comitê de Redes

A estratégia utilizada para integração da resposta do comitê de redes para inferência de regime foi a votação, levando em conta a quantidade de redes que apresentaram inferência. A partir dessa votação, é avaliado um conjunto de regras, mostrado na figura 4.3, o qual estabelece valores de espera até a inferência do sistema, baseado no resultado da votação. Essa estratégia incorpora certa robustez no sistema, já que cada rede apresenta probabilidade de não inferir regime, fazendo que a votação do comitê apresente patamares finais variados, podendo variar desde 15 até as 30 redes inferindo regime permanente. Na figura 4.11 são mostrados comportamentos possíveis para o comitê de redes neurais.

Esse comportamento do comitê varia, dependendo do ensaio, entre patamares distintos. O conjunto de regras avalia apenas o número absoluto de redes que inferiram o regime, e se ocorre alguma variação grande nesse número. Isso faz com que o sistema acabe não levando em conta a dinâmica da votação do comitê, deixando de aproveitar informações interessantes, como tendências de mudança de patamar, que podem indicar melhora ou piora na resposta. Uma análise da dinâmica das redes mostra que em certos casos, apesar de um número grande de redes já apresentar inferência, a dinâmica




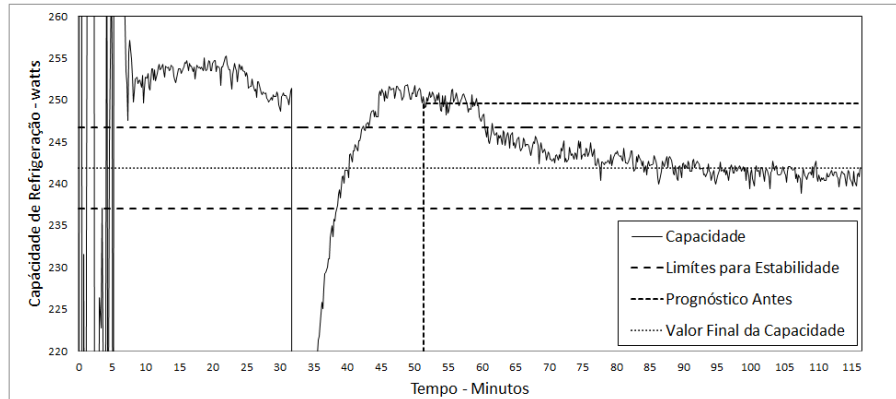
FIGURA 4.11: Comportamento do comitê de redes neurais.

apresentada pela votação está relacionada à dinâmica do ensaio, podendo ser utilizada para melhorar a resposta do sistema.

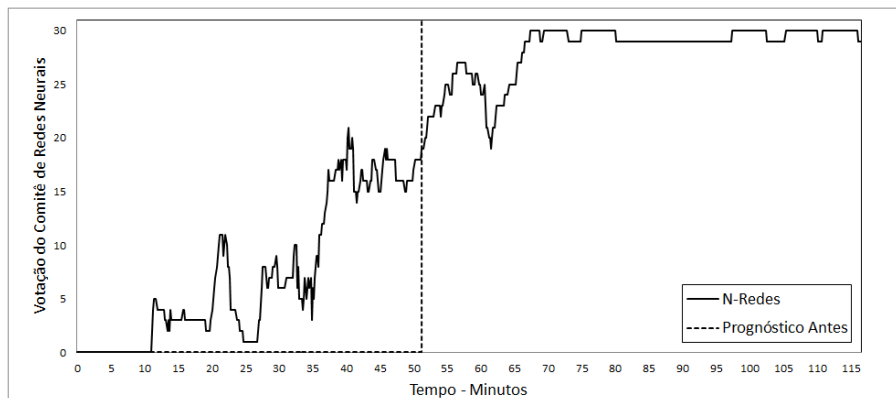
Analisando a dinâmica do comitê de redes é possível observar que derivadas positivas na votação estão relacionadas à aproximação do regime; já derivadas negativas têm relação à identificação de mudanças frequentemente associadas a períodos de falsa identificação de regime (situação na qual o ensaio apresenta tendência de entrada em regime em certo patamar de capacidade e, de forma abrupta, apresenta dinâmicas que levam ao assentamento do ensaio em outro patamar de capacidade). Esse fenômeno é uma das principais causas para erros significativos no prognóstico da capacidade de refrigeração, sendo de difícil identificação. Assim, a utilização de dados provenientes do acompanhamento do comportamento da votação é uma alternativa interessante, pois possibilita a identificação desses fenômenos durante o período de avaliação do conjunto de regras, auxiliando as mesmas na tarefa de integrar a resposta do comitê.

Na figura 4.12(a) pode ser observado um exemplo no qual a inferência ocorre em um instante de falso regime, o que resulta em um erro percentual fora dos limites desejados. Na figura 4.12(b) observa-se o comportamento da votação do comitê de redes neurais. Fica evidente que a inferência do regime ocorreu em um período no qual o comitê estava sofrendo forte variação.

A partir do estudo desses comportamentos foi desenvolvida ferramenta capaz de inibir a inferência em instantes de mudanças na votação do comitê de redes. A ferramenta usa somente o valor da soma da resposta do conjunto de redes como entrada e, através de um algoritmo de processamento digital, retorna uma confirmação do assentamento da votação do comitê. Quando identifica variações significativas na resposta, a ferramenta



(a) Capacidade de refrigeração e limites de estabilidade.




(b) Votação do comitê de redes.

FIGURA 4.12: Análise do comportamento do comitê de redes neurais.


conclui que o sistema ainda está sofrendo variações significativas na capacidade, inibindo a inferência do regime, por parte do conjunto de regras.

Na figura 4.13, pode-se ver o comportamento da ferramenta, para o mesmo exemplo mostrado anteriormente. Nela é possível observar que a ferramenta inibe a inferência nos períodos em que o comitê varia a sua resposta, retornando 0 quando o sistema está desabilitado e 1 quando está habilitado. Isso faz com que a inferência aconteça apenas na região onde ocorre a entrada em regime efetiva da capacidade, melhorando a resposta do sistema substancialmente.

Com a adição dessa ferramenta no software, diversos ensaios passam a ter um erro percentual menor e observa-se uma melhora na resposta, principalmente para os ensaios em que o erro percentual é maior do que a faixa de erro desejada, como mostrado na figura 4.14. O número de ensaios válidos permaneceu inalterado, já o número de ensaios válidos fora da faixa desejada, de  $\pm 2\%$ , passou de 10 para 7.



(a) Capacidade de refrigeração e prognósticos antes e depois.



(b) Votação do comite de redes e saída da ferramenta.

FIGURA 4.13: Resposta da ferramenta de monitoramento do comitê.




FIGURA 4.14: Erro percentual.

A seção 4.4 mostra a evolução do desempenho do software para as várias etapas.

## 4.4 Resultados

Na seção 4.2.3, foi analisada a característica da resposta do sistema original, tomando como parâmetros o conjunto de testes composto por 201 ensaios completos. Foi possível observar que o comportamento médio do sistema, medido através do erro percentual de prognóstico, se aproximou do desejado, mas a dispersão da resposta era visivelmente grande, fazendo com que o sistema apresentasse resposta com erro maior do que o desejado em uma quantidade grande de ensaios, cerca de 30% dos ensaios válidos. Adicionalmente, observou-se que o sistema não apresentou inferência em cerca de 15% dos ensaios, característica indesejada para o sistema.

Após a implementação das ferramentas propostas neste trabalho, visando a melhora do comportamento geral do sistema, foram obtidos os resultados mostrados na seção 4.3.3. O erro percentual de prognóstico apresentou valor médio dentro da faixa desejada, com dispersão menor, e reduzido número de ensaios com erro percentual de prognóstico fora da faixa desejada. Na figura 4.15 é mostrado o histograma do erro percentual de prognóstico obtido pelo software em sua versão após as modificações comparado com o obtido pelo software original. Fica evidente a melhoria no comportamento geral do sistema: o erro percentual para o sistema final está melhor distribuído e apresentando uma quantidade maior de ensaios dentro da faixa de erro desejada ( $\pm 2\%$ ).




FIGURA 4.15: Erro percentual de prognóstico para o sistema original e o sistema com as ferramentas propostas.

A tabela 4.4 compara o sistema após cada etapa da atualização do software. O maior ganho de desempenho veio através da implementação do banco de dados para valores típicos nas determinadas condições de ensaio. É importante notar que o ganho de desempenho, oriundo das novas ferramentas, apresentou aumento significativo no tempo médio de inferência, comparando-se com o sistema original. Esse aumento justifica-se pela melhor qualidade das inferências, que deixam de acontecer precocemente em diversos casos, aproximando-se do instante real de entrada em regime permanente. Apesar de existir a demanda por inferências com menor tempo, sendo esse um dos objetivos do projeto, é necessário também garantir a confiabilidade dos prognósticos. Devido a isso, é preferível que o prognóstico seja mais demorado a ser incorreto, fazendo com que o aumento no tempo médio seja considerado aceitável.

Número de Ensaio	Sistema Original	Com Valores Típicos	Comitê de Redes	Estabilização do Comitê
Disponíveis	201	201	201	201
Sem Inferência	30	7	1	1
Ensaio Válido	171	194	200	200
Erro Máximo	Percentual de ensaios válidos			
± 0,75%	21,05%	41,75%	51,00%	55,00%
± 1,0%	40,35%	75,77%	84,50%	88,00%
± 1,5%	57,89%	81,11%	93,00%	94,00%
<b>± 2,0%</b>	<b>71,93%</b>	<b>90,72%</b>	<b>95,00%</b>	<b>96,50%</b>
± 2,5%	80,12%	90,72%	97,50%	97,50%
± 3,0%	84,21%	92,27%	99,00%	99,00%
± 3,5%	88,89%	95,88%	99,00%	99,00%
± 4,0%	90,06%	95,88%	99,00%	99,00%
Tempo Médio até Inferência (min)	41	69	65	67

TABELA 4.4: Resumo dos resultados de prognóstico das ferramentas propostas.

Observa-se melhoria acentuada na diminuição do número de ensaios que não apresentaram inferência, que passou de 30 para 1, o que evidencia uma redução significativa. Quanto ao erro absoluto médio do prognóstico, houve melhora acentuada na distribuição, sendo que a quantidade de ensaios válidos que apresentam erro máximo menor que 1% aumentou de 40% para 88%. Essa melhora evidencia que as ferramentas implementadas no software cumprem com o objetivo de melhorar a qualidade das inferências e prognósticos, fazendo com que o sistema de inteligência artificial apresente respostas satisfatórias.



## Capítulo 5

# Análise de Métodos para Atualização das Ferramentas

O sistema de geração de inferências e prognósticos foi desenvolvido utilizando ferramentas de aprendizado de máquina, as quais utilizam conhecimento *a priori* incorporado em sua estrutura, com o intuito de gerar inferências e prognósticos acerca das variáveis de interesse em ensaios de desempenho de compressores.

O conhecimento *a priori* é proveniente de ensaios de desempenho completos, que foram selecionados de forma a representar o comportamento típico das grandezas do ensaio, incorporando as variações de dinâmica associadas à diferença entre os modelos de compressores e, adicionalmente, às diferenças entre as bancadas de ensaio. Para as redes neurais, esse conhecimento é processado para a geração de entradas para o treinamento de redes neurais, as quais irão incorporar esse conhecimento por meio dos pesos sinápticos em sua estrutura.

O objetivo desse sistema é, através dessas ferramentas “inteligentes”, reduzir o tempo total de ensaio, garantindo confiabilidade às respostas do sistema. A garantia da confiabilidade é associada à robustez do sistema, já que ele será utilizado para ensaios de pesquisa e desenvolvimento, que apresentam variabilidade significativa tanto na dinâmica das variáveis quanto nos valores típicos das variáveis do ensaio.

Quanto à robustez do sistema, a variabilidade da dinâmica das variáveis de ensaio é associada a diversos fatores, podendo abranger desde defeitos de manufatura até variações no projeto. Dentre esses fatores, que não são conhecidos *a priori*, as variações no projeto devem, eventualmente, ser incorporadas na base de conhecimento do sistema. Essa variação pode ser caracterizada tanto como uma deriva conceitual, já que o conceito a ser aprendido varia com o tempo, devido às variações de projeto, e também como um problema de aprendizado sequencial, já que novos conceitos a serem aprendidos são obtidos com o passar do tempo.

Para lidar com essas características, é necessário estudar métodos de atualização de redes neurais que preservem o conhecimento já incorporado no sistema e, ao mesmo tempo, seja capazes de incorporar o novo conhecimento que surgirá durante o funcionamento da ferramenta. Esses métodos, após implantação no sistema, devem ter a capacidade de identificar a perda de qualidade nas inferências e prognósticos e, através do novo conhecimento adquirido durante o funcionamento, atualizar o sistema visando a melhora da qualidade das respostas.

Na seção 5.1 será exposta a proposta de métodos para atualização das ferramentas, e após, na seção 5.2 serão apresentados os algoritmos de retreinamento de redes neurais desenvolvidos para essa abordagem. Por fim, na seção 5.3 serão mostrados os resultados provenientes dos testes dos algoritmos de retreinamento.

## 5.1 Propostas de Método para Atualização de Redes Neurais

Existem na literatura diversos métodos para a atualização de redes neurais, levando em conta a problemática inerente às mesmas, comumente descrita como esquecimento catastrófico. Essas abordagens buscam adicionar novos conhecimentos às redes, mantendo o conhecimento adquirido previamente através de uma variada gama de soluções. Na revisão da literatura realizada por [30] são apresentados métodos que permitem a adição de novos exemplos em redes previamente treinadas, evitando o esquecimento catastrófico. As soluções identificadas lidam com o problema de formas distintas: tentando reduzir a sobreposição da informação armazenada na rede ou através de métodos para revigorar o conhecimento durante o novo aprendizado.

As técnicas que visam a redução da sobreposição têm como característica a variação da morfologia das redes, buscando segregar a rede em módulos, regiões ou até unidades distintas de armazenamento do conhecimento, fazendo com que o aprendizado antigo não seja afetado pelo novo. São apresentados vários métodos, variando desde redes com grande quantidade de neurônios, fazendo o conhecimento ficar esparso, até sistemas com duas redes distintas, nos quais o conhecimento antigo é mantido nos pesos sinápticos de uma rede e o conhecimento novo nos pesos da outra rede.

Uma breve análise das técnicas demonstra a inadequação ao sistema que se pretendem atualizar. O fato dessas técnicas apresentarem variações na estrutura da rede inviabiliza sua utilização, já que pretende-se manter a estrutura da rede inalterada.

Por sua vez, as técnicas que buscam revigorar o conhecimento antigo durante o novo aprendizado não diferem muito de um novo treinamento. A principal diferença consiste na escolha dos exemplos utilizados no treinamento. Na sua forma mais básica, incorpora-se o novo exemplo aos exemplos antigos e retreina-se a rede, podendo ser descartado algum exemplo antigo. Outra técnica possível é a utilização de pseudopadrões, técnica que caracteriza-se por não guardar explicitamente os exemplos antigos, mas gerar novos exemplos a partir do conhecimento armazenado na própria rede.

Apesar de a geração de pseudopadrões mostrar-se promissora, neste trabalho foi explorada a incorporação de exemplos novos aos antigos e retreinamento. Essa escolha justifica-se pelo fato de o armazenamento dos exemplos ser viável e pela técnica apresentar fácil implementação, já que possui diversas similaridades com o processo de treinamento utilizado para a obtenção das redes originais.

Além da técnica de retreinamento, um sistema capaz de incorporar conhecimento às ferramentas de inteligência artificial já implementadas necessita implementar diversas funcionalidades, desde o monitoramento da qualidade das respostas do sistema até a adaptação dos pesos das sinapses das redes neurais. As funcionalidades desse sistema podem ser divididas em duas tarefas principais: avaliação do desempenho das ferramentas e atualização das mesmas. O diagrama de blocos para o sistema proposto é mostrado na figura 5.1.

A avaliação do desempenho das ferramentas compreenderá as tarefas de monitoramento da qualidade das inferências e prognósticos, bem como a aquisição de novo

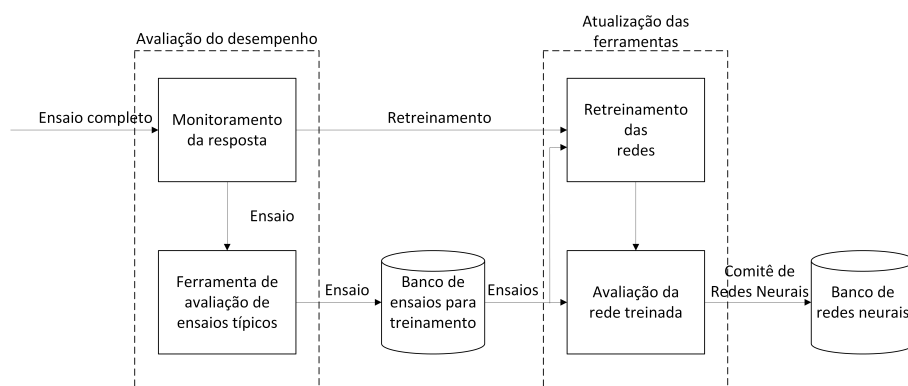


FIGURA 5.1: Diagrama de blocos para o sistema de retreinamento.

conhecimento. Para o monitoramento da qualidade, ilustrado no diagrama como *Monitoramento da resposta*, serão utilizadas métricas para avaliação quantitativa do desempenho das ferramentas. Para isso, é necessário executar ensaios completos, os quais serão realizados com uma determinada periodicidade. Esses ensaios completos representarão, além de parâmetros para a avaliação da qualidade das inferências e prognósticos, o novo conhecimento a ser adquirido pelo sistema, o qual será incorporado a um banco de dados contendo os ensaios aptos para utilização no treinamento.

A incorporação efetiva ao banco de dados do ensaio adquirido no monitoramento dar-se-á através de uma ferramenta, que avaliará se o presente ensaio apresenta comportamento típico que o habilite à classe de ensaios adequados à utilização no treinamento. Essa tarefa é ilustrada como *Ferramenta de avaliação de ensaios típicos*.

A tarefa de atualização das ferramentas consiste na escolha automática dos ensaios a serem usados no treinamento e na atualização das ferramentas através do retreinamento, representados no diagrama pelo bloco *Retreinamento das redes*. O sistema terá que escolher o conjunto de ensaios adequado, constando os novos padrões a serem aprendidos, e levando em conta a distribuição dos ensaios que serão usados.

Por fim, existirá uma ferramenta, a qual será responsável por verificar se o novo comitê de redes apresenta resultado satisfatório, sendo representada no diagrama como *Avaliação da rede treinada*. Essa ferramenta deverá, através de um conjunto de ensaios para teste, escolhido entre os ensaios disponíveis no banco de dados, avaliar se a rede retreinada apresenta desempenho melhor do que os outros comitês de redes disponíveis, para assegurar que o sistema apresentará melhora de desempenho.

No escopo deste trabalho foram implementados um conjunto de algoritmos de retreinamento, tanto para a rede de inferência de regime quanto para a de prognóstico da capacidade de refrigeração. Na seção 5.2 é discutida a estratégia de retreinamento, e na seção 5.3 são apresentados os resultados dos testes da estratégia.

## 5.2 Estratégia de Retreinamento

Os algoritmos de retreinamento foram desenvolvidos partindo dos algoritmos originais de treinamento das redes neurais. O objetivo inicial desse desenvolvimento é validar o método de retreinamento, avaliando as variações no método de retreinamento. Essa validação é necessária para entender melhor o processo de retreinamento, bem como a influência de diversos parâmetros no tempo de treinamento e na qualidade das redes treinadas.

Para isso, foram desenvolvidos algoritmos no software Matlab[5], tanto para a rede de inferência de regime, quanto para a rede de prognóstico, que possibilitam realizar o treinamento inicial das redes neurais, bem como permitem adicionar um novo ensaio ao conjunto de treinamento e retreinar a rede a partir do ponto em que foi parado o treinamento anterior. Com isso é possível avaliar se acontece algum ganho no tempo de treinamento e no desempenho.

O algoritmo de treinamento é mostrado através de um fluxograma na figura 5.2. Ele é equivalente para ambas as redes neurais, havendo diferenças apenas na implementação de algumas funções, já que a arquitetura das redes é diferente.

O algoritmo é dividido em duas partes complementares: preparação dos dados e treinamento. Na primeira etapa é realizado todo o processamento dos exemplo, para gerar os conjuntos de entrada para o treinamento. Já a segunda etapa realiza o treinamento e salva os parâmetros da rede treinada.

A etapa de preparação dos dados de entrada para a rede neural inicia com o carregamento do conjunto de ensaios, escolhidos de uma lista com 63 ensaios disponíveis. A partir desses ensaios são criados os conjuntos de treinamento e validação online, escolhidos de forma aleatória com reposição, sendo o conjunto de treinamento composto por dois terços dos ensaios e o conjunto de validação composto pelos ensaios não utilizados no

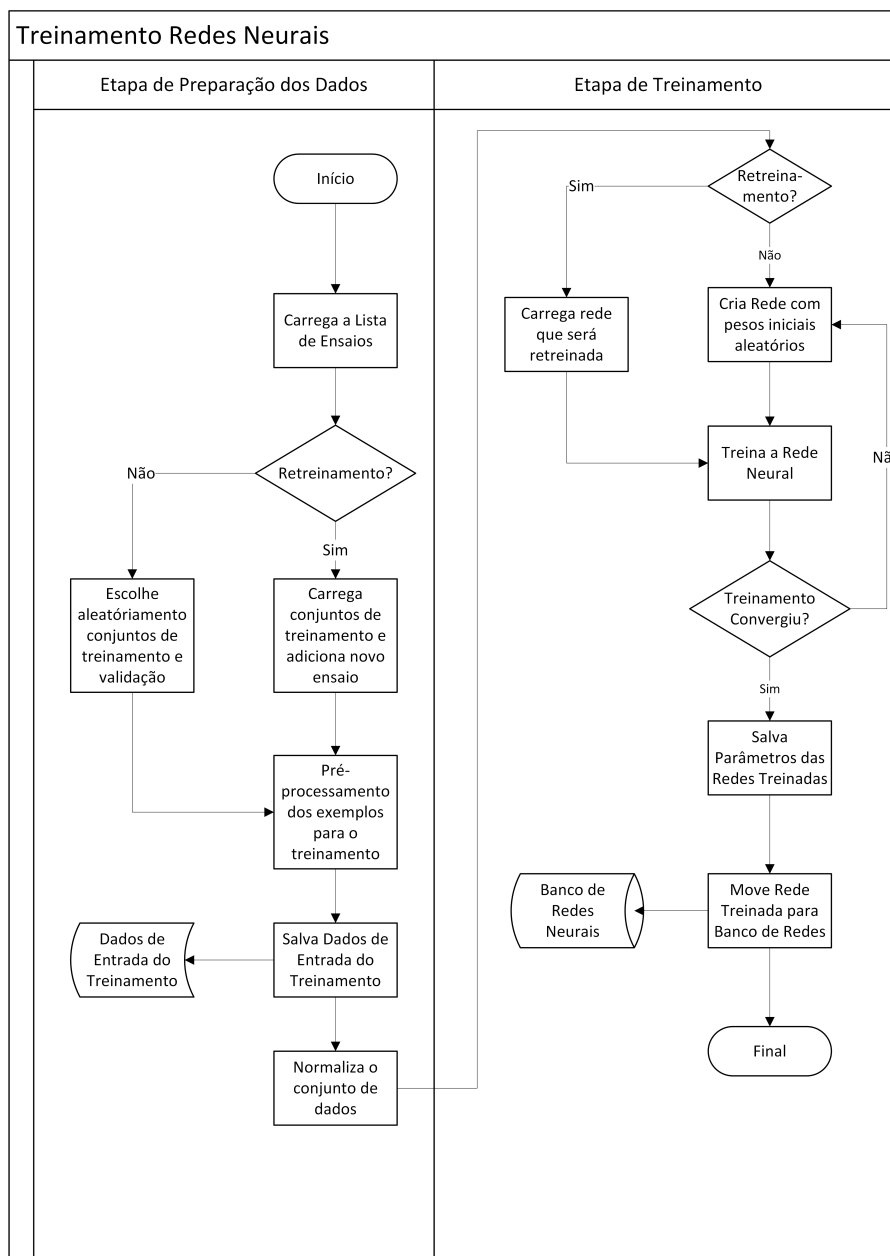


FIGURA 5.2: Algoritmo de treinamento das redes neurais.

outro conjunto. Para o retreinamento, pretende-se manter os conjuntos de treinamento e validação semelhantes, apenas adicionando novos exemplos aos conjuntos anteriores, para isso são carregados os conjuntos usados no treinamento anterior e é adicionado o novo ensaio a um dos conjuntos.

Com o conjunto de treinamento e validação definidos, é necessário realizar o pré-processamento dos ensaios para geração dos conjuntos de dados que irão alimentar o treinamento da rede. Esse pré-processamento consiste em várias etapas: identificação do instante real de entrada em regime permanente de cada ensaio; eliminação de pontos

espúrios (*outliers*); e processamento das diversas amostras para a obtenção das entradas da rede em cada instante do ensaio. O resultado desse procedimento é um conjunto de dados composto pelas entradas processadas das redes, que junto às saídas almejadas será usado no treinamento.

Posteriormente é realizada a normalização das variáveis, tanto dos valores mínimos e máximos, quanto do desvio padrão. Essa etapa é usada para que o conjunto de treinamento tenha média zero e desvio padrão unitário. Essa etapa é importante para que a rede compare os exemplos a partir da mesma ordem de magnitude, melhorando a capacidade de generalização.

Já na etapa de preparação do treinamento, é necessário inicializar os pesos da rede neural com valores não nulos. Nessa etapa é analisada a possibilidade de utilizar as redes previamente treinadas ao invés de pesos aleatórios na inicialização da rede. Essa alternativa é explorada com o intuito de acelerar a convergência do algoritmo, ao iniciar o treinamento em um mínimo local obtido para um conjunto de treinamento semelhante, e também buscar uma melhora no desempenho da rede, ao buscar a manutenção de parte do conhecimento que não está presente no conjunto de treinamento novo. Neste trabalho, a alternativa que utiliza uma rede previamente treinada como pesos iniciais do novo treinamento é denominada *retreinamento*.

A próxima etapa é o treinamento das redes neurais através do algoritmo de retropropagação. Esse treinamento tem, geralmente, custo computacional elevado, sendo demasiadamente demorado. Para o treinamento de um comitê, com diversas redes, esse tempo acaba aumentando linearmente com o número de redes. Caso o treinamento não convirja, ou seja, o algoritmo de treinamento não encontre uma rede com desempenho apropriado para o conjunto de treinamento, são repetidas as etapas de inicialização da rede, nesse caso usando pesos iniciais aleatórios, e posteriormente é realizado o treinamento.

Com o treinamento finalizado, são salvos os pesos da rede neural treinada, para uso no software de geração de inferências e prognóstico. São salvos adicionalmente, os parâmetros usados na etapa de normalização, já que os ensaios que serão testados necessitam passar pela mesma normalização para o correto funcionamento da rede neural.

Para avaliar o método de retreinamento foram propostas duas estratégias que usam uma mescla de exemplos antigos com os padrões novos, buscando avaliar o impacto do aumento do número de ensaios no conjunto de treinamento comparado com um conjunto fixo de treinamento. Essas estratégias são mostradas na figura 5.3.

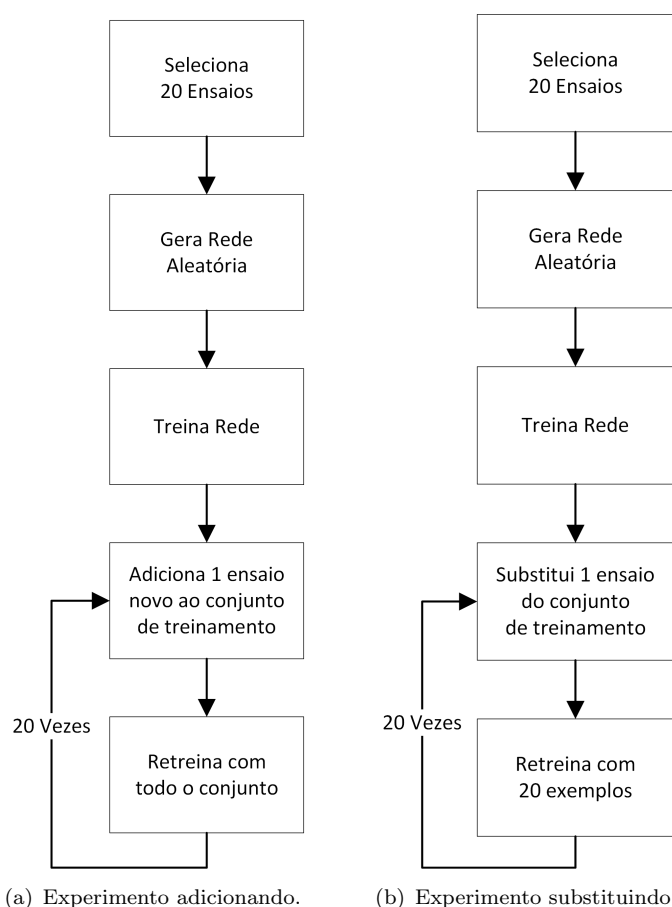


FIGURA 5.3: Experimentos para avaliação do retreinamento de redes neurais.

Na estratégia mostrada na figura 5.3(a) é realizado um treinamento de uma rede, a partir de pesos iniciais aleatórios, usando 20 ensaios. Após, foram realizados 20 retreinamentos, sendo que em cada um deles foi adicionado 1 novo exemplo ao conjunto de treinamento, o que resultou na utilização de 40 ensaios para o retreinamento da última rede. Para cada retreinamento foram usados como pesos iniciais os pesos da rede obtida na etapa anterior. Na estratégia mostrada na figura 5.3(b), foi realizado o mesmo treinamento inicial, com 20 exemplos, e, posteriormente, foram realizados 20 retreinamentos, dessa vez substituindo 1 ensaio de cada vez, o que resultou em um conjunto de treinamento com tamanho constante.



### 5.3 Resultados

Através da implementação de algoritmos de retreinamento para os comitês de redes neurais, tanto de inferência, quanto de prognóstico, buscou-se observar a eficácia do método na tarefa de absorver conhecimento novo e exploraram-se as variações possíveis nos métodos.

Por motivos de simplicidade na análise optou-se pela validação dos métodos usando apenas uma rede neural, análise que pode ser facilmente estendida para um comitê. Inicialmente foi validada a utilização da rede já treinada como rede inicial no retreinamento, observando se existe melhorias no tempo de treinamento. Todos os treinamentos foram realizados para a rede de prognóstico da capacidade de refrigeração.


Foram realizados 5 treinamentos, com 20 ensaios cada, a partir de pesos iniciais aleatórios. Foram usados sempre os mesmos ensaios, mudando apenas os pesos iniciais. Adicionalmente, foram realizados 5 retreinamentos, com 20 ensaios, a partir de redes treinadas previamente. Essas redes, treinadas previamente, utilizaram 19 ensaios cada. Com isso, pretendia-se avaliar a melhoria no tempo de treinamento.

Na tabela 5.1 são apresentados os tempos de treinamento para os dois métodos testados. É possível observar que no treinamento a partir de pesos iniciais aleatórios o número de iterações (épocas) do algoritmo de otimização dos pesos até a convergência é relativamente grande, demandando tempos na ordem de minutos. Já, quando o treinamento parte de pesos iniciais obtidos de uma rede treinada, o algoritmo demora um tempo substancialmente menor, na ordem de segundos, mostrando que a utilização dos pesos da rede previamente treinada como pesos iniciais do retreinamento é mais eficiente em termos de tempo de processamento.

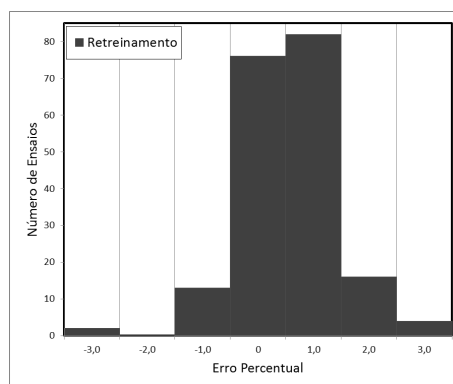
Número	Treinamento		Retreinamento	
	Épocas	Tempo [min:s]	Épocas	Tempo [min:s]
1	4370	07:04	132	00:13
2	3840	06:16	319	00:31
3	2380	03:46	143	00:13
4	1320	02:01	69	00:07
5	3025	04:41	91	00:09

TABELA 5.1: Tempo demandado pelo algoritmo de treinamento.


As redes obtidas nas duas estratégias de retreinamento, mostradas na seção 5.2, foram testadas no software de geração de inferências e prognósticos, para quantificar melhorias no desempenho ou comparar as duas metodologias. O conjunto de teste contendo 201 ensaios foi utilizado e os resultados são mostrados em forma de histogramas de erro percentual na figura 5.4. São mostrados os resultados para a rede treinada originalmente e após os 20 retreinamentos, para ambos os experimentos.



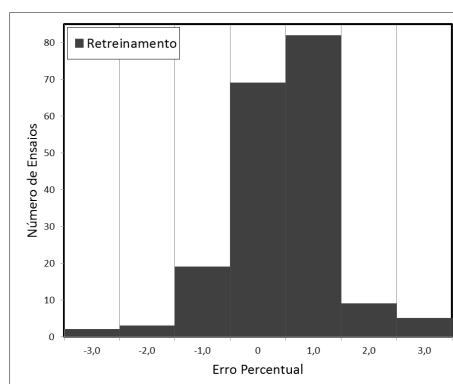
(a) Erro percentual para o treinamento adicionando exemplos.



(b) Erro percentual para o retreinamento adicionando exemplos.



(c) Erro percentual para o treinamento substituindo exemplos.



(d) Erro percentual para o retreinamento substituindo exemplos.

FIGURA 5.4: Histograma do erro percentual para a avaliação do retreinamento de redes neurais.

Os histogramas do erro percentual após retreinamentos para ambas estratégias mostraram tendência de melhora comparados ao histograma do treinamento inicial. Esse comportamento era esperado, já que o processo de retreinamento busca agregar conhecimento novo ao sistema. É interessante comparar o resultado final dos retreinamentos entre os dois experimentos, já que procura-se comparar o desempenho dos métodos.

É possível notar pelos histogramas na figura 5.4(b) e figura 5.4(d) que os métodos de retreinamento apresentam resposta semelhante, sendo, inclusive, difícil avaliar qual

dos experimentos de retreinamento apresentou melhor resposta. É interessante o fato de termos uma rede treinada com um número menor de ensaios, obtendo desempenho semelhante a uma com o dobro de ensaios usados no treinamento. Isso evidencia a eficácia do método de retreinamento, já que ao usarmos a rede treinada anteriormente e um conjunto de ensaios com uma mescla de padrões antigos e novos, foi obtida uma rede que incorporou o conhecimento de ambos os padrões. Esse resultado é interessante, pois a utilização de um conjunto de treinamento variável traz junto o problema do aumento do custo computacional, que em algum instante inviabilizaria o treinamento. Dessa forma, conclui-se que é possível agregar conhecimento novo à rede através de retreinamentos usando conjuntos de treinamento com um misto de ensaios antigos e novos, o que resulta na manutenção de parte do conhecimento adquirido em aprendizados anteriores.



## Capítulo 6

# Considerações Finais

Este trabalho teve como objetivos a implementação de ferramentas de inteligência artificial para geração de inferências e prognósticos em ensaios energéticos de compressores herméticos de refrigeração. Diversas ferramentas foram adicionadas ao *software* de inteligência artificial que fará parte da bancada de ensaios, entre elas: suporte a banco de dados de valores típicos para as variáveis de interesse em ensaios de desempenho energético; comitês de redes neurais, substituindo tanto a rede neural para inferência de regime permanente, quanto a rede neural para prognóstico da capacidade de refrigeração. Foi desenvolvida, adicionalmente, ferramenta para o acompanhamento da dinâmica da resposta do comitê de redes neurais, possibilitando melhorias na inferência de regime permanente. Por fim, foram estudados métodos para atualização das redes neurais e proposta uma arquitetura para o acompanhamento do desempenho das ferramentas de inteligência artificial e métodos de atualização das mesmas.

A atualização do software obteve os resultados esperados, resultando em uma melhora sensível na qualidade das inferências e prognósticos. O sistema de geração de inferências apresentou melhora significativa, decorrente principalmente do comitê de redes neurais, fazendo com que o sistema apresentasse resposta para um número maior de casos, aumentando o número de ensaios com inferência de 85% para 99%. Verificou-se também uma melhora significativa na qualidade dos prognósticos em relação ao número de ensaios dentro da faixa considerada, cerca de 25%.

A ferramenta de acompanhamento da dinâmica da resposta do comitê de redes mostrou resultado promissor, melhorando a qualidade da inferência em alguns ensaios problemáticos, que apresentavam erros significativos anteriormente.

O estudo das técnicas de atualização para as redes neurais mostrou a necessidade de estabelecer métodos para o acompanhamento do desempenho das ferramentas de inferência e prognóstico. A estratégia para retreinamento mostrou eficácia, carecendo de mais testes, com um conjunto de teste mais amplo e representativo do problema. Apesar disso, mostrou-se adequada à tarefa de agregar informação nova às ferramentas.

O software desenvolvido neste trabalho propiciará a implementação dessas ferramentas em bancadas de ensaio reais e melhor avaliação das soluções desenvolvidas nessa linha de pesquisa. Com isso, será possível observar o comportamento do *software* com o tempo, gerando informações importantes para o desenvolvimento de soluções para a atualização automática das ferramentas.

Para o aprimoramento deste trabalho é sugerida a continuação do desenvolvimento do sistema de acompanhamento de desempenho das ferramentas e atualização automática. Para a obtenção de um sistema completo, capaz de atualizar automaticamente o sistema, é necessário o desenvolvimento de ferramentas para identificação automática de ensaios de desempenho típicos, para a geração autônoma de conjuntos de treinamento para a avaliação do desempenho *online* dos comitês de redes neurais.

A ferramenta de acompanhamento da dinâmica se mostrou promissora pois agrega informações. Sugere-se um estudo da utilização de informações acerca da probabilidade de indicação de regime para cada rede neural do comitê, agregando informações adicionais a essa ferramenta. Isso pode levar essa ferramenta a, inclusive, suplantando a utilização do conjunto de regras, deixando de ser uma ferramenta auxiliar, passando a realizar toda a tarefa de integração da resposta do comitê de redes.

# Referências

- [1] PENZ, C. A. **Desenvolvimento de recursos para prover confiabilidade ao uso de inteligência artificial em ensaios de desempenho de compressores herméticos de refrigeração.** Tese (Doutorado em Engenharia Mecânica) - Programa de Pós-graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina, 2011.
- [2] HENKLEIN, P. **Análise de ensaios de desempenho de compressores herméticos durante o transitório.** Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, 2006.
- [3] SMOLA, A.; VISHWANATHAN, S. V. N. **Introduction to machine learning,** Cambridge University Press, Santa Clara, 2008.
- [4] HAYKIN, S. **Redes neurais.** Princípios e práticas, Bookman, Porto Alegre, 2001.
- [5] BEALE, M; DEMUTH, H. **Neural network toolbox.** For use with MATLAB. The MathWorks, 2004.
- [6] LIMA, V. R. **Desenvolvimento e Avaliação de Sistema Neural para Redução de Tempo de Ensaio de Desempenho de Compressores.** Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, 2010.
- [7] LACERDA, A. Globalização e o brasil: riscos, oportunidades e desafios. **Revista de Economia e Relações Internacionais,** FAAP, 2002.

- 
- [8] ISO - International Organization for Standardization. ISO 917: Testing of refrigerant compressors.
- [9] BARBOSA, .F Q. **Redução das Incertezas nas Medições de Grandezas Elétricas em uma Bancada de Ensaios de Desempenho de Compressores**. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, 2006.
- [10] FLESCHE, R. C C. **Desenvolvimento e Instalação de Recursos de Automação Aplicados a Ensaios de Compressores de Refrigeração da Embraco**. Monografia (Curso de Engenharia de Controle e Automação), 2006.
- [11] POLETTI, 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) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, 2006.
- [12] SCUSSEL, J. N. **Propostas de ações para reduzir o tempo demandado por ensaio de desempenho de compressores herméticos**. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, 2006.
- [13] PETROVIC, S. A. B. **Proposta de arquitetura do sistema de automação aplicado a ensaios de desempenho de compressores herméticos de refrigeração**. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, 2007.
- [14] FLESCHE, R. C. C.; NORMEY-RICO, J. E. **Modelling, Identification and control of a calorimeter used for performance evaluation of refrigerant compressors**. Control Engineering Practice, 2010.



- [15] STEINBACH K. **Identificação do instante de entrada em condição de regime permanente em ensaios de desempenho de compressores.** Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, 2008.
- [16] CASELLA, A. V. **Ferramenta *fuzzy*-bayesiana para identificação do instante de entrada no regime permanente em ensaios de desempenho de compressores.** Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, 2008.
- [17] Engenharia de Controle e Automação, Disponível em: <<http://automacao.ufsc.br/course>>, Acesso em: 22 jul. 2015.
- [18] WANG, S. K. **Handbook of air conditioning and refrigeration,** McGraw-Hill, New York, 2000.
- [19] STOECKER, W. F.; SAIZ JABARDO, J. M. **Refrigeração Industrial,** Edgard Blücher, 2009.
- [20] FLESCHE, R. C. C. **Contribuições ao Controle de Sistemas Monovariáveis e Multivariáveis com Atraso de Transporte.** Tese (Doutorado em Engenharia de Automação e Sistemas) - Programa de Pós-graduação em Engenharia de Automação e Sistemas, Universidade Federal de Santa Catarina, 2011.
- [21] LOPES, R. H. C.; TARVER, M. Inducing theorem provers from proofs. **Tools with Artificial Intelligence,** 1997. Proceedings., Ninth IEEE International Conference on, 1997.
- [22] HEDBERG, S. Smart games: beyond the deep blue horizon. **IEEE Expert,** 1997.
- [23] POMERLEAU, D. A. Progress in neural network-based vision for autonomous robot driving. **Intelligent Vehicles '92 Symposium,** Proceedings of the, 1992.

- 
- [24] GERMAN, O. A fuzzy expert systems design for diagnosis of parkinson's disease. **E-Health and Bioengineering Conference (EHB)**, 2008.
- [25] NORVIG, P.; RUSSEL, S. **Artificial intelligence**. a modern approach, Pearson, New Jersey, 2009.
- [26] BISHOP, P. M. **Pattern recognition and machine learning**, Springer, 2007.
- [27] BITTENCOURT, G. **Inteligência artificial**. ferramentas e teorias, Editora da UFSC, Florianópolis 2006.
- [28] PFEIFER, R.; SCHEIER, C. **Understanding intelligence**, The MIT Press, Cambridge 1999.
- [29] RUMELHART, D. E.; HINTON, G. E.; WILLIAMS R. J. Learning internal representations by backpropagating errors. **Nature**, 1986.
- [30] ROBINS, A. Sequential learning in neural networks: A review and a discussion of pseudorehearsal based methods. **Intelligent Data Analysis**, 2004.
- [31] FRENCH, R. M. Catastrophic forgetting in connectionist networks: Causes, consequences and solutions. **Trends in Cognitive Sciences**, 1999.
- [32] TRESP, V. **Committee Machines**. Handbook for Neural Network Signal Processing, CRC Press, 2001.
- [33] National Instruments Corporation. **LabVIEW User Manual**, National Instruments Corporation, 2001.