

DAS Departamento de Automação e Sistemas
CTC **Centro Tecnológico**
UFSC Universidade Federal de Santa Catarina

Técnicas de Inteligência Artificial para Inferência e Prognóstico em Ensaios de Compressores

*Relatório submetido à Universidade Federal de Santa Catarina como
como requisito para a aprovação da disciplina:*

DAS 5511: Projeto de Fim de Curso

Marcelo Sousa Menegol

Florianópolis, setembro de 2015

Técnicas de Inteligência Artificial para Inferência e Prognóstico em Ensaios de Compressores

Marcelo Sousa Menegol

Esta monografia foi julgada no contexto da disciplina
DAS 5511: Projeto de Fim de Curso
e aprovada na sua forma final pelo
Curso de Engenharia de Controle e Automação

Prof. Marcelo Ricardo Stemmer, Dr. Eng.

Banca Examinadora:

Eng. João Paulo Rosseto

Orientador na empresa

Prof. Marcelo Ricardo Stemmer

Orientador no curso

Prof. Carlos Montez

Avaliador

Marcus Aurélio Tavares

Heron Monteiro

Debatedores

Agradecimentos

Agradeço aos meus pais, Osmar e Rita de Cássia, que me apoiaram tanto nesta trajetória até aqui, e ao meu irmão Matheus, que tanto me influenciou a sempre ir adiante.

Ao professor Marcelo Ricardo Stemmer pela orientação e ajuda.

À Embraco, ao Labmetro / LIAE e ao engenheiro João Paulo Rosseto, pela supervisão, oportunidade e fomento.

A Cesar Penz, Ahryman Nascimento e Bernardo Schwedersky pela tutoria e por me ajudar a formular minhas ideias e validar meus conhecimentos durante a execução do projeto.

A todos meus amigos, que ao longo dos anos contribuíram para fazer de mim quem hoje sou e me deram suporte para chegar até aqui.

Resumo

Técnicas de inteligência artificial têm sido amplamente usadas no mundo inteiro para resolver os mais variados problemas. Um problema muito comum é o de se prever o comportamento de sistemas, e existem abordagens de *Machine Learning* muito apropriadas para lidar com estes tipos de problema. O prognóstico de variáveis de interesse em ensaios de desempenho de compressores de refrigeração é um desses problemas, e redes neurais é uma das abordagens usadas.

Várias pesquisas já comprovaram que sistemas neurais podem fazer o prognóstico de grandezas como: capacidade de refrigeração, consumo energético e coeficiente de desempenho. O prognóstico feito, em testes, tem uma taxa de erro baixa o suficiente para ser utilizado em ensaios reais de compressores. Estes sistemas de prognósticos, assim, reduzem o tempo dos ensaios (de 4 ou 5 horas para cerca de 1 hora), levando a ganhos de produtividade muito significativos na indústria.

Mesmo que ganhos já tenham sido alcançados, a busca incessante por soluções ainda melhores não para. O sistema utilizado atualmente pela Embraco emprega um comitê de redes neurais para realizar este prognóstico. Este trabalho propõe e testa outras formas diferentes de se combinar a resposta dos integrantes deste comitê para se obter o prognóstico do valor final dos ensaios.

Além disso, uma outra abordagem, baseada em redes neurais recorrentes, é proposta e testada. Para se criar este novo sistema, além das próprias redes neurais treinadas, utiliza-se técnicas de "clusterização" para se classificar e organizar os dados utilizados para o treinamento das redes neurais.

Palavras-chave: Redes Neurais Recorrentes. Compressores. Prognóstico. Refrigeração.

Abstract

Artificial intelligence techniques have been broadly used world-wide to solve various problems. A very common problem is the one to predict the behaviour of systems, and there are various *Machine Learning* approaches that are appropriate to deal with such problems. The prognosis of interest variables in performance tests of refrigeration compressors is one of those problems, and recurrent neural networks is one of the approaches used.

Various researches have proven that neural systems can do the prognosis of variables such as: refrigeration capacity, energy consumption and performance coefficient. The prognosis done, in tests, have an error rate low enough to be used in real compressors' tests. These prognosis' systems reduce the tests' time (from 4 or 5 hours to around 1 hour), leading to very significant productivity gains in the industry.

Although those gains have been reached, the incessant search for even better solutions doesn't stop. The system currently used at Embraco uses an ensemble of neural networks to do the prognosis. This work proposes and tests different ways of combining the result given by the members of this ensemble in order to obtain the prognosis of the final value of the tests.

Moreover, another approach, based on recurrent neural networks, is proposed and tested. To create this new system, besides the trained neural networks, clustering techniques are used to classify and organize the data used to train the neural networks.

Keywords: Recurrent Neural Networks. Compressor. Refrigeration. Prognosis.

Lista de ilustrações

| | |
|---|----|
| Figura 1 – Circuito de Refrigeração. Adaptado de [1] | 18 |
| Figura 2 – Compressor hermético. Adaptado de [2] | 18 |
| Figura 3 – Diagrama da bancada de ensaios | 20 |
| Figura 4 – Diagrama simplificado do calorímetro a seco [3]. | 21 |
| Figura 5 – Modelo básico de neurônio [4]. | 25 |
| Figura 6 – Funções de ativação comumente usadas. Adaptado de [5]. | 26 |
| Figura 7 – Redes neurais <i>feedforward</i> e recorrente. Adaptado de [6]. | 26 |
| Figura 8 – Clusterização. A esquerda, <i>cluster</i> não classificado. A direita, <i>cluster</i> dividido em dois grupos. Adaptado de [7] | 30 |
| Figura 9 – Erro percentual de inferência de cada método de comitê. | 38 |
| Figura 10 – Erro percentual de prognóstico de cada método de comitê. | 38 |
| Figura 11 – Número de ensaios nos quais não foi possível fazer o prognóstico, com cada método de comitê | 39 |
| Figura 12 – Tempo médio para o prognóstico em minutos, para cada métodos de comitê. | 39 |
| Figura 13 – Ensaio com comportamento inicial não desejado. Amostras a cada 10 segundos. | 43 |
| Figura 14 – Diagrama de funcionamento de programa de busca de topologias de redes neurais. | 44 |
| Figura 15 – Ensaio dos grupos de treinamento 1 a 5, da esquerda para a direita e de cima para baixo. | 46 |
| Figura 16 – Diagrama da rede NAR, em malha fechada. | 47 |
| Figura 17 – Diagrama da rede de atraso temporal. | 47 |
| Figura 18 – Diagrama ilustrativo do funcionamento do sistema de prognóstico. . . . | 48 |
| Figura 19 – Erro médio e desvio padrão de prognóstico do valor final em diferentes tempos de prognóstico da dinâmica. | 49 |
| Figura 20 – Histograma do erro de prognóstico do valor final. | 50 |

Lista de tabelas

| | |
|--|----|
| Tabela 1 – Arquitetura das redes neurais para inferência de regime permanente . . | 34 |
| Tabela 2 – Entradas das redes neurais de inferência do regime | 34 |
| Tabela 3 – Relação entre quantidade de redes e tempo de espera | 35 |
| Tabela 4 – Arquitetura das redes neurais para prognóstico do valor final | 35 |
| Tabela 5 – Entradas das redes neurais de prognóstico | 35 |
| Tabela 6 – Resultado dos testes - GEM | 36 |
| Tabela 7 – Resultado dos testes - CEM | 37 |
| Tabela 8 – Resultado dos testes - média simples | 37 |
| Tabela 9 – Resultado dos testes - conjunto de regras | 37 |
| Tabela 10 – Parâmetros topológicos das redes de prognóstico da dinâmica | 45 |
| Tabela 11 – Parâmetros topológicos da rede de prognóstico do valor final | 45 |
| Tabela 12 – Número de ensaios por grupo de treinamento. | 45 |
| Tabela 13 – Topologia das redes de prognóstico da dinâmica. | 46 |
| Tabela 14 – Topologia das redes de prognóstico do valor final. | 47 |
| Tabela 15 – Incerteza da medição na validação de ganhos de desempenho. Adaptado de [3]. | 51 |

Sumário

| | | |
|------------|--|-----------|
| 1 | INTRODUÇÃO | 13 |
| 1.1 | Contextualização | 13 |
| 1.2 | Objetivo | 14 |
| 1.2.1 | Objetivo Geral | 14 |
| 1.2.2 | Objetivos Específicos | 15 |
| 1.2.3 | Resultados Esperados | 15 |
| 1.2.4 | Relação do Projeto com a Engenharia de Controle e Automação | 15 |
| 1.3 | Estrutura do Documento | 15 |
| 2 | ENSAIOS DE DESEMPENHO DE COMPRESSORES PARA REFRI- GERAÇÃO | 17 |
| 2.1 | O Circuito de Refrigeração e Compressores Herméticos | 17 |
| 2.2 | Ensaio de Desempenho de Compressores | 18 |
| 2.3 | Bancada de Ensaio de Desempenho | 19 |
| 3 | TÉCNICAS DE IA | 23 |
| 3.1 | Inteligência Artificial | 23 |
| 3.2 | Redes Neurais | 24 |
| 3.2.1 | Modelo do Neurônio | 24 |
| 3.2.2 | Arquiteturas de Redes Neurais | 25 |
| 3.2.3 | Redes Neurais Recorrentes | 26 |
| 3.2.4 | Aprendizado de Redes Neurais | 27 |
| 3.2.5 | Comitês de Redes Neurais | 28 |
| 3.3 | Clusterização | 29 |
| 3.3.1 | k-Means | 30 |
| 4 | TESTE DE MÉTODOS DE COMITÊ DE REDES NEURAIS | 33 |
| 4.1 | Sistema atual de inferência e prognóstico | 33 |
| 4.1.1 | Comitê de redes para inferência de regime permanente | 33 |
| 4.1.2 | Comitê de redes para prognóstico do valor final | 35 |
| 4.2 | Resultados dos testes | 36 |
| 5 | SISTEMA COM REDES NEURAIS RECORRENTES PARA PROG- NÓSTICO DO VALOR FINAL | 41 |
| 5.1 | Pré-processamento das entradas | 42 |
| 5.2 | Topologia das redes recorrentes | 43 |

| | | |
|-----|---|-----------|
| 5.3 | Estrutura do comitê de prognóstico da dinâmica | 45 |
| 5.4 | Treinamento do comitê de prognóstico da dinâmica | 46 |
| 5.5 | Treinamento de rede de prognóstico do valor final | 47 |
| 5.6 | Teste do sistema de prognóstico | 48 |
| 6 | CONCLUSÕES E OPORTUNIDADES FUTURAS | 51 |
| 6.1 | Técnicas de comitê | 51 |
| 6.2 | Redes Neurais Recorrentes para prognóstico de ensaios | 52 |
| 6.3 | Aprendizado no projeto | 53 |
| | REFERÊNCIAS | 55 |

1 Introdução

1.1 Contextualização

Sistemas de refrigeração já estão amplamente difundidos na sociedade atual, tanto no âmbito residencial quanto industrial: refrigeradores domésticos¹, condicionadores de ar, câmaras frias, entre outros. Como a maioria destes sistemas possui um ou mais compressores, torna-se evidente a alta demanda por este equipamento.

Com a globalização, algumas empresas fabricantes deste produto passaram a internacionalizar sua produção e venda para poderem atender melhor a demanda mundial e aumentarem a competitividade. A Whirlpool S.A. - Unidade Embraco é uma delas. A forte competitividade no setor leva os fabricantes a melhorar cada vez mais seus produtos. Para garantir a qualidade dos compressores, bem como validar melhorias feitas, um procedimento de testes de compressores eficiente é necessário.

Conforme aprimoramentos sucessivos são feitos (em busca do aumento da qualidade), as diferenças de desempenho entre um modelo e outro tornam-se cada vez menores. Logo, os procedimentos de testes para estes produtos precisam de uma incerteza de medição compatível. Ainda, devido à incessante busca por agilidade na produção, o tempo demandado pelos ensaios deve ser reduzido.

Os ensaios para avaliação de desempenho de compressores de refrigeração ficam cerca de 3 horas em regime transitório. Como a norma ISO 917 requer que o compressor fique ao menos 1 hora em regime permanente para que medições possam ser feitas, o tempo médio de ensaio é de 4 horas. Dado o grande volume da produção de empresas como a Whirlpool S.A., ensaios desta duração podem ser muito danosos à produtividade.

Para se reduzir a duração destes ensaios e sua incerteza de medição, várias melhorias foram aplicadas nos processos de ensaio da Whirlpool S.A. - Unidade Embraco ao longo do tempo. Melhorias estas que foram fruto da parceria desta com o Labmetro - Laboratório de Metrologia e Automatização da Universidade Federal de Santa Catarina.

Os trabalhos desenvolvidos pelo Labmetro desde o início da parceria levaram a reduções expressivas da duração média dos ensaios. Em média, as reduções foram de cerca de 50% [3]. Melhorias dos equipamentos na bancada de ensaio, uso de processos de medição excelentes e de técnicas avançadas de controle são responsáveis por tais resultados.

Para se reduzir ainda mais os tempos de ensaios, procurou-se outras ferramentas que pudessem realizar inferência e prognóstico de grandezas relevantes dos compressores

¹ 95,75% dos domicílios brasileiros possuíam ao menos uma geladeira em 2011 [8].

herméticos. Em especial, técnicas de inteligência artificial apresentaram resultados promissores. Estas técnicas, ao avaliar o comportamento transitório do ensaio, conseguem estimar valores de interesse com erro relativamente baixo.

O primeiro uso destas técnicas para este propósito foi apresentado por Henklein [2]. Redes neurais e lógica *fuzzy* foram utilizadas para se fazer o prognóstico do desempenho energético. Em seguida, Steinbach [9] explorou redes neurais para se realizar o prognóstico da capacidade de refrigeração, potência elétrica ativa consumida e coeficiente de desempenho.

Em seguida, redes fuzzy-bayesianas foram exploradas, por Casella [10], para se analisar o grau de assentamento dos ensaios a partir do instante de entrada em regime permanente da capacidade de refrigeração. Penz [3] então estudou a utilização de comitês de redes neurais, junto com uma rede fuzzy-bayesiana, para se aumentar a confiabilidade das inferências e prognósticos.

Porém, por mais confiáveis que os prognósticos sejam, eles nunca são tão bons quanto a medição direta feita em um ensaio completo. Assim, vários ensaios de curta duração, utilizando essas técnicas, podem ser necessários para validar um resultado que necessitaria de menos ensaios completos, com maior confiabilidade [3]. Mesmo assim, se o tempo total dos vários ensaios curtos somados for menor do que o de poucos ensaios longos, a ferramenta cumpre seu papel final.

Percebe-se, então, que é necessário se achar um equilíbrio entre tempo de execução da ferramenta e confiabilidade do resultado. Procedimentos de teste lentos, mesmo que com baixa incerteza, podem levar a uma diminuição na produtividade. Procedimentos rápidos, porém incertos, fazem com que um mesmo teste tenha que ser repetido várias vezes para se validar resultados, o que também acarreta na diminuição da produtividade.

Para se estabelecer meios mais eficientes, outros métodos de inteligência artificial foram explorados no intuito de se melhorar os meios já existentes ou propor meios potencialmente melhores, levando em consideração o equilíbrio entre tempo e confiabilidade. Em específico, diferentes métodos de se combinar a resposta de comitês de redes neurais foram explorados, no intuito de se melhorar o que já foi feito, e técnicas envolvendo redes neurais recorrentes foram testadas, buscando se propor um meio potencialmente mais eficiente.

1.2 Objetivo

1.2.1 Objetivo Geral

Pesquisar e testar diferentes técnicas de inteligência artificial para inferência e prognóstico de características de desempenho, aplicada a ensaios de compressores de

refrigeração, em bancadas de teste e avaliação.

1.2.2 Objetivos Específicos

- Pesquisar diferentes técnicas de inteligência artificial que possam ser aplicadas em problemas de inferência e prognóstico de sistemas dinâmicos.
- Propor métodos de se aplicar as técnicas estudadas para inferência e prognóstico de ensaios de compressores de refrigeração.
- Testar e validar as técnicas propostas.

1.2.3 Resultados Esperados

Ao fim do projeto, espera-se obter resultados que indiquem o potencial de diferentes técnicas de inteligência artificial na inferência e prognóstico em ensaios de compressores de refrigeração.

1.2.4 Relação do Projeto com a Engenharia de Controle e Automação

Apesar de os métodos serem estudados no âmbito de compressores herméticos, as técnicas apresentadas de inferência e prognóstico são extrapoláveis para outros sistemas dinâmicos. Inferência de parâmetros de sistemas dinâmicos se mostra muito útil em áreas como identificação de sistemas (inferência de características de um sistema a partir de informações limitadas) e controle preditivo (predição do comportamento de um sistema). Além disso, por se tratar de inteligência artificial, conhecimentos de informática são indispensáveis para o andamento deste projeto.

1.3 Estrutura do Documento

No capítulo 2 são apresentados os conceitos básicos necessários acerca do ensaio de compressores herméticos necessários para o melhor entendimento do problema.

No capítulo 3 são apresentados conceitos básicos de inteligência artificial, com ênfase nas ferramentas exploradas neste trabalho.

No capítulo 4 se apresenta diferentes métodos de comitê de classificadores, uma proposta de alteração da ferramenta já existente de inferência e prognóstico, bem como resultados que mostram as forças e fraquezas de cada método.

No capítulo 5 se apresenta um novo métodos de inferência e prognóstico, baseado em redes neurais recorrentes, bem como resultados que atestam as forças e fraquezas do método proposto. Um comparativo é feito com a ferramenta vigente.

No capítulo 6 são apresentadas as considerações finais e as perspectivas para trabalhos futuros.

2 Ensaaios de Desempenho de Compressores para Refrigeração

Este capítulo apresenta alguns conceitos relacionados a sistemas de refrigeração e seus compressores. Foca-se em ensaios de desempenho destes compressores, bem como os procedimentos relacionados. A bancada de ensaios também é descrita.

2.1 O Circuito de Refrigeração e Compressores Herméticos

Refrigeração é definida como o processo de se extrair calor de uma fonte de calor de temperatura mais baixa e transferi-lo para um dissipador de calor de maior temperatura. Refrigeração mantém a temperatura da fonte de calor abaixo daquela de suas redondezas, transferindo o calor extraído para o ar atmosférico ou outro dissipador de calor [11]. Para se realizar este trabalho, uma fonte externa de energia é necessária. Tipicamente, esta é a rede elétrica.

Um circuito de refrigeração consiste em um conjunto de equipamentos que, quando em funcionamento, executam a refrigeração de um ambiente [12]. Estes componentes são: compressor, condensador, dispositivo de expansão, evaporador e tubulação (Figura 1).

O meio de transporte da energia entre os trocadores de calor é o refrigerante, que é movido através do circuito pelo compressor. Na Figura 1, o fluido se move no sentido 1-2-3-4-1. No ponto 1, o fluido é um gás superaquecido. Ele então passa pelo condensador, perdendo calor (que é transferido para o meio externo) e torna-se um líquido sub-resfriado quando chega no ponto 2.

O líquido passa então pelo dispositivo de expansão, que diminui sua pressão e torna-se um líquido superaquecido no ponto 3. Neste estado, o fluido precisa de quantidades mínimas de calor para se tornar vapor. Assim, quando passa pelo evaporador, o líquido retira calor do meio a ser resfriado e passa para o estado de vapor superaquecido no ponto 4. Em seguida, o vapor é aspirado e comprimido pelo compressor. O ciclo então se repete.

Os compressores para pequenas capacidades (utilizados em refrigeradores domésticos, condicionadores de ar, etc.) possuem suas partes, bem como o óleo de lubrificação, envolvidas por um envólucro hermeticamente selado (compressor hermético).

Os compressores envolvidos neste trabalho são herméticos, de estágio simples, com apenas um pistão e um cilindro, de deslocamento positivo (Figura 2).

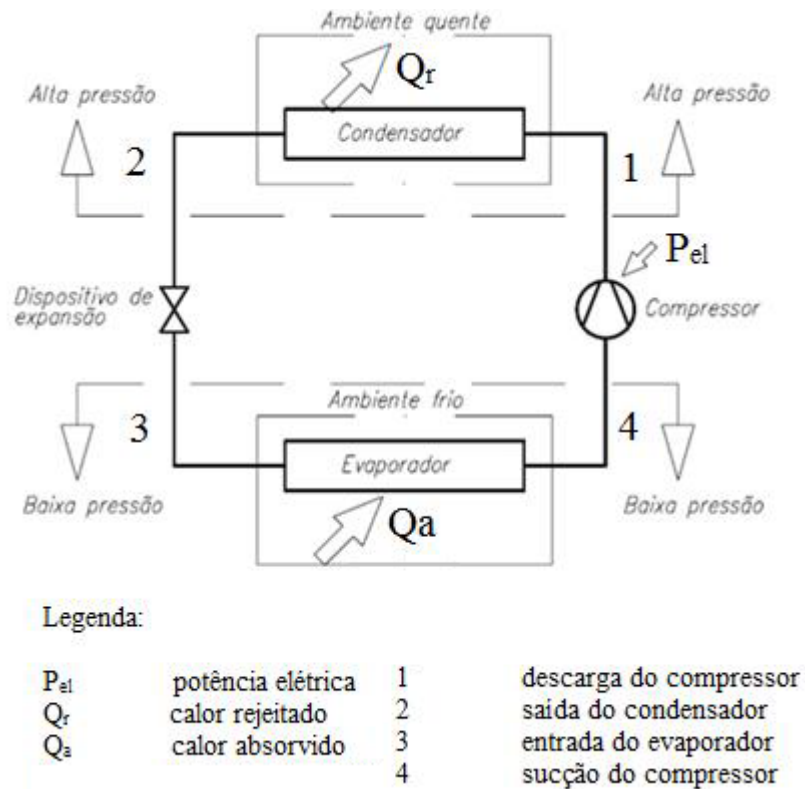


Figura 1 – Circuito de Refrigeração. Adaptado de [1]




Figura 2 – Compressor hermético. Adaptado de [2]

2.2 Ensaio de Desempenho de Compressores

Este trabalho lida em específico com os ensaios descritos pela norma "ISO 917 - *Testing of refrigerant compressors*" [13]. Esta norma estabelece procedimentos padrões para a determinação de características de compressores [2], como capacidade de refrigeração, potência elétrica ativa consumida e coeficiente de desempenho (sob condições pré-determinadas). Determinar as grandezas supracitadas pode ser útil para: controle de

qualidade, comparação de produtos diferentes, projeto de diferentes produtos.

A capacidade de refrigeração de um compressor, expressa em watt, advem do produto da vazão mássica de refrigerante pelo compressor; a razão entre os volumes específicos do refrigerante durante o ensaio e o estabelecido anterior ao ensaio; e a diferença entre a entalpia específica do fluido refrigerante ao entrar no compressor e ao sair do compressor [13]. Capacidade de refrigeração é uma medida da capacidade do compressor de gerar vazão mássica do fluido refrigerante quando sob um diferencial de pressão entre sucção e descarga do compressor [12]. Matematicamente, esta relação é expressa pela Equação 2.1.

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

Tal que:

| | | |
|----------|--|----------------------|
| ϕ | capacidade de refrigeração do compressor | [W] |
| q_{mf} | vazão mássica do fluido refrigerante | [kg/s] |
| V_{ga} | volume específico do fluido refrigerante na entrada do compressor, durante o ensaio | [m ³ /kg] |
| V_{gl} | volume específico do fluido refrigerante na entrada do compressor, estabelecido anterior ao ensaio | [m ³ /kg] |
| h_{g1} | entalpia específica do fluido refrigerante na entrada do compressor, durante ensaio | [kJ/kg] |
| h_{f1} | entalpia específica do fluido refrigerante na descarga do compressor, durante ensaio | [kJ/kg] |

Potência elétrica ativa consumida é a potência consumida nos terminais do compressor: consumo do motor e de outros elementos que mantêm o compressor em operação. É expressa em watt [13]. O coeficiente de desempenho é a razão da capacidade de refrigeração pela potência consumida. Logo, é adimensional [13].

2.3 Bancada de Ensaio de Desempenho

Os ensaios que determinam as características de desempenho são realizados em bancadas específicas, capazes que submeter os compressores às condições específicas nas

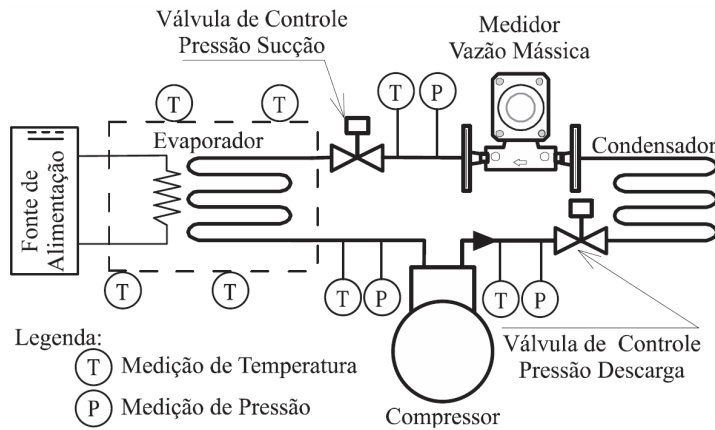


Figura 3 – Diagrama da bancada de ensaios

quais eles devem ser avaliados. A Figura 3 apresenta um diagrama simplificado da bancada da Embraco.

A norma ISO 917 estabelece procedimentos gerais para todas as condições de operação, tal que valores diferentes para pressão absoluta de descarga e sucção, temperatura de sucção e rotação do compressor são determinados para cada condição. As demais variáveis podem ser fixas [13]. A realização de um ensaio de desempenho pode ser descrito da seguinte forma:

Determina-se as temperaturas de evaporação e condensação nas quais deseja-se avaliar o compressor. Estas temperaturas determinam as pressões de sucção e descarga do compressor, de acordo com o fluido refrigerante a ser usado.

Para se obter a capacidade de refrigeração, necessita-se da entalpia do fluido refrigerante na entrada e descarga do compressor, bem como o fluxo de massa pelo compressor. A entalpia do fluido refrigerante é obtida com valores de temperatura e pressão nos medidos nos pontos de interesse.

O fluxo de massa de refrigerante pode ser medido direta ou indiretamente, dependendo do método utilizado na bancada (métodos F e C). O método F requer um equipamento específico que mede o fluxo de massa instantâneo. Para tal, o fluido deve estar completamente líquido subresfriado [13]. O método C, método do calorímetro a seco, mede o calor trocado dentro de um calorímetro. No caso da bancada, o calorímetro é o ambiente no qual se localiza o evaporador. Mede-se a potência dissipada em um resistor elétrico que envolve a serpentina por onde o fluido circula no condensador 4.

Além das grandezas necessárias para se obter a capacidade de refrigeração, outras grandezas são medidas para se definir os parâmetros do compressor [3]:

- temperatura de descarga do compressor;




Figura 4 – Diagrama simplificado do calorímetro a seco [3].

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

Durante o ensaio, o compressor opera continuamente até entrar em regime permanente de todas suas variáveis. Por regime permanente, entende-se um período no qual as variáveis mantêm seus valores dentro de determinadas condições [13]:

- as leituras de pressão não podem variar além de $\pm 1\%$ do valor de referência;
- as leituras de temperatura não podem variar além de ± 3 K do valor de referência;
- a frequência rotacional não pode variar além de $\pm 1\%$ do valor de referência;
- a tensão de alimentação do compressor não pode variar além de $\pm 3\%$ e a frequência além de $\pm 1\%$ dos valores nominais de placa;
- no método C, a potência fornecida aos resistores de aquecimento não deve variar além de $\pm 1\%$ do valor medido na última hora;
- no método F, o valor lido no medidor de fluxo de massa não deve variar além de $\pm 1\%$ do valor medido na última hora.

Capacidade de refrigeração, potência ativa consumida e coeficiente de desempenho são calculados com base na média aritmética dos valores medidos consecutivamente na

última hora de ensaio operando em regime permanente [13]. Os limites de variação da capacidade de refrigeração, potência ativa consumida e temperatura do corpo do compressor não são especificados em norma. Mas estes limites são definidos por especialistas de compressores da seguinte forma [3]:

| | |
|-----------------------------------|------------------------------------|
| capacidade de refrigeração | $\pm 2\%$ do valor final de ensaio |
| potência elétrica ativa consumida | $\pm 2\%$ do valor final de ensaio |
| temperatura da carcaça | $\pm 1K$ do valor final |

Estas tolerâncias, aliadas à uma hora de regime permanente, fazem com que os ensaios de compressores tenham longos tempos de execução. A estabilização de diferentes grandezas pode variar de 2 a 5 horas. Portanto, a redução destes tempos, tanto por técnicas de controle na bancada de testes quanto por métodos de prognóstico das variáveis de interesse são importantes [3].

3 Técnicas de IA

Este capítulo apresenta alguns conceitos de inteligência artificial de forma a dar a base para que se entenda o que foi feito no projeto. O foco é dado às técnicas que foram utilizadas no projeto: redes neurais recorrentes e *clustering*.

3.1 Inteligência Artificial

A Inteligência Artificial (IA) é a área do conhecimento que busca criar ou reproduzir comportamentos inteligentes de forma artificial (computadores e máquinas). A IA pode ser dividida em duas principais vertentes [14]:

- sistemas que pensam racionalmente ou como seres humanos;
- sistemas que agem racionalmente ou como seres humanos.

Para as atividades desenvolvidas, o segundo tipo de IA se mostra mais útil. Em especial, uma área da IA muito promissora é o Aprendizado de Máquina (*Machine Learning*). Esta área busca desenvolver programas e sistemas que possam aprender e reconhecer padrões a partir de exemplos para posteriormente fazer uma previsão ou resolver um problema com base no conhecimento adquirido [15].

A abordagem de um problema com técnicas de aprendizagem de máquina normalmente envolve um conjunto de exemplos a ser usado como entradas de um programa ou sistema. Este programa irá então, a partir destes exemplos, ajustar parâmetros de um modelo adaptativo de forma a melhor representar os padrões e dinâmicas incorporados nos exemplos. A isto se dá o nome de aprendizado. Há três formas diferentes de aprendizado para um programa [14], que podem ser resumidas nas formas abaixo:

| | |
|----------------------------------|---|
| Aprendizagem supervisionada: | aprendizagem a partir de entradas e saídas de cada exemplo |
| Aprendizagem não-supervisionada: | aprendizagem a partir de exemplos sem as saídas esperadas |
| Aprendizagem por reforço: | a aprendizagem ocorre enquanto o problema tenta ser resolvido |

Para o trabalho realizado, utilizou-se técnicas das duas primeiras formas de aprendizagem: supervisionada e não supervisionada. Especificamente, estas técnicas foram: redes neurais e *k-means*.

3.2 Redes Neurais

As redes neurais surgiram da década de 1940, quando descobertas acerca do cérebro humano e seus neurônios levaram pesquisadores a tentar simular sistemas semelhantes em computador. As redes neurais tentam, a partir de um modelo simplificado de neurônio, criar redes de neurônios capazes de resolver problemas como: reconhecimento de padrões, processamento de sinais, prognóstico de variáveis, dentre outros.

Algumas características que tornam estas redes interessantes para a resolução dos mais variados problemas são [16, 17]:

- robustez: é mais "resistente" a informações falsas ou faltantes. Menos afetado por ruído;
- generalização: o modelo resultante tem capacidade de, depois de treinado, lidar com situações nunca antes vistas;
- não requer muito conhecimento do problema a ser resolvido em si (modelos matemáticos), apenas dos exemplos;
- bom desempenho em tarefas mal definidas, das quais não se conhece direito os padrões, regras ou dinâmicas;

3.2.1 Modelo do Neurônio

A unidade básica de processamento de uma rede neural é o neurônio (Figura 5). Ele apresenta os seguintes elementos básicos:

- pesos das sinapses de entrada;
- somador;
- função de ativação.

As sinapses de entrada do neurônio recebem uma entrada na forma de um vetor de valores, cada um correspondente a um atributo ou variável do exemplo. Cada valor é então multiplicado por um peso (um valor por sinapse de entrada). Os resultados destes produtos são somados (no somador). A soma é utilizada como argumento da função de ativação, cujo resultado é a saída do neurônio. Matematicamente, este comportamento pode ser descrito pelas equações 3.1 e 3.2.

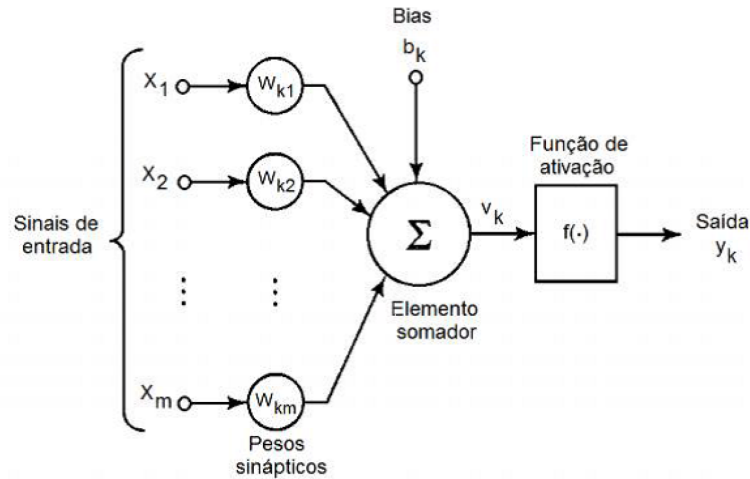


Figura 5 – Modelo básico de neurônio [4].

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

$$y_k = f(v_k) \quad (3.2)$$

Tal que:

- x_j são os atributos de entrada;
- w_{kj} são os pesos sinápticos do neurônio k ;
- b_k é o bias, um valor.

Normalmente este resultado da saída do neurônio varia em um intervalo finito (0 a 1 ou -1 a 1) e indica a qual classe o exemplo pertence ou é mais provável de pertencer. É comum, portanto, estabelecer um limite para este resultado final: acima de certo valor o exemplo é considerado pertencente a uma classe, abaixo, pertencente a outra classe.

A saída de um neurônio, então, depende fortemente de sua função de ativação. Algumas funções de ativação comumente usadas podem ser vistas na Figura 6.

3.2.2 Arquiteturas de Redes Neurais

Normalmente, as redes neurais podem ter duas estruturas distintas: rede *feedforward* e rede recorrente. Estas redes podem ter uma camada ou mais (rede multicamada). O que diferencia uma rede *feedforward* de uma recorrente é a existência de laços de *feedback*: no primeiro caso, a informação flui apenas em um sentido, da entrada para a saída; no




Figura 6 – Funções de ativação comumente usadas. Adaptado de [5].

segundo caso, existem conexões que podem levar a informação para pontos anteriores da rede ou, porventura, fazer com que a informação re-circule no mesmo ponto.

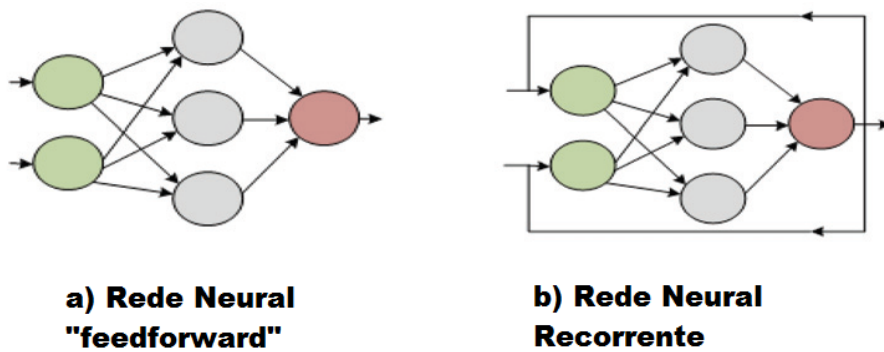


Figura 7 – Redes neurais *feedforward* e recorrente. Adaptado de [6].

Entre as camadas de entrada e saída, uma rede neural pode possuir camadas ocultas ou intermediárias. Na Figura 7, ambas as redes neurais apresentam apenas uma camada escondida, uma de entrada e uma de saída. Portanto, são redes multicamada.

A diferença entre elas é o laço de *feedback*. A rede (a) recebe em sua entrada apenas a informação apresentada a ela. A rede (b) recebe, além disso, informação da saída dela mesma. Esta informação pode ser o resultado do exemplo anterior, o resultado já computado do mesmo exemplo (que agora deve re-circular e gerar um novo exemplo). Esta característica faz com que redes neurais recorrentes sejam mais usadas para resolver problemas sequenciais ou variantes no tempo [18].

3.2.3 Redes Neurais Recorrentes

Existem vários tipos de redes neurais recorrentes: máquina de Boltzmann, redes NARX e NAR, redes de atraso temporal, entre outras [5, 18]. Neste trabalho, foram

utilizadas as redes de atraso temporal (*time delay*) e redes NAR (*Non-linear Auto-Regressive*).

As redes de atraso temporal trabalham com séries temporais, tratando cada instante da série como um exemplo. Para compor seu resultado em determinado instante de tempo t , ela utiliza não apenas o ponto em t , mas também aqueles anteriores a t , até o seu atraso D (*delay*). Uma rede de atraso 3, por exemplo, utilizaria as entradas em t , $t-1$ e $t-2$ de uma série temporal. Mais informações em [5].

As redes NAR funcionam de forma semelhante às de atraso temporal no sentido que elas também têm o atraso como um dos parâmetros de sua arquitetura. Porém, além disso, uma rede NAR é muito adequada para fazer o prognóstico do valor que uma série temporal terá no instante seguinte [5]. Logo, se a rede operar em malha fechada, ela poderá utilizar seu próprio resultado como um ponto na série para computar um ponto mais a frente. A isto se dá o nome de predição multi-passo.

3.2.4 Aprendizado de Redes Neurais

A capacidade de aprender as nuances e dinâmicas de um sistema ou problema a partir de exemplos é fundamental para o funcionamento de um rede neural. Define-se aprendizagem como: processo pelo qual os parâmetros livres de uma rede neural são adaptados por um processo de estimulação pelo ambiente no qual a rede está inserida [4].

Normalmente, estes métodos são processos iterativos de ajustes aplicados aos pesos sinápticos e ao bias da rede. Há diferentes formas de se atualizar os parâmetros de uma rede neural. Dentre elas, destacam-se métodos de correção de erro, baseado em memória, *hebbiano*, competitivo de Boltzmann. O método utilizado neste trabalho, porém, é um de correção de erro, em especial um algoritmo de retropropagação (ou *backpropagation*) [4].

Nos métodos de treinamento de retropropagação, a rede, inicialmente com seus parâmetros aleatórios, recebe um exemplo de treinamento como entrada. Ela então computa um resultado e compara com o resultado esperado (aprendizagem supervisionada). Os pesos então são ajustados de acordo com o erro entre o prognóstico e o resultado real. O erro, portanto, se propaga para as camadas anteriores da rede, ajustando-a. Em seguida, outro exemplo de treinamento é escolhido, e o processo então se repete até que a condição de parada seja alcançada. Mais detalhes sobre o processo podem ser encontrados em [19].

É comum que este método de treinamento seja realizado por época. O algoritmo varre parte do conjunto de treinamento (ou todo ele) antes de realizar a atualização dos pesos. Cada varredura e atualização recebe o nome de "época". Neste caso, é necessário que todo o conjunto de treinamento esteja disponível ao mesmo tempo. Outra forma é por padrão, no qual cada propagação é seguida imediatamente de uma atualização dos parâmetros, e os exemplos são apresentados de forma aleatória de forma a reduzir a chance

do algoritmo se prender em um mínimo local [4].

3.2.5 Comitês de Redes Neurais

Várias tarefas computacionais complexas normalmente podem ser divididas em tarefas mais simples para facilitar sua resolução. Se tratando de redes neurais e algoritmos de treinamento, o "dividir para conquistar" se traduz para comitês de redes neurais. Em um comitê, as respostas de várias redes neurais para um determinado problema são combinadas de forma a gerar um único resultado.

Existem diferentes formas de se combinar as respostas. Pode-se utilizar a média do comitê: a resposta final é a média das respostas das redes. Na mesma linha de pensamento, pode-se fazer uma média ponderada, cujos pesos são baseados em qualquer parâmetro, que pode ser estático ou dinâmico [20, 21]. Pode-se também fazer votação simples no caso de problemas de classificação. Ou ainda pode se escolher a rede com a melhor resposta (de acordo com algum critério) para dar a resposta do comitê. Cada problema pode necessitar de uma abordagem diferente.

Quanto à estruturação do comitê, também existem diferentes métodos. Pode-se treinar várias redes no mesmo conjunto de treinamento ou em seções diferentes do conjunto. Elas podem ainda ser estruturadas por reforço (boosting), no qual vários classificadores de baixa performance são treinados e sua resposta então é combinada para se obter um comitê classificador de alta performance [22].

Os métodos de comitê utilizados neste trabalho foram: média simples, *Generalized Ensemble Method* (GEM), e comitê dinâmico baseado em certeza (CEM). Os métodos GEM e CEM merecem uma explicação mais detalhada.

GEM utiliza os erros que cada rede obteve quando testada no exemplo de treinamento (após o treino) e trata isso como uma espécie de "assinatura da rede". Depois, compara-se os erros em uma matriz de covariância (ou correlação). Por fim, as redes que apresentam menos correlação com as outras (tendem a apresentar um resultado mais diferenciado) ganham um peso maior no comitê. Aquelas que apresentam resultados semelhantes (erros semelhantes para os mesmos problemas) recebem um peso menor [21]. O método de cálculo dos pesos é ilustrado pela equação 3.3.

$$\alpha_i = \frac{\sum_j C_{ij}^{-1}}{\sum_k \sum_j C_{kj}^{-1}} \quad (3.3)$$

Tal que:

- α_i é o peso para o classificador i ;
- C é a matriz de covariância. Ela é simétrica;

Este método é bastante sensível. Dependendo dos erros das redes, o método de cálculo pode atribuir pesos negativos a algumas redes, o que seria um absurdo. Neste caso, deve-se excluir as redes que apresentam maior correlação com outras redes e repetir o processo novamente, até que todos os coeficientes sejam coerentes. Além disso, a matriz de covariância pode não ser invertível, operação necessária para o cálculo dos pesos. Neste caso, o método pode simplesmente não ser adequado. Mais detalhes podem ser encontrados em [21].

CEM é um método que leva em consideração a confiança que cada rede tem em seu resultado. Aquelas com maior confiança recebem maior peso na geração do resultado final. Confiança, neste âmbito, é definida em quão próximo a resposta da rede está dos limites da sua função de ativação. Para uma rede que produz saídas de 0 a 1, por exemplo, a confiança seria o valor absoluto de sua saída subtraída de 0,5 (média do intervalo). A confiança é então utilizada para o cômputo do peso de cada rede. Isto pode ser descrito matematicamente pelas Equações 3.4 e 3.5. Diferente dos outros métodos apresentados, este método é dinâmico: cada exemplo que é apresentado à rede pode gerar pesos diferentes para o comitê. Mais informações em [20].

$$c(y) = \begin{cases} y & \text{se } y \geq 0,5 \\ 1 - y & \text{caso contrário} \end{cases} \quad (3.4)$$

$$\alpha_i = \frac{c(y_i)}{\sum_i c(y_i)} \quad (3.5)$$

Tal que:

- $c(y_i)$ é a confiança da rede i ;
- α_i é o peso da rede i .

3.3 Clusterização

Clusterização (*clustering*) é uma área de pesquisa muito estudada em *machine learning* e *data mining*. Trata-se, basicamente, de segmentar, agrupar e/ou classificar informação. Ela pode ser considerada um modelo conciso para lidar com informação sem classificação ou legenda (aprendizado não-supervisionado). O problema básico de *clustering* pode ser descrito da seguinte forma: dado um conjunto de pontos, particioná-los em grupos que sejam tão semelhantes quanto possível [23]. A Figura 8 demonstra ilustrativamente o problema.

Existem vários métodos de clusterização: baseados em distância, baseados em densidade, de redução de dimensionalidade, entre outros. Os métodos baseados em distância

tentam estabelecer uma função de distância, tratando cada exemplo do conjunto como um ponto em um espaço n -dimensional. Quanto menor esta distância entre um ponto e outro, mais relacionados eles estão e, portanto, mais a probabilidade deles estarem em um mesmo grupo. O método utilizado neste trabalho é conhecido como *k-Means* ("k-Médias").




Figura 8 – Clusterização. A esquerda, *cluster* não classificado. A direita, *cluster* dividido em dois grupos. Adaptado de [7]

3.3.1 k-Means

k-Means é um método de clusterização que separa a informação em k grupos pré-determinados. Para tal, ele inicialmente cria k pontos aleatórios (centroides), que serão os representativos de cada grupo. Em seguida, ele associa cada ponto ao seu representativo mais próximo (de acordo com sua função de distância) e calcula a média dos pontos de cada grupo. Esta média passa a ser o novo representativo de cada grupo. O processo se repete até que o algoritmo cumpra o requisito de convergência. A Figura 8 mostra um processo de clusterização por este método.

Uma das vantagens de se utilizar *k-Means* é que se trata de um método simples, o que faz com que ele esteja amplamente disponível em bibliotecas e pacotes para diferentes linguagens e ferramentas de *software*. Seu processo de classificação também é rápido, e pode-se obter diferentes desempenhos e resultados de classificação manipulando-se a função de distância utilizada para se agrupar os pontos. A função mais comum é a distância euclidiana (ou distância métrica). Neste contexto, podemos chamar esta de uma distância de ordem 2 (pois todas as dimensões são elevadas ao expoente 2 para o cálculo da distância). Analogamente, pode-se utilizar ainda distância de ordem menor (ordem 1, distância *Manhattan* ou pombalina) ou de ordem maior (expoente 3, 4 e assim por diante).

A maior desvantagem do *k-Means* é que o número de centroides deve ser determinado antes de se realizar o processo. Ou seja, o número de grupos final precisa ser determinado pelo projetista. Este número pode ser determinado arbitrariamente, baseado na experiência ou conhecimento do projetista, ou determinado por alguma outra ferramenta. De uma

forma ou de outra, isto torna o k-Means um tanto "incompleto". Mesmo assim, seu desempenho é bom o suficiente para se resolver variados problemas de forma rápida.

Outro ponto importante de se ter em mente é que, como os k centroides são gerados aleatoriamente, o k-Means é um método não-determinístico. Porém, uma vez que as mesmas posições iniciais sejam fixas, o resultado final da clusterização é sempre o mesmo. Mais informações acerca do método podem ser encontradas em [23].

4 Teste de Métodos de Comitê de Redes Neurais

Atualmente, o programa de inferência e prognóstico utilizado nos ensaios realizados pela Embraco em seus compressores é composto de duas partes. A primeira é um comitê de redes neurais que, a cada 10 segundos, infere se o sistema entrou em regime permanente ou se ainda está no transitório. Em seguida, a segunda parte do programa faz o prognóstico de qual seria o valor final do ensaio da variável de interesse. A primeira parte deste trabalho explorou diferentes formas de combinar a resposta do comitê de redes neurais do programa já existente.

4.1 Sistema atual de inferência e prognóstico

Por anos, o Labmetro tem trabalhado em formas de se fazer a inferência do instante no qual um ensaio de compressor atinge regime permanente e, depois, como inferir o valor final do ensaio a partir desta informação. Abordagens por rede neurais foram exploradas por Henklein [2], Steinbach [9] e Lima [24]. Redes fuzzy-bayesianas para a inferência do regime permanente foram apresentadas por Casella [10]. Enfim, o trabalho de Penz [3] definiu métodos e procedimentos para melhoria e garantia de confiabilidade dos resultados.

Ao fim destes trabalhos, consolidou-se um sistema que utiliza um comitê de 120 redes neurais para se realizar a inferência do instante de regime permanente do ensaio, e outro comitê de 500 redes faz o prognóstico do valor final. No caso estudado, a variável de interesse é a capacidade de refrigeração, e as entradas das redes são a própria capacidade de refrigeração, valores de temperatura do corpo do compressor e pressão de sucção em diferentes instantes de tempo.

4.1.1 Comitê de redes para inferência de regime permanente

Para se estimar o instante de entrada em regime permanente da capacidade de refrigeração do compressor durante o ensaio, utiliza-se um comitê de 120 redes neurais. A Tabela 1 mostra a arquitetura das redes. O treinamento das redes foi feito pelo algoritmo Levenberg-Marquardt, utilizando o *toolbox* de redes neurais do software MATLAB. A função de erro avaliada foi a soma quadrática dos erros. As variáveis de entrada da rede estão listadas na Tabela 2. A saída das redes tem valor entre 0 ou 1. Este valor então passa por um patamar de decisão de 0,7. Logo, se o valor for maior que 0,7, a rede indica regime permanente. Menor que 0,7, regime transitório.

| <i>Camada</i> | <i>Número de neurônios</i> | <i>Função de ativação</i> |
|---------------|----------------------------|---------------------------|
| Entrada | 16 | - |
| 1a Escondida | 15 | Tangente hiperbólica |
| 2a Escondida | 10 | Tangente hiperbólica |
| 3a Escondida | 10 | Tangente hiperbólica |
| Saída | 2 | Logística |

Tabela 1 – Arquitetura das redes neurais para inferência de regime permanente

| <i>Variável</i> | <i>Entrada</i> |
|----------------------------|--|
| Capacidade de refrigeração | 1 Desvio padrão de 15 amostras precedentes ao instante atual. |
| | 2 Média de 15 amostras precedentes ao instante atual. |
| | 3 Média de 15 amostras precedentes ao instante atual, deslocado de 15 amostras. |
| | 4 Média de 15 amostras precedentes ao instante atual, deslocado de 30 amostras. |
| | 5 Derivada entre entradas 2 e 3. |
| | 6 Derivada entre entradas 3 e 4. |
| | 7 Derivada entre entradas 2 e 4. |
| | 8 Derivada entre entradas 5 e 6. |
| Temperatura do corpo | 9 Média de 15 amostras precedentes ao instante atual. |
| | 10 Média de 15 amostras precedentes ao instante atual, deslocado de 15 amostras. |
| | 11 Derivada entre entradas 9 e 10. |
| | 12 Derivada entre entrada 9 e a média de 15 amostras precedentes ao instante atual, deslocado de 30 amostras. |
| Pressão de sucção | 13 Média de 15 amostras precedentes ao instante atual. |
| | 14 Média de 15 amostras precedentes ao instante atual, deslocado de 15 amostras. |
| | 15 Derivada entre entradas 13 e 14. |
| | 16 Derivada entre entrada 13 e a média de 15 amostras da variável precedentes ao instante atual, deslocado de 30 amostras. |

Tabela 2 – Entradas das redes neurais de inferência do regime

Para integrar a resposta das redes deste comitê, utiliza-se um conjunto de regras que relaciona o número de redes que afirmam o regime permanente com o tempo decorrido de ensaio. Por exemplo, se apenas 40 redes indicam que em determinado instante ocorreu entrada em regime permanente, a regra manda que se aguarde ainda 20 minutos de ensaio até que se afirme o regime. Se nada mudar neste tempo, o regime é inferido. Caso contrário, o ensaio continua. Estas regras estão descritas na Tabela 3. Nota-se que as regras são

específicas para este comitê (120 redes). Para comitê diferentes, um conjunto de regras diferente precisaria ser elaborado.

| <i>Quantidade de redes</i> | <i>Tempo de espera</i> |
|----------------------------|------------------------|
| De 40 a 79 | 20 minutos |
| De 80 a 104 | 15 minutos |
| De 105 a 114 | 10 minutos |
| De 115 a 119 | 5 minutos |
| 120 | 10 segundos |

Tabela 3 – Relação entre quantidade de redes e tempo de espera

4.1.2 Comitê de redes para prognóstico do valor final

Após o momento de entrada em regime permanente ter sido inferido, um comitê de 500 redes neurais faz o prognóstico do valor final. O treinamento das redes foi feito pelo algoritmo Levenberg-Marquardt, utilizando o *toolbox* de redes neurais do software MATLAB. A função de erro avaliada foi a soma quadrática dos erros. A arquitetura das redes deste comitê pode ser visto na Tabela 4. As variáveis de entrada dessas redes estão listadas na Tabela 5. Após cada rede dar o seu valor de prognóstico, faz-se uma média dos valores para se obter o valor final.

| <i>Camada</i> | <i>Número de neurônios</i> | <i>Função de ativação</i> |
|---------------|----------------------------|---------------------------|
| Entrada | 8 | - |
| Escondida | 20 | Tangente hiperbólica |
| Saída | 1 | Linear |

Tabela 4 – Arquitetura das redes neurais para prognóstico do valor final

| <i>Variável</i> | <i>Entradas</i> |
|----------------------------|--|
| Capacidade de refrigeração | 1 Desvio padrão de 15 amostras precedentes ao instante atual |
| | 2 Média de 15 amostras precedentes ao instante atual |
| | 3 Média de 15 amostras precedentes ao instante atual, deslocado de 15 amostras |
| | 4 Média de 15 amostras precedentes ao instante atual, deslocado de 30 amostras |
| | 5 Derivada entre 2 e 3 |
| | 6 Derivada entre 3 e 4 |
| | 7 Derivada entre 2 e 4 |
| | 8 Derivada entre 5 e 6 |

Tabela 5 – Entradas das redes neurais de prognóstico

4.2 Resultados dos testes

Para se isolar os efeitos dos diferentes métodos de comitê de redes neurais, alterou-se apenas o método de combinação das respostas do comitê de inferência do regime permanente. Testaram-se as mesmas redes no mesmo conjunto de testes, de 842 ensaios, com 4 tipos diferentes de comitê: conjunto de regras (método atual), *Generalised Ensemble Method*, comitê dinâmico baseado em certeza e média simples.

O GEM, devido a suas fragilidades, não produziu pesos consistentes com as 120 redes. Devido a alta correlação entre algumas redes, o resultado do cômputo dos pesos apresentou valores negativos. Portanto, para se testar a técnica, retiraram-se redes do cômputo aos poucos, até que um conjunto de redes suficientemente não correlacionadas fosse encontrado. Este conjunto é de apenas 8 redes. Os outros métodos foram testados sem nenhuma alteração.

O desempenho dos métodos foi testado em diferente quesitos: número de falsos positivos, número de falsos negativos, número de ensaios nos quais não foi possível realizar inferência, erro percentual médio de inferência, erro percentual médio de prognóstico, tempo médio até o prognóstico. Todos os testes foram feitos em LABVIEW. Com exceção do conjunto de regras, que apresenta um patamar de decisão fixo (0,7), as outras técnicas foram testadas em diferente patamares de decisão para a resposta combinada do comitê. Os valores testados foram de 0,6 a 0,9. Os resultados podem ser vistos nas Tabelas 6, 7, 8 e 9.

| <i>Patamar</i> | <i>Falso negativo</i> | <i>Falso positivo</i> | <i>Não inferência</i> | <i>Erro % inferência</i> | <i>Erro % prognóstico</i> | <i>Tempo médio [min]</i> |
|----------------|-----------------------|-----------------------|-----------------------|--------------------------|---------------------------|--------------------------|
| 0,6 | 81,29% | 16,9% | 1,0% | 1,26 | 0,95 | 48,5 |
| 0,7 | 85,9% | 11,8% | 1,2% | 1,11 | 0,84 | 51,09 |
| 0,8 | 87,5% | 8,2% | 2,1% | 0,96 | 0,74 | 54,47 |
| 0,9 | 88,8% | 4,0% | 3,6% | 0,76 | 0,62 | 59,77 |

Tabela 6 – Resultado dos testes - GEM

Alguns resultados mostrados nas tabelas podem ser melhor visualizados nos gráficos das Figuras 9, 10, 11 e 12.

Todos os métodos novos testados apresentaram desempenho semelhante. É possível afirmar que, no geral, o método de média simples foi o que obteve melhor desempenho (menores erros, maior capacidade de inferência e tempo semelhante aos outros). Porém, todos foram pior que o método original: o conjunto de regras. Em apenas um quesito o

| <i>Patamar</i> | <i>Falso negativo</i> | <i>Falso positivo</i> | <i>Não inferência</i> | <i>Erro % inferência</i> | <i>Erro % prognóstico</i> | <i>Tempo médio [min]</i> |
|----------------|-----------------------|-----------------------|-----------------------|--------------------------|---------------------------|--------------------------|
| 0,6 | 80,3% | 18,8% | 0,5% | 1,34 | 1,00 | 47,54 |
| 0,7 | 83,3% | 14,8% | 1,0% | 1,22 | 0,92 | 49,01 |
| 0,8 | 89,9% | 10,9% | 1,1% | 1,08 | 0,81 | 51,62 |
| 0,9 | 91,8% | 3,9% | 2,1% | 0,78 | 0,61 | 58,35 |

Tabela 7 – Resultado dos testes - CEM

| <i>Patamar</i> | <i>Falso negativo</i> | <i>Falso positivo</i> | <i>Não inferência</i> | <i>Erro % inferência</i> | <i>Erro % prognóstico</i> | <i>Tempo médio [min]</i> |
|----------------|-----------------------|-----------------------|-----------------------|--------------------------|---------------------------|--------------------------|
| 0,6 | 81,6% | 17,2% | 0,6% | 1,28 | 0,97 | 48,24 |
| 0,7 | 86,9% | 12,2% | 1,0% | 1,13 | 0,85 | 50,67 |
| 0,8 | 89,9% | 0,7% | 1,1% | 0,97 | 0,72 | 54,13 |
| 0,9 | 91,8% | 3,2% | 2,5% | 0,68 | 0,57 | 61,29 |

Tabela 8 – Resultado dos testes - média simples

| <i>Patamar</i> | <i>Falso negativo</i> | <i>Falso positivo</i> | <i>Não inferência</i> | <i>Erro % inferência</i> | <i>Erro % prognóstico</i> | <i>Tempo médio [min]</i> |
|----------------|-----------------------|-----------------------|-----------------------|--------------------------|---------------------------|--------------------------|
| 0,7 | 96,1% | 2,7% | 0,6% | 0,56 | 0,5 | 64,6 |

Tabela 9 – Resultado dos testes - conjunto de regras

conjunto de regras não obteve um desempenho superior: tempo médio para prognóstico. Portanto, é seguro afirmar que embora as regras sejam precisas, elas são mais conservadoras que outros métodos, esperando mais para afirmar um resultado. Porém, no caso analisado, seus ganhos de precisão compensam seu acréscimo de tempo, o que a classifica como o melhor método de comitê para este problema específico.

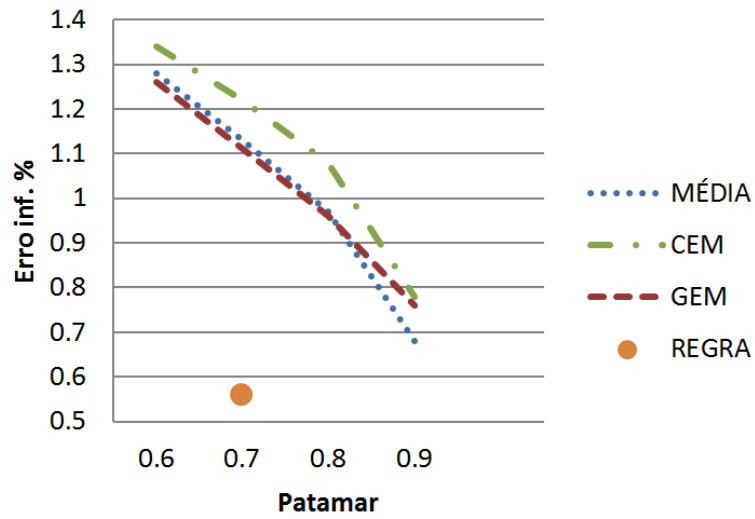


Figura 9 – Erro percentual de inferência de cada método de comitê.




Figura 10 – Erro percentual de prognóstico de cada método de comitê.

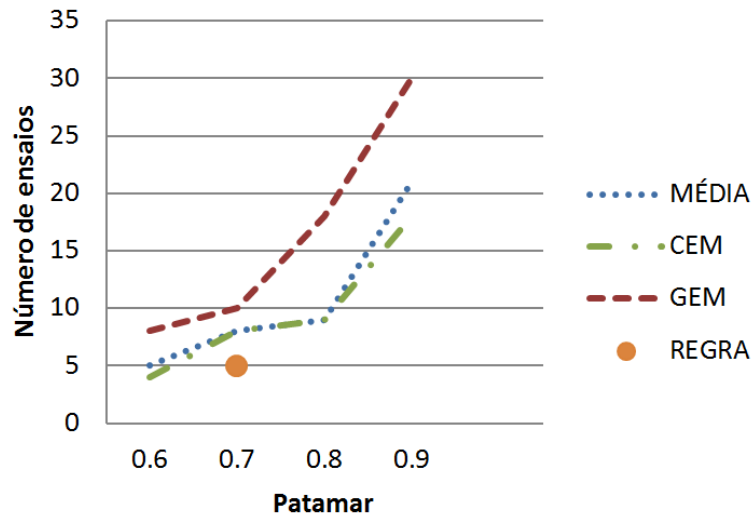


Figura 11 – Número de ensaios nos quais não foi possível fazer o prognóstico, com cada método de comitê




Figura 12 – Tempo médio para o prognóstico em minutos, para cada métodos de comitê.

5 Sistema com Redes Neurais Recorrentes para Prognóstico do Valor Final

O atual sistema de inferência e prognóstico utiliza como entrada de suas redes neurais valores passados de temperatura do corpo do compressor, pressão de sucção e capacidade de refrigeração para inferir o valor final da capacidade de refrigeração. Isto é uma tentativa de se extrair informações de um sistema dinâmico e fazer inferências a respeito dele com uma ferramenta originalmente feita para se lidar com sistemas estáticos, as redes neurais convencionais.

Outra limitação que se observa no sistema atual é em relação ao tempo necessário para sua execução. Como antes infere-se a entrada em regime permanente do instante atual, o tempo para o prognóstico (idealmente) nunca será menor que o tempo de regime permanente. E, com base nos ensaios disponíveis, este tempo é de cerca de 40 minutos, em média. Para que seja possível reduzir ainda mais o tempo dos ensaios, uma nova abordagem é necessária.

Portanto, na esperança de se reduzir ainda mais os tempos de ensaio, um novo sistema foi criado e testado para se fazer o prognóstico do valor final dos ensaios. Ao invés de utilizar redes neurais convencionais, ele utiliza redes neurais recorrentes, que naturalmente incorporam a informação temporal de sua entrada em sua estrutura. E para que o tempo de regime permanente não seja um limitante, ele tenta prever o comportamento futuro do ensaio para realizar seu prognóstico, reduzindo ainda mais o tempo necessário.

O sistema foi reduzido em duas partes. A primeira é um comitê de redes NAR que, a partir de alguns valores anteriores de temperatura de corpo, pressão de sucção e capacidade de refrigeração, tenta prever os valores futuros destas três variáveis. Estas são chamadas de "comitê de prognóstico da dinâmica". A segunda parte é uma única rede de atraso no tempo (*time-delay*), que a partir dos último valores prognosticados pela primeira parte, faz o prognóstico do valor final do ensaio.

Para se definir a arquitetura das redes neurais do sistema, criou-se um programa que treina redes com diferentes parâmetros em um conjunto limitado ensaios e compara o erro de previsão de uma amostra a frente das diferentes redes. E para se formar o comitê da primeira parte do sistema, utilizou-se um método de clusterização para se separar os ensaios de treinamento, fazendo com que as redes resultantes fossem especializadas no prognóstico de ensaios com dinâmicas diferentes.

5.1 Pré-processamento das entradas

Antes de tudo, definiu-se os conjuntos de treinamento e teste a serem utilizados neste sistema. Para o propósito de comparação, decidiu-se utilizar um conjunto específico de ensaios: 275 ensaios para treinamento, 842 ensaios para teste. Estes ensaios foram selecionados de um conjunto maior de ensaios, no qual havia ensaios de comportamentos muito variados. Estes 1117 ensaios ($275 + 842$) foram manualmente avaliados e julgados como sendo mais apropriados para o treinamento de um sistema de prognóstico [25].

Estes ensaios pertencem a compressores de diferentes categorias. São de tamanhos diferentes e/ou utilizam fluidos refrigerantes diferentes. Logo, seus valores absolutos das variáveis de interesse são muito díspares (de aproximadamente 50W até mais de 200 W). Para colocar todos os ensaios em um referencial comum, os valores das variáveis de interesse foram divididos por seus valores padrão esperado. Assim, os valores normalizados passam a ser mensurados em variações relativas a seu valor padrão.

Como pretende-se fazer o prognóstico de várias amostras a frente com o comitê de prognóstico da dinâmica, e a rede NAR realimenta seus próprios resultados para continuar fazendo prognósticos, o menor erro que surge neste processo é "carregado" para o resultados posteriores e pode rapidamente crescer de forma a tornar os últimos resultados inutilizáveis para o prognóstico do valor final. Por este mesmo motivo as redes NAR são muito sensíveis a "ruído": variações bruscas no comportamento da série temporal.

Para se lidar com este problema, optou-se por condensar a informação das amostras (que ocorrem a cada 10 segundos no sistema original). A cada 6 amostras dos ensaios originais, fez-se a média, transformando-as em 1 única amostra. O período amostral assim é alterado para 1 amostra por minuto. Assim, para um mesmo período de tempo, menos amostras efetivas são geradas e menor a influência de ruídos no resultado do prognóstico.

Como a bancada de testes em funcionamento é um sistema multivariável complexo, o comportamento inicial dos ensaios é por vezes errático e não oferece informação sobre o comportamento real do ensaio, como mostra o ensaio da Figura 13. Logo, para eliminar esta fonte de ruído dos conjuntos de treinamento, elimina-se os 5 primeiros minutos dos ensaios (30 amostras de período 10 segundos). Para possibilitar a classificação dos ensaios e, posteriormente, seu uso para treinamento, todos os ensaios foram "podados" para o tamanho do seu ensaio de menor duração (95 amostras condensadas, 95 minutos).

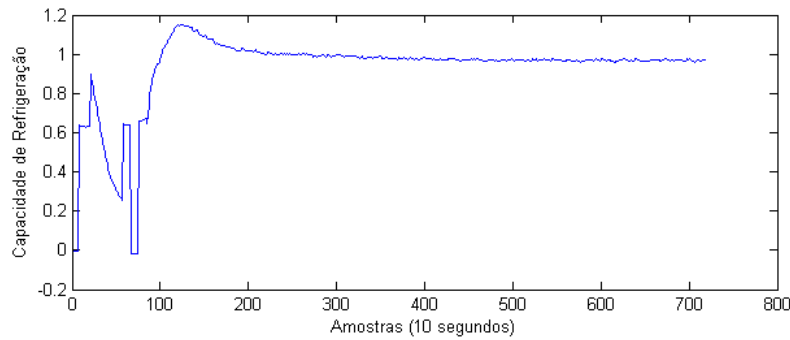


Figura 13 – Ensaio com comportamento inicial não desejado. Amostras a cada 10 segundos.

5.2 Topologia das redes recorrentes

Definir uma topologia para um sistema de redes neurais não é uma tarefa simples. Normalmente, a escolha é feita empiricamente. Utiliza-se o conhecimento que o projetista já tem sobre o problema (quais são as variáveis importantes, qual é a dinâmica do sistema) para se ter uma estimativa inicial sobre quais deveriam ser os parâmetros da rede e depois se testa diferentes possibilidades na vizinhança até que se obtenha um resultado satisfatório.

Para se reduzir o tempo a ser gasto neste processo de projeto, um programa em MATLAB foi desenvolvido. Este programa altera um parâmetro estrutural de cada vez e treina várias redes diferentes, cada uma com um valor diferente apenas naquele parâmetro escolhido na iteração em questão. Escolhe-se então a rede que obteve menor erro em um conjunto de teste naquele grupo. A partir deste novo melhor indivíduo, outro parâmetro é selecionado para variar e o ciclo se repete até que a condição de parada seja atingida. Neste caso, uma parada acontece se há convergência: se a variação de diferentes parâmetros indicam a mesma rede como melhor indivíduo.

Testou-se redes com uma e duas camadas escondidas neste programa. Para os testes de uma camada, o programa atingiu um mínimo local que apresentava erros de prognóstico muito altos. Portanto, apenas o caso para redes de duas camadas será discutido aqui.

Os parâmetros que sofrem variação na execução do programa são: número total de neurônios, fator de distribuição e número de atrasos (*delays*). Número de neurônios e número de atrasos são parâmetros evidentes. O fator de distribuição é um número positivo definido pela Equação 5.1.

$$fd = \frac{hl_1}{hl_2} \quad (5.1)$$

Tal que fd é o fator de distribuição, hl_1 é o número de neurônios da primeira camada escondida, hl_2 é o número de neurônios da segunda camada escondida.

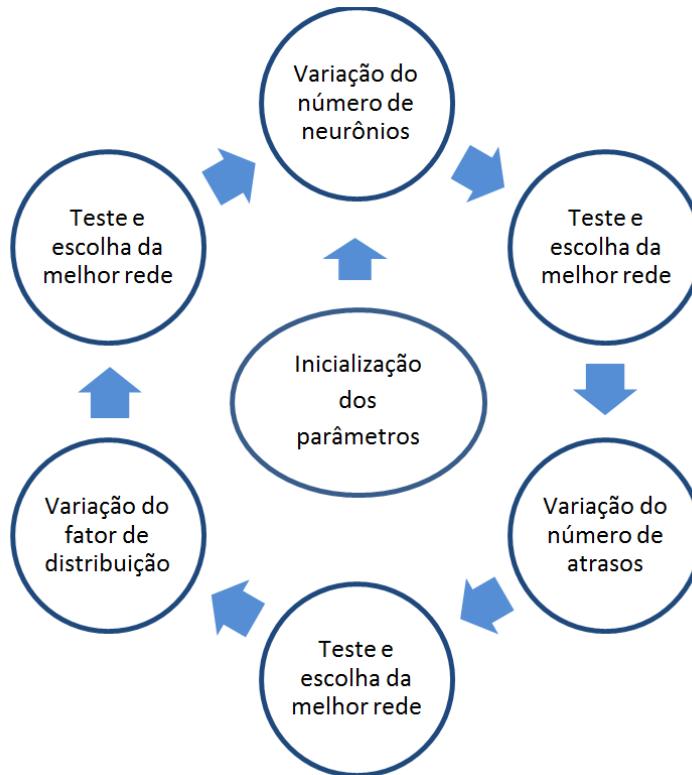


Figura 14 – Diagrama de funcionamento de programa de busca de topologias de redes neurais.

O funcionamento do programa pode ser ilustrado pelo diagrama da Figura 14.

O número de entradas depende do número de atrasos do sistema. Optou-se por usar como entradas a temperatura de corpo do compressor, a pressão de sucção e a capacidade de refrigeração por ter sido avaliado em trabalhos anteriores que a capacidade de refrigeração depende fortemente destas variáveis [3]. Portanto, com 3 variáveis de entrada, as redes teriam como entrada, no total, 3 multiplicado pelo número de atrasos. As redes de prognóstico da dinâmica têm 3 saídas: ela faz o prognóstico das variáveis de entrada. A rede de prognóstico do valor final tem apenas uma saída e uma entrada: a capacidade de refrigeração. Os resultados da busca de topologias para as redes de prognóstico da dinâmica do ensaio podem ser vistos nas Tabelas 10 e 11. Para o treinamento das redes neste teste, utilizou-se o algoritmo de retropropagação do Gradiente Conjugado Escalonado (SCG: "Scaled Conjugate Gradient"), por ser adequado ao problema em si (prognóstico de sistemas dinâmicos) e ser normalmente mais rápido que o Levenberg-Marquardt.

Apesar de o programa proposto não ser muito sofisticado (não garante mínimo global, não é determinístico), seu desempenho foi satisfatório na automatização de um processo empírico que normalmente seria feito manualmente. Vale lembrar também que ele não é o foco deste trabalho, apenas uma ferramenta auxiliar. Por isso, ele não foi tão bem trabalhado quando poderia ter sido.

| | |
|--|-------|
| Erro percentual médio de prognóstico | 4,14% |
| Número de neurônios da primeira camada escondida | 40 |
| Número de neurônios da segunda camada escondida | 9 |
| Número de atrasos | 3 |

Tabela 10 – Parâmetros topológicos das redes de prognóstico da dinâmica

| | |
|--|-------|
| Erro percentual médio de prognóstico | 4,86% |
| Número de neurônios da primeira camada escondida | 15 |
| Número de neurônios da segunda camada escondida | 8 |
| Número de atrasos | 5 |

Tabela 11 – Parâmetros topológicos da rede de prognóstico do valor final

5.3 Estrutura do comitê de prognóstico da dinâmica

Testes preliminares demonstraram que uma única rede, se treinada em um conjunto diversificado, tem um desempenho muito pobre para prognóstico de ensaios. As redes NAR são sensíveis a ruído e não oferecem uma capacidade de generalização tão grande quanto necessária para uma única rede prognosticar os variados ensaios. Portanto, um comitê com redes especializadas em tipos diferentes de ensaios foi proposto. Cada rede neste comitê deveria ser capaz de prever um tipo de ensaio. Para tal, o conjunto original de treinamento, composto por 275 ensaios, precisava ser dividido em grupos de ensaios semelhantes.

Separar informação não categorizada em grupos semelhantes é um tarefa típica de aprendizagem não supervisionada. Portanto, um algoritmo de aprendizagem não-supervisionada foi utilizado para realizar esta divisão. Optou-se pelo algoritmo *k-Means* para realizar esta tarefa por sua simplicidade. Optou-se arbitrariamente em se dividir os ensaios em cinco grupos diferentes. O algoritmo então trata cada ensaio como um "ponto", e cada amostra da capacidade de refrigeração como uma dimensão. Como distância, ele utiliza a distância euclidiana entre os ensaios. A Figura 15 mostra cada grupo de ensaios de treinamento, com todos os seus ensaios plotados no mesmo gráfico. O número de ensaios por grupo está na Tabela 12.

| <i>Grupo</i> | <i>Número de ensaios</i> |
|--------------|--------------------------|
| 1 | 69 |
| 2 | 90 |
| 3 | 3 |
| 4 | 96 |
| 5 | 17 |

Tabela 12 – Número de ensaios por grupo de treinamento.

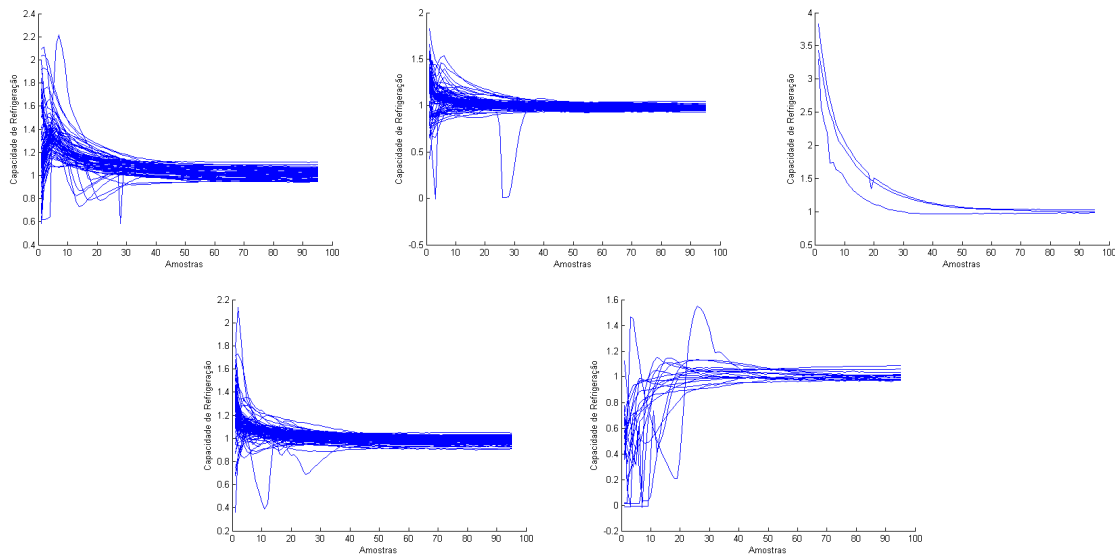


Figura 15 – Ensaios dos grupos de treinamento 1 a 5, da esquerda para a direita e de cima para baixo.

5.4 Treinamento do comitê de prognóstico da dinâmica

Após separados os grupos de treinamento, as redes podem enfim serem treinadas. O treinamento do comitê de prognóstico da dinâmica foi feito em cima apenas do regime transitório dos ensaios. Como o tempo de regime permanente médio dos ensaios da base de dados é cerca de 40 minutos, utilizou-se apenas os primeiros 45 minutos dos ensaios para se realizar o treinamento do comitê. As redes foram treinadas com o algoritmo Levenberg-Marquardt na *toolbox* de redes neurais do MATLAB, cada uma das 5 em seus devido conjunto de treinamento. As redes são do tipo NAR, operando em malha fechada. A cada etapa do treinamento, o algoritmo minimiza o erro de previsão do próximo instante de um ensaio, em instantes arbitrários dos ensaios. A topologia destas redes está descrita na Tabela 13. O número de entradas deriva do número de atrasos (3) e do número de variáveis de entrada(3). A Figura 16 mostra um diagrama das redes.

| Camada | Número de neurônios | Função de ativação |
|-------------|---------------------|----------------------|
| Entrada | 9 | - |
| Escondida 1 | 40 | Tangente hiperbólica |
| Escondida 2 | 9 | Tangente hiperbólica |
| Saída | 3 | Linear |

Tabela 13 – Topologia das redes de prognóstico da dinâmica.




Figura 16 – Diagrama da rede NAR, em malha fechada.

5.5 Treinamento de rede de prognóstico do valor final

Em seguida, treina-se a rede de prognóstico do valor final. Esta rede tem o propósito de, a partir de um ponto arbitrário do ensaio, estimar o valor final da capacidade de refrigeração a partir dos pontos anteriores. Logo, ela foi treinada usando como exemplos de treinamento os primeiros 45 minutos do conjunto de treinamento (275 ensaios), e como alvo de treinamento, o valor final de cada ensaio. As redes foram treinadas com o algoritmo Levenberg-Marquardt, na *toolbox* de rede neurais do MATLAB. As redes são do tipo atraso temporal (*time-delay*). A topologia destas redes pode ser vista na tabela 14. O número de entradas deriva do número de atrasos (5) e do número de variáveis de entrada (1, a capacidade de refrigeração). A Figura 17 mostra um diagrama da rede.

| Camada | Número de neurônios | Função de ativação |
|-------------|---------------------|----------------------|
| Entrada | 5 | - |
| Escondida 1 | 15 | Tangente hiperbólica |
| Escondida 2 | 8 | Tangente hiperbólica |
| Saída | 1 | Linear |

Tabela 14 – Topologia das redes de prognóstico do valor final.




Figura 17 – Diagrama da rede de atraso temporal.

5.6 Teste do sistema de prognóstico

Após o treinamento, o sistema de prognóstico foi testado no conjunto de treinamento (842 ensaios). Este conjunto de testes é o mesmo que foi utilizado nos testes dos métodos de comitê, apresentados no Capítulo 4. Inicialmente, procurou-se descobrir quantas amostras era necessário se explorar a frente no comitê de prognóstico da dinâmica para se obter um bom prognóstico do valor final. Fez-se então o prognóstico de até 40 amostras a frente utilizando apenas os primeiros minutos do ensaio. Optou-se por 40 minutos por ser o tempo médio de entrada em regime permanente dos ensaios. Espera-se que a melhor forma de se prognosticar o valor final seria com informação do ensaios em seu regime permanente.

Neste momento torna-se importante explicar melhor o funcionamento do comitê de prognóstico da dinâmica. O comitê utiliza cinco redes, uma para cada dinâmica diferente, para que elas possam lidar melhor com diferentes tipos de ensaios. Para descobrir qual rede tem melhor capacidade de previsão em cada ensaio, inicialmente faz-se apenas o prognóstico de cinco minutos de ensaio. Depois, compara-se estes cinco valores com as amostras reais do ensaio em questão. A rede que apresentar menor erro médio de prognóstico é então escolhido para prognosticar a dinâmica do ensaio.

Logo, em um caso real (que é necessário se esperar as amostras chegarem), o prognóstico do valor final de um ensaio demoraria 13 minutos: primeiros cinco minutos descartados, 3 minutos necessários para se realizar o primeiro prognóstico (redes de atraso 3), 5 minutos para se comparar o prognóstico inicial. O funcionamento do sistema projetado pode ser melhor visualizado no diagrama da Figura 18.

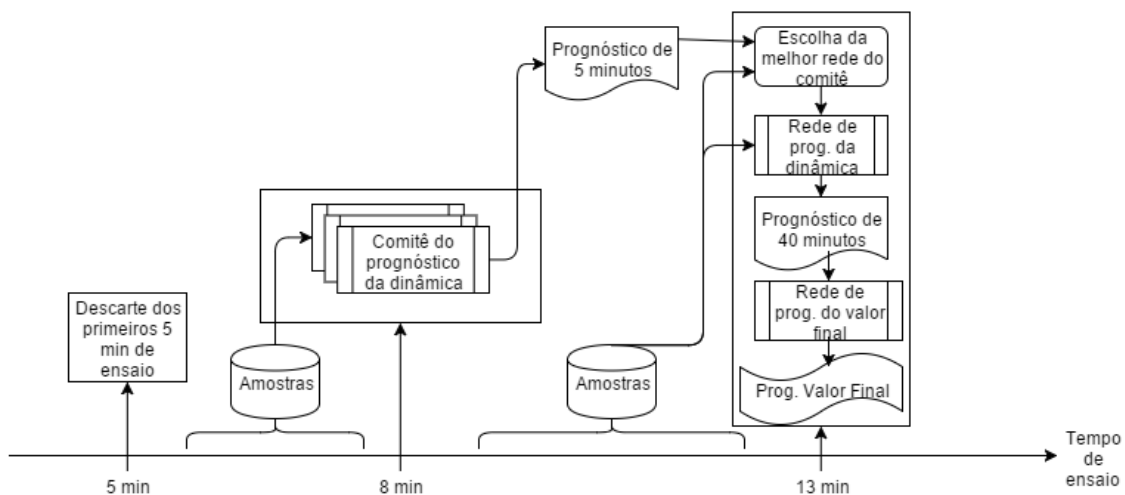


Figura 18 – Diagrama ilustrativo do funcionamento do sistema de prognóstico.

Para então se descobrir quantas amostras são necessárias para se obter um bom prognóstico do valor final, fez-se o prognóstico em diferentes instantes da dinâmica prevista e verificou-se o erro de cada um. A Figura 19 mostra o erro e o desvio padrão deste erro

percentual de prognóstico do valor final, quando feito em diferentes instantes de ensaio previsto.

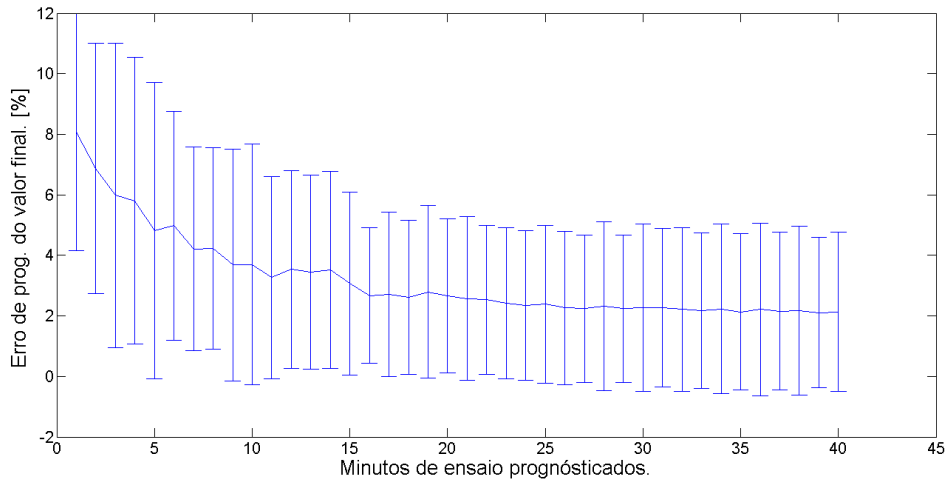


Figura 19 – Erro médio e desvio padrão de prognóstico do valor final em diferentes tempos de prognóstico da dinâmica.

Pela figura, pode-se observar que a partir de aproximadamente 30 minutos, o erro de prognóstico médio cai muito pouco, bem como o desvio padrão. Portanto, pode-se afirmar de que quanto maior o número de amostras prognosticadas do ensaio, menor o erro do prognóstico do valor final, mesmo que a chance de ocorrer uma divergência no prognóstico da dinâmica aumente. E também se conclui que 40 é um número de amostras a serem previstas aceitável para este caso.

Em seguida, é analisado o erro de prognóstico do valor final, computado nas últimas amostras do prognóstico de 40 minutos de ensaio. Na Figura 20 pode se ver o histograma dos erros. Pode-se observar que, dos 842 ensaios, a grande maioria dos ensaios apresentou erro menor que 5% (730 ensaios). Porém poucos apresentaram erro menor que 1% (12 ensaios). Alguns poucos apresentaram erros muito grandes (maior que 10%, apenas 9). Um ensaio não pode ser prognosticado por ter valores de variáveis inválidos (*NaN - not a number*).




Figura 20 – Histograma do erro de prognóstico do valor final.

6 Conclusões e Oportunidades Futuras

O objetivo deste trabalho era explorar diferentes técnicas de inteligência artificial para o prognóstico de ensaios de compressores, tanto no âmbito de se propor e testar melhorias do processo atual como de se propor novas ferramentas. Duas técnicas diferentes foram exploradas: técnicas de comitê (alteração do método atual) e redes neurais recorrente (proposta de nova ferramenta). Os resultados, por mais que porventura não levem a alterações muito significativas no método de prognóstico no futuro, ainda assim são interessantes.

6.1 Técnicas de comitê

Apesar de, como explicado no fim do Capítulo 4, os novos métodos de comitê apresentarem uma vantagem em relação ao método atual (menor tempo de ensaio), eles acabam sendo piores que o método atual (conjunto de regras) quando o resultado é avaliado no contexto da Embraco. A Tabela 15 ajuda a visualizar isto.

| Incerteza da medição praticada | Ganho a validar | | | Número de amostras |
|--------------------------------|-----------------|------|------|--------------------|
| | 0,5% | 0,8% | 1,5% | |
| 3 % | 155 | 61 | 18 | |
| 1 % | 18 | 8 | 3 | |

Tabela 15 – Incerteza da medição na validação de ganhos de desempenho. Adaptado de [3].

Maiores erros de medição requerem um maior número de ensaios para se validar ganhos de desempenho. Nesta perspectiva o erro de prognóstico do método de comitê se mostra um fator decisivo na redução do tempo total dos ensaios. Um erro muito baixo faz com que menos ensaios sejam necessários para se validar um mesmo resultado. Desta forma, um procedimento de 60 minutos com erro de prognóstico de 0,5% (conjunto de regras) pode se mostrar muito mais eficiente que um procedimento de erro prognóstico de 0,85% porém com duração de 50 minutos (média simples com patamar 0,7).

O alto desempenho do conjunto de regras mostra que, apesar de os outros métodos serem amplamente usados e explorados na literatura, um método menos convencional pode ser o mais indicado para a resolução de um problema específico. Apesar de ser um método mais complexo de se projetar e utilizar, o investimento que se fez para se desenvolver tal método mostra seu retorno na alta eficiência no prognóstico das grandezas dos ensaios.

Para o futuro, pode ser interessante procurar outras técnicas de comitê. Uma desvantagem da técnica atual do conjunto de regras é que ela não tem muita fundamentação teórica. Como várias outras coisas na indústria, ela foi escolhida porque funciona. Porém,

algum outro método de comitê já validado ainda pode ter um desempenho melhor. Ou, ainda, se esta técnica atual for melhor estudada, aplicada a outros sistemas diferentes, pode vir a ser mais um incremento ao grupo de técnicas de comitê fundamentadas teoricamente.

6.2 Redes Neurais Recorrentes para prognóstico de ensaios

Os resultados obtidos com o sistema de prognóstico com redes neurais recorrentes foram muito interessantes. Apesar de apresentar um erro de prognóstico muito superior ao erro do sistema atual, as reduções de tempo de ensaio foram muito significativas. Além de reduzir de 40 minutos (em média) para 13 minutos, este novo tempo para o prognóstico é fixo.

Este tempo fixo pode facilitar muito o planejamento dos ensaios a serem realizados nos compressores herméticos. Porém, como indica a Tabela 15, um erro de aproximadamente 5% aumentaria muito o número de ensaios a serem realizados para a validação de um mesmo ganho. Logo, o tempo total de uma sequência de ensaios seria enorme também, desvalorizando os ganhos de tempo dos ensaios individuais.

Mesmo assim, a estrutura de prognóstico mostrou-se muito eficiente. Vale ressaltar que este sistema não recebeu muitos aprimoramentos desde sua idealização inicial. Trabalhos futuros podem deixá-lo muito mais preciso. É esperado também que se o processo demorasse mais, trabalhando com informações mais próximas do regime permanente do ensaio, o prognóstico do valor final deve se tornar mais preciso. Esta e outras possibilidades podem ser aplicadas no sistema e torná-lo o próximo sistema de prognóstico de ensaios da Embraco.

Outro aspecto que influencia o desempenho do sistema é a variedade de ensaios. Dentro do mesmo conjunto de ensaios fornecido, há muitos ensaios diferentes. Isto ocorre porque existem diferentes tipos de ensaios realizados pela Embraco, para se testar coisas diferentes: há ensaios com o compressor a frio, com o compressor já quente, ensaios em que há alteração dos parâmetros durante o ensaio.

Foi devido a grande variedade de ensaios que a separação dos ensaios em grupo (com o algoritmo *k-Means*) e o treinamento de redes neurais independentes melhorou o desempenho do sistema. Se estas informações fossem disponibilizadas junto com os ensaios, uma separação mais adequada poderia ser feita e melhorar o desempenho do sistema ainda mais. Ou ainda, sistemas de prognóstico diferentes poderiam ser feitos para ensaios diferentes.

O período de teste para seleção da rede para prognóstico da dinâmica do ensaio foi arbitrário também. Talvez um tempo diferente, maior, pudesse melhorar o prognóstico da dinâmica do ensaio. Um melhor prognóstico da dinâmica se traduz em, posteriormente,

um melhor prognóstico do valor final do ensaio.

O conjunto de treinamento da rede de prognóstico do valor final também pode ser modificado. A utilização de tempos iniciais de ensaio para o prognóstico do valor final no treinamento possivelmente adiciona uma capacidade de generalização desnecessária à rede, visto que depois ela opera sempre com informações mais futuras dos ensaios.

6.3 Aprendizado no projeto

O projeto foi muito proveitoso do ponto de vista didático. Aprendeu-se sobre o processo de refrigeração e características inerentes ao processo. Mas principalmente, o aprendizado foi muito amplo em técnicas de inteligência artificial. Para se chegar nas técnicas utilizadas, várias outras técnicas foram levadas em consideração.

O autor deste trabalho teve que pesquisar e aprender sobre várias técnicas diferentes, não apenas de prognóstico de ensaios, mas também de classificação em geral, visto que a decisão de se tentar criar uma nova ferramenta de prognóstico surgiu apenas durante o andamento do projeto.

O projeto também serviu como aprendizado ao autor quanto a elaboração de documentação, voltado a relatórios acadêmicos e técnicos. Agregou-se também experiência de programação com os programas MATLAB e LABVIEW, bem como experiência prática com várias ferramentas de inteligência artificial. Além disso, aprendeu-se sobre o regime de trabalho dentro de um laboratório, o LABMETRO.

Referências

- 1 SCUSSEL, J. N. *Proposta de Ações para Reduzir o Tempo Demandado por Ensaio de Desempenho de Compressores Herméticos*. Dissertação (Mestrado em Metrologia Científica e Industrial) — UFSC, Florianópolis, 2006.
- 2 HENKLEIN, P. *Análise de Ensaios de desempenho de compressores herméticos durante o transitório*. Dissertação (Mestrado em Metrologia Científica e Industrial) — UFSC, Florianópolis, 2006.
- 3 PENZ, C. *Desenvolvimento de recursos para prover confiabilidade ao uso de inteligência artificial em ensaios de desempenho de compressores herméticos de refrigeração*. Dissertação (Doutorado em Engenharia Mecânica) — UFSC, Florianópolis, 2011.
- 4 HAYKIN, S. *Redes Neurais: Princípios e práticas*. Porto Alegre: Bookman, 2001.
- 5 BEALE M; HAGAN, M. T. D. H. *Neural network toolbox.: User's guide*. [S.l.]: The MathWorks, 2012.
- 6 MITREA C. A.; LEE, C. K. M. W. Z. *A Comparison between Neural Networks and Traditional Forecasting Methods: A Case Study*. *International Journal of Engineering Business Mangement*, Vol. 1, 2009.
- 7 MATHWORKS. *kmeans*. 2015. Disponível em: <<http://www.mathworks.com/help/stats/kmeans.html>>.
- 8 IBGE. Disponível em: <<http://seriesestatisticas.ibge.gov.br/series.aspx?vcodigo=PD279>>.
- 9 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) — UFSC, Florianópolis, 2008.
- 10 CASELLA, A. V. Mestrado em Metrologia Científica e Industrial, *Ferramenta fuzzy-bayesiana para identificação do instante de entrada no regime permanente em ensaios de desempenho de compressores*. 2008.
- 11 WANG, S. *Handbook of air conditioning and refrigeration*. New York: McGraw-Hill, 2000.
- 12 STOECKER, W. S. J. J. *Refrigeração Industrial*. São Paulo: 2. ed. Edgar Blücher Ltda, 2002.
- 13 ISO. *ISO 917: Testing of refrigerant compressors*. [S.l.], 1989.
- 14 RUSSEL J.N.; NORVIG, P. *Artificial Intelligence: a modern approach*. [S.l.]: 2. ed. Prentice Hall series in artificial intelligence, 2003.
- 15 BISHOP, P. *Pattern recognition and machine learning*. [S.l.]: Springer, 2007.
- 16 PFEIFER R.; SCHEIER, C. *Understanding Intelligence*. Cambridge: The MIT Press, 1999.

- 17 BITTENCOURT, G. *Inteligência Artificial: ferramentas e teorias*. Florianópolis: Editora UFSC, 2006.
- 18 JAIN, L. C. M. L. R. *Recurrent Neural Networks: Design and applications*. [S.l.]: CRC Press, 2001.
- 19 RUMELHART D. E.; HINTON, G. E. W. R. J. *Learning internal representations by backpropagating errors*. *Nature*, 1986.
- 20 MAQSOOD I.; KHAN, M. R. A. A. *An ensemble of neural networks for weather forecasting*. *Neural Computing and Applications*, 2004.
- 21 PERRONE M. P.; COOPER, L. N. *When Networks Disagree: Ensemble Methods for Hybrid Neural Networks*. [S.l.], 1992.
- 22 FREUND Y.; SCHAPIRE, R. E. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and Systems Sciences*, 1997.
- 23 AGGARWAL C. C.; REDDY, C. K. *DATA CLUSTERING: Algorithms and applications*. [S.l.]: CRC Press, 2014.
- 24 LIMA, V. R. Mestrado em Metrologia Científica e Industrial, *Desenvolvimento e Avaliação de Sistema Neural para Redução de Tempo de Ensaio de Desempenho de Compressores*. Florianópolis: [s.n.], 2010.
- 25 NASCIMENTO, A. Mestrado em Engenharia Mecânica, *Desenvolvimento de Ferramentas Baseadas em Redes Neurais para Inferências e Prognósticos em Ensaios de Desempenho de Compressores Herméticos*. Florianópolis: [s.n.], 2015.