



UNIVERSIDADE FEDERAL DE MINAS GERAIS

ENGENHARIA MECÂNICA

**PREVISÃO DA VAZÃO MÁSSICA EM UMA MÁQUINA
FRIGORÍFICA UTILIZANDO REDES NEURAIS
ARTIFICIAIS**

VINÍCIUS DAVID FONSECA

Belo Horizonte, 25 de abril de 2022

Vinícius David Fonseca

**PREVISÃO DA VAZÃO MÁSSICA EM UMA MÁQUINA
FRIGORÍFICA UTILIZANDO REDES NEURAIAS
ARTIFICIAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. Antônio Augusto Torres Maia

Belo Horizonte

Escola de Engenharia da UFMG

2022

F676p

Fonseca, Vinícius David.

Previsão da vazão mássica em uma máquina frigorífica utilizando redes neurais artificiais [recurso eletrônico] / Vinícius David Fonseca. - 2022.

1 recurso online (98 f. : il., color.) : pdf.

Orientador: Antônio Augusto Torres Maia.

Dissertação (mestrado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Anexos: f. 95-98.

Bibliografia: f. 90-94.

Exigências do sistema: Adobe Acrobat Reader.

1. Engenharia mecânica - Teses. 2. Redes Neurais (Computação) – Teses. 3. Máquinas Térmicas – Teses. I. Maia, Antônio Augusto Torres. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.

CDU: 621(043)



UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

FOLHA DE APROVAÇÃO

PREVISÃO DA VAZÃO MÁSSICA EM UMA MÁQUINA FRIGORÍFICA UTILIZANDO REDES NEURAIS ARTIFICIAIS

VINICIUS DAVID FONSECA

Dissertação submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Minas Gerais, constituída pelos Professores: Dr. Antonio Augusto Torres Maia (Orientador – Departamento de Engenharia Mecânica/UFMG), Dr. Ricardo Poley Martins Ferreira (Departamento de Engenharia Mecânica/UFMG) e Dr. Tiago de Freitas Paulino (CEFET-MG), como parte dos requisitos necessários à obtenção do título de "**Mestre em Engenharia Mecânica**", na área de concentração de "**Energia e Sustentabilidade**".

Dissertação aprovada no dia 27 de maio de 2022.



Documento assinado eletronicamente por **Antonio Augusto Torres Maia, Professor do Magistério Superior**, em 31/05/2022, às 10:52, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Tiago de Freitas Paulino, Usuário Externo**, em 31/05/2022, às 15:55, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ricardo Poley Martins Ferreira, Professor do Magistério Superior**, em 04/06/2022, às 13:13, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1490571** e o código CRC **26E371D9**.

À minha família e aos meus amigos

AGRADECIMENTOS

Aos meus pais, Dilson e Sayonara, que sempre me amaram e apoiaram, e, também, ao meu irmão, Victor, pelo companheirismo e amizade.

Ao Programa de Pós-Graduação em Engenharia Mecânica da UFMG, aos meus colegas e professores, pelo convívio, ajuda e aprendizados.

Ao orientador, Dr. Antônio Augusto Torres Maia, pela paciência na orientação, apoio e incentivo, tornando possível a realização desse trabalho.

O presente trabalho foi realizado com o apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e da Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG).

“A felicidade só é verdadeira se for compartilhada”

Christopher McCandless

RESUMO

A medição da vazão mássica em sistemas de refrigeração com medidores de vazão pode ter custo elevado quando se leva em consideração o valor do próprio equipamento e dos custos relacionados à instalação e manutenção. Um modelo baseado em Redes Neurais Artificiais (RNAs) pode ser utilizado para prever o valor da vazão mássica, a baixo custo, através de parâmetros facilmente observáveis e medidos, como temperaturas. Além disso, correlações bem conhecidas para calcular parâmetros que influenciam diretamente na vazão mássica podem ser usadas para se estimar o valor de alguns dos dados de entrada para a RNA melhorar sua precisão. Dentro deste contexto, o presente estudo tem como objetivo desenvolver um modelo Multilayer Perceptrons (MLP) para prever a vazão mássica de um sistema de refrigeração. Posteriormente é apresentado um medidor de vazão mássica alternativo, utilizando um modelo RNA programado em um circuito microcontrolado com apenas três temperaturas como entradas, desenvolvido e testado no *software* Proteus. Para desenvolver o modelo de RNA, os dados experimentais foram coletados em uma máquina de refrigeração em diversos pontos de operação. Distúrbios de degrau foram introduzidos na vazão mássica para produzir dados em regime transiente. Dois conjuntos de dados diferentes foram considerados no processo de treinamento. O primeiro conjunto de dados continha apenas dados de regime permanente e no segundo conjunto de dados havia dados de regime permanente mais dados transientes. Na validação do modelo, a vazão mássica estimada através da RNA apresentou erro médio de 0,79 % ao considerar os dados permanentes e transientes no processo de treinamento, e 0,81 % ao considerar apenas os dados permanentes no procedimento de treinamento. Em ambos os casos, o erro médio ficou abaixo da incerteza do medidor de vazão utilizado.

Palavras-Chave: Previsão da vazão mássica, Máquinas frigoríficas, Redes Neurais Artificiais

ABSTRACT

Measuring mass flow rate in refrigeration systems with flow meters can be expensive when taking into account the cost of the equipment itself and the costs related to installation and maintenance. A model based on Artificial Neural Networks (ANNs) can be used to predict the value of the mass flow, at low cost, through easily observed and measured parameters, like temperatures. Additionally, well-known correlations to calculate parameters that directly influence the mass flow rate can be used as input data for the ANN to improve its accuracy. Within this context, the present study aims to develop a Multilayer Perceptrons (MLP) model to predict the mass flow rate of a refrigeration systems. Later, it is presented an alternative mass flow rate meter, using an ANN model programmed in a microcontrolled circuit with only three temperatures as inputs, that was developed and tests using the software Proteus. To develop the ANN model, experimental data were collected in a refrigeration machine in several operating points. Step disturbances were introduced in the mass flow rate to produce transient data. Two different data set were considered in the training process. The first data set contained only steady-state data and in the second data set there were steady-state plus transient data. The mass flow rate estimated through the ANN presented an average error of 0.79 % when considering steady-state and transient data in the training process, and 0.81 % when considering only steady-state data in the training procedure. In both cases, the average error was smaller than the mass flow meter uncertainty.

Keywords: Mass flow prediction, Refrigeration machines, Artificial Neural Networks

LISTA DE ILUSTRAÇÕES

Figura 1 – Esquema de um medidor de vazão eletromagnético	16
Figura 2 – Esquema de um medidor de vazão de turbina.....	17
Figura 3 - Esquema de um medidor de vazão de turbina	18
Figura 4 - Esquema de um medidor de vazão mássica Coriolis.....	19
Figura 5 – Fluxograma com o resumo da metodologia.....	26
Figura 6 – Esquema do banco de testes experimentais utilizado	27
Figura 7 – Equação do neurônio artificial	33
Figura 8 – Funções de ativação binária	34
Figura 9 – Funções de ativação	35
Figura 10 – Estrutura do MLP.....	36
Figura 11 – Comparação entre resultados de treinamentos.....	37
Figura 12 – Exemplo de um treinamento resultante em um RNA com <i>overfitting</i>	41
Figura 13 – Fluxograma da estimação da vazão mássica com o sistema microcontrolado	45
Figura 14 – Sistema embarcado desenvolvido no Proteus	46
Figura 15 – Temperatura de evaporação em função do tempo para 650 rpm e 0 °C	50
Figura 16 – Vazão mássica em função do tempo para 650 rpm e 0 °C.....	50
Figura 17 – Temperatura de evaporação original e filtrada, em função do tempo, para 650 rpm e 0 °C	51
Figura 18 – Relação entre a temperatura de evaporação e a vazão mássica	52
Figura 19 – Relação entre a temperatura de condensação e a vazão mássica	53
Figura 20 – Relação entre as pressões de condensação e evaporação e a vazão mássica	53
Figura 21 – Função tangente hiperbólica	55
Figura 22 – Evolução do MSE durante o treinamento e a validação	56
Figura 23 – Testes da RNA com a rotação do compressor de entrada.....	57
Figura 24 – Previsão do ponto 650 rpm e 5 °C com a rotação, temperatura de evaporação e razão das pressões de entrada	58
Figura 25 – Previsão do ponto 750 rpm e 5 °C com a rotação, temperatura de evaporação e razão das pressões de entrada	58
Figura 26 – Evolução do MSE durante o treinamento e a validação para 650 rpm.....	60
Figura 27 – Evolução do MSE durante o treinamento e a validação para 750 rpm.....	60
Figura 28 – Testes da RNA para 650 rpm.....	61

Figura 29 – Testes da RNA para 750 rpm.....	61
Figura 30 – Previsão do ponto 650 rpm e 5 °C	62
Figura 31 – Previsão do ponto 750 rpm e 5 °C	62
Figura 32 – Relação entre a massa específica e a vazão mássica.....	64
Figura 33 – Evolução do MSE durante o treinamento e a validação utilizando a massa específica como entrada.....	65
Figura 34 – Testes da RNA utilizando massa específica na entrada.....	66
Figura 35 – Previsão do ponto 650 rpm e 5 °C com a massa específica de entrada	67
Figura 36 – Previsão do ponto 750 rpm e 5 °C com a massa específica de entrada	67
Figura 37 – Evolução do MSE durante o treinamento com apenas dados de regime permanente	69
Figura 38 – Testes da RNA treinada com dados de regime permanente.....	70
Figura 39 – Previsão do ponto de 650 rpm e 5°C com uma rede treinada apenas com o regime permanente.....	71
Figura 40 – Previsão do ponto de 750 rpm e 5°C com uma rede treinada apenas com o regime permanente.....	71
Figura 41 – Evolução do MSE da rede mais simples treinada com apenas dados de regime permanente.....	75
Figura 42 – Testes da RNA mais simples treinada com dados de regime permanente.....	75
Figura 43 – Previsão do ponto de 650 rpm e 5 °C com uma rede mais simples treinada apenas com o regime permanente.....	76
Figura 44 – Previsão do ponto de 750 rpm e 5 °C com uma rede mais simples treinada apenas com o regime permanente.....	77
Figura 45 – Evolução do MSE da rede mais simples treinada com todos os dados.....	78
Figura 46 – Testes da RNA mais simples treinada com todos os dados	79
Figura 47 – Previsão do ponto de 650 rpm e 5 °C com uma rede mais simples treinada com todos os dados.....	80
Figura 48 – Previsão do ponto de 750 rpm e 5 °C com uma rede mais simples treinada com todos os dados.....	80
Figura 49 – Sistema embarcado desenvolvido em funcionamento no Proteus utilizando o LM35	83
Figura 50 – Relação entre a RNA no PC e a RNA no sistema embarcado com o LM35	84
Figura 51 – Sistema embarcado desenvolvido em funcionamento no Proteus utilizando o LM335	85

Figura 52 – Relação entre a RNA no PC e a RNA no sistema embarcado com o LM33586

LISTA DE TABELAS

Tabela 1 – Comparação qualitativa entre medidores de vazão.....	20
Tabela 2 – Resumo dos modelos matemáticos para compressores alternativos.....	24
Tabela 3 – Equipamentos utilizados na bancada de testes	28
Tabela 4 – Constantes das equações de cálculo do volume específico de vapor saturado e da massa específica	30
Tabela 5 – Constantes da equação de cálculo da pressão saturada.....	31
Tabela 6 – Componentes utilizados no sistema embarcado	46
Tabela 7 – Resultado da primeira otimização dos hiperparâmetros	54
Tabela 8 – Resumo dos resultados utilizando a rotação do compressor, temperatura de evaporação e razão das pressões de entrada	59
Tabela 9 – Resumo dos resultados com uma RNA para cada rotação do compressor.....	63
Tabela 10 – Resumo dos resultados utilizando a massa específica como entrada	68
Tabela 11 – Resumo dos resultados utilizando a massa específica como entrada e apenas dados do regime permanente no treino	72
Tabela 12 – Resumo dos resultados obtidos comparando os modelos com três camadas escondidas e diferentes entradas.....	73
Tabela 13 – Resultado da segunda otimização dos hiperparâmetros	74
Tabela 14 – Resumo dos resultados para a rede mais simples e com apenas dados do regime permanente no treinamento	78
Tabela 15 – Resumo dos resultados para a rede mais simples com todos os dados no treinamento.....	81
Tabela 16 – Comparação do erro médio entre as duas configurações da rede.....	82
Tabela 17 – Matrizes com os pesos do modelo final da RNA	82

LISTA DE SÍMBOLOS

a_i : Constantes

b : Viés do neurônio

$[b_n]$: Matriz de vieses de uma camada da RNA

c : Coeficiente de espaço morto do compressor

$f()$: Função de ativação

$[I_n]$: Matriz de entradas da RNA

\dot{m} : Vazão mássica de fluido refrigerante

μ : Média

n : Razão dos calores específicos do fluido frigorífico

N : Rotação do compressor

η : Rendimento volumétrico do compressor

P : Pressão de saturação

P_c : Pressão de condensação

P_e : Pressão de evaporação

ρ : Massa específica do fluido refrigerante na entrada do compressor

T : Temperatura de saturação

ΔT : Superaquecimento

T_e : Temperatura de evaporação

T_e : Temperatura de evaporação

T_c : Temperatura de condensação

T_o : Temperatura na saída do evaporador

σ : Desvio padrão

r_{max} : Limite superior da escala normalizada

r_{min} : Limite inferior da escala normalizada

v_v : Volume específico de vapor saturado do fluido refrigerante

V : Cilindrada do compressor

w_i : Peso referente ao neurônio i

$[W_n]$: Matriz de pesos de uma camada da RNA

x_i : Entrada do neurônio i

x_n : Amostra normalizada

x_{max} : Valor máximo presente na amostra de dados

x_{min} : Valor mínimo presente na amostra de dados

X : Valor do ponto usado no cálculo do escore

y : Saída do neurônio

Z : Escore Z

SUMÁRIO

1 INTRODUÇÃO	13
1.1 Objetivos gerais	14
1.2 Objetivos específicos	14
2 REVISÃO BIBLIOGRÁFICA	15
2.1 Introdução.....	15
2.2 Medidores de vazão mássica	15
2.3 Modelagem de sistemas de refrigeração.....	20
2.4 Conclusões parciais	24
3 METODOLOGIA.....	25
3.1 Introdução.....	25
3.2 Obter os dados experimentais.....	26
3.3 Definição dos parâmetros de entrada da RNA	28
3.3.1 Cálculo da massa específica	29
3.3.2 Cálculo das pressões.....	30
3.4 Preparação dos dados	31
3.4.1 Limpeza dos dados	31
3.4.2 Normalização dos dados	32
3.5 Redes neurais artificiais.....	32
3.5.1 Função de ativação.....	33
3.5.2 Perceptron multicamadas (MLP).....	35
3.5.3 Treinamento da RNA	36
3.6 Otimização dos hiperparâmetros da RNA	38
3.7 Desenvolvimento da RNA.....	40
3.8 Treinamento da RNA	40
3.9 Validação da RNA.....	43
3.10 Desenvolvimento do sistema microcontrolado para a medição da vazão mássica em tempo real	43
3.10.1 Modelo do sistema embarcado.....	45
3.10.2 Funcionamento do sistema embarcado para a medição da vazão mássica.....	47
3.11 Validação dos resultados da RNA gerados pelo micro controlador	47
4 RESULTADOS E DISCUSSÃO	49
4.1 Introdução.....	49
4.2 Tratamento dos dados experimentais	49
4.2.1 Exemplo dos dados coletados	49

4.2.2 Limpeza dos dados experimentais	51
4.3 Avaliação das possíveis entradas para o modelo	52
4.4 Otimização dos hiperparâmetros	54
4.5 Resultados do primeiro modelo da RNA.....	56
4.5.1 Resultados utilizando a rotação do compressor, temperatura de evaporação e razão das pressões de entrada	56
4.5.2 Resultados utilizando uma RNA para cada rotação do compressor.....	59
4.6 Aprimorando os resultados da RNA.....	64
4.6.2 Resultados do modelo utilizando a massa específica como entrada	65
4.6.3 Comparando resultados com apenas dados de regime permanente no treinamento	68
4.7 Desenvolvimento do modelo do sistema embarcado no <i>software</i> Proteus.....	73
4.8 Resultados da nova otimização dos hiperparâmetros da RNA.....	73
4.9 Resultados do modelo mais simples da RNA.....	74
4.9.1 RNA treinada apenas com dados de regime permanente	74
4.9.2 RNA treinada com dados de regime permanente e transiente.....	78
4.10 Aplicação da nova rede no Proteus.....	82
5 CONCLUSÃO.....	87
6 SUGESTÕES DE TRABALHOS FUTUROS.....	89
7 REFERÊNCIAS BIBLIOGRÁFICAS	90
8 APÊNDICE	95

1 INTRODUÇÃO

Sistemas de refrigeração estão presentes em inúmeras aplicações diferentes, tanto industriais quanto residenciais. Dentro desses sistemas, o compressor influencia diretamente na vazão mássica de fluido refrigerante. Essa vazão mássica possui um impacto significativo na capacidade de refrigeração, sendo, também, uma grandeza importante para se avaliar o desempenho do sistema (He *et al* 2020).

O conhecimento da vazão mássica pode ser importante para o desenvolvimento de correlações e na validação de modelos matemáticos de sistemas de refrigeração. O conhecimento da vazão mássica é importante também para a realização de balanços de energia do sistema, que informa aspectos importantes, como a sua eficiência. Conhecer a vazão mássica também é importante ao se realizar a manutenção preditiva do sistema de refrigeração, podendo ser um indicativo importante de alguma possível falha no sistema.

Considerando a necessidade de se estimar a vazão mássica do fluido refrigerante de forma mais assertiva, várias abordagens podem ser utilizadas. Uma delas é o uso de Redes neurais artificiais (RNAs), que são amplamente utilizadas em sistemas de refrigeração para a previsão de diversos parâmetros. Kamar *et al.* (2013) utiliza esse modelo para prever o coeficiente de performance, o trabalho realizado pelo compressor e a capacidade de refrigeração de um sistema de refrigeração. Kizilkan (2011), e Saleh e Aly (2016) utilizam uma abordagem similar para prever, além dos parâmetros anteriormente citados, a vazão mássica de fluido refrigerante e a irreversibilidade do ciclo. Hosoz e Ertnuc (2006) também utilizaram RNAs em um ar condicionado de um automóvel para prever a vazão mássica.

Nas últimas décadas, o uso de inteligência artificial tem aumentado em função da sua capacidade de se resolver problemas complexos, como mencionado por Azizi e Ahmadloo (2016). Mohanraj *et al.* (2012) também destaca o aumento da utilização de inteligência artificial, mais especificamente para aplicações em sistemas de refrigeração. Uma das principais vantagens do uso de RNAs é a sua capacidade de modelar sistemas complexos, não lineares e com múltiplas variáveis. Normalmente, outras abordagens envolvem equações analíticas mais complexas e várias suposições teóricas. As RNAs conseguem resolver isso extraindo as informações necessárias do treinamento, conseguindo realizar previsões consistentes (Mohanraj *et al.*, 2012).

1.1 Objetivos gerais

O objetivo central deste trabalho é conseguir medir a vazão mássica de fluido refrigerante em uma máquina frigorífica de forma indireta, com a correlação de variáveis facilmente medidas, utilizando redes neurais artificiais.

1.2 Objetivos específicos

O trabalho teve como objetivos específicos a preparação dos dados experimentais, escolha dos parâmetros de entrada de forma a se obter um modelo simples mas com um resultado satisfatório, a otimização do modelo da RNA, e o desenvolvimento de um sistema embarcado capaz de utilizar o modelo. O sistema deve possuir um micro controlador de 8 bits, podendo ser utilizado em uma máquina frigorífica real, com o intuito de substituir um medidor de vazão mássica. O sistema deve ser capaz de medir todas as variáveis necessárias, calcular a vazão mássica, e exibi-la. Com isso é possível criar um protótipo de um produto que pode ser usado como alternativa a um medidor de vazão mássica.

2 REVISÃO BIBLIOGRÁFICA

2.1 Introdução

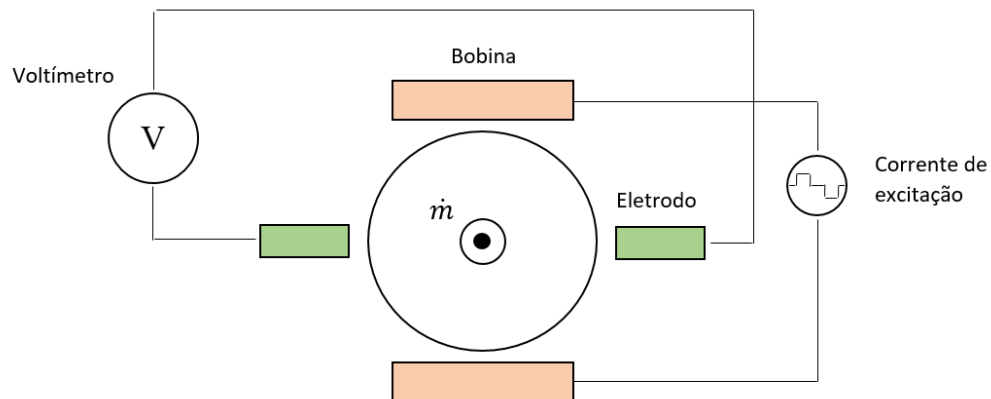
Neste capítulo será apresentada uma visão geral sobre medidores de vazão mássica, abordando algumas de suas características e aplicações. Em seguida, será apresentada a utilização de modelos matemáticos em sistemas de refrigeração, destacando os principais contextos de utilização, objetivos e tipos de modelos.

2.2 Medidores de vazão mássica

Conhecer a vazão mássica em um processo industrial é importante para garantir a qualidade dos produtos e otimizar o consumo energético (Yang et al., 2020a). Para tal, os processos industriais exigem medidores de vazão precisos e confiáveis. Em diversas aplicações envolvendo vazão de fluidos, conhecer a vazão mássica é mais vantajoso do que a vazão volumétrica, em relação aos custos e cálculos envolvendo volumes de controle (Kolhe and Edlabadkar, 2021). Os principais tipos de medidores de vazão mássica de fluidos de uma fase, utilizados na indústria de forma consolidada, são os medidores de turbina, eletromagnéticos, ultrassônicos e de efeito Coriolis (Yang et al., 2020a).

Os medidores de vazão eletromagnéticos são muito utilizados em processos envolvendo o fornecimento de água e na produção de comida. Com um líquido que conduz eletricidade fluindo por um tubo com um campo magnético ortogonal, uma tensão entre eletrodos em lados opostos será induzida por forças de Lorentz. Essa tensão será proporcional à vazão do fluido (Linnert, et al., 2019). A Figura 1 mostra o esquema de um medidor eletromagnético.

Figura 1 – Esquema de um medidor de vazão eletromagnético




Fonte: Autor, 2022

Yang et al. 2020b utiliza medidores de vazão eletromagnéticos junto com sensores de condutância para medir a velocidade superficial da fase da água em uma vazão bifásica de gás e água, mostrando a versatilidade desse tipo de medidor. Além disso, eles possuem a vantagem de não depender da pressão, da temperatura e nem da viscosidade do fluido de trabalho (Linnert, et al., 2019).

Em contrapartida, os medidores de vazão eletromagnéticos possuem um *offset* de medição, que devem ser corrigidos por algum tipo de compensação. A utilização de alguma técnica de compensação pode acarretar no aumento dos gastos com manutenção, redução da precisão e redução da escalada de medidas (Linnert, et al., 2019). Além disso, Yang et al 2020b destaca a dificuldade em se adaptar os parâmetros do medidor para diferentes padrões de escoamento.

Os medidores de vazão de turbinas são utilizados cada vez mais por suas vantagens relativas à alta precisão, boa manutenibilidade e larga escala de medição. São muito utilizados em medições de combustíveis de aeronaves por sua boa repetibilidade e resistência à corrosão (Wang, et al. 2018) e em medições de vazão volumétrica de gases naturais por sua boa acurácia e confiabilidade (Dzemic, Sirok e Bizjan, 2018). Eles funcionam a partir da energia do próprio fluido em escoamento, que é utilizado para mover um rotor colocado na tubulação. Assim, a velocidade de rotação do rotor é proporcional à vazão de fluido. A bobina posicionada na parte externa do tubo consegue contar a passagem das pás do rotor, permitindo calcular a vazão. A Figura 2 ilustra o funcionamento de um medidor de vazão de turbina.

Figura 2 – Esquema de um medidor de vazão de turbina



Fonte: Autor, 2022

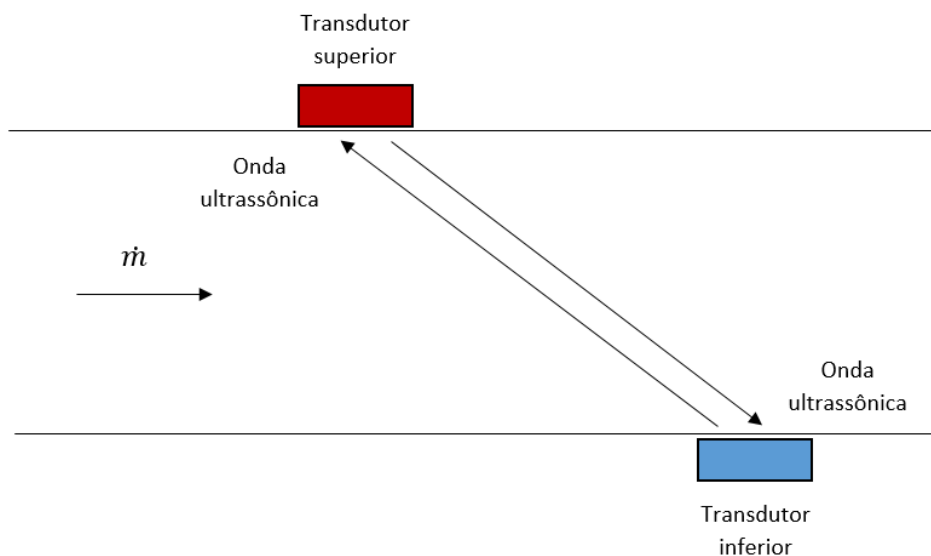
As medições da vazão mássica em situações de regime transiente são necessárias e comuns nas aplicações envolvendo medidores de vazão de turbinas (Wang, et al. 2018). Dzemic, Sirok e Bizjan (2018) apresentaram um estudo para avaliar o desempenho desses medidores em situações de regime transiente, identificando um aumento no erro de medições para o caso de escoamentos em estado de desaceleração. Além disso, nos dois estudos, Wang, et al. 2018 e Dzemic, Sirok e Bizjan, 2018, os autores destacam a dificuldade em se calibrar esses medidores.

Os medidores de vazão ultrassônicos são uma das tecnologias de mais rápido crescimento dentro do campo geral de instrumentos para monitoramento de processos, medições e controle (Lynnworth e Liu, 2006). São muito utilizados, por exemplo, para medir a vazão de vapor em tubos de plantas industriais (Murakawa, *et al* 2020). Esses medidores são versáteis e podem conseguir medir outra grandeza simultaneamente, como temperatura ou massa específica do fluido (Lynnworth e Liu, 2006). Entretanto, na prática, é difícil de se conseguir medições precisas com os medidores ultrassônicos, que, muitas vezes apontam um erro de vazão sendo medida como zero, ou possuem erros aleatórios significativos (Willigen, Massaad e Verweij, 2021).

Um medidor de vazão ultrassônico funciona a partir da emissão e recebimento de uma onda com frequência acima da escuta humana. A emissão e recebimento são realizadas por dois transdutores, que ficam alternando entre emissor e receptor. A vazão do fluido pela qual as

ondas passam é diretamente proporcional à diferença de tempo de viagem das ondas. A Figura 3 mostra um exemplo de funcionamento de um medidor de vazão ultrassônico.

Figura 3 - Esquema de um medidor de vazão de turbina

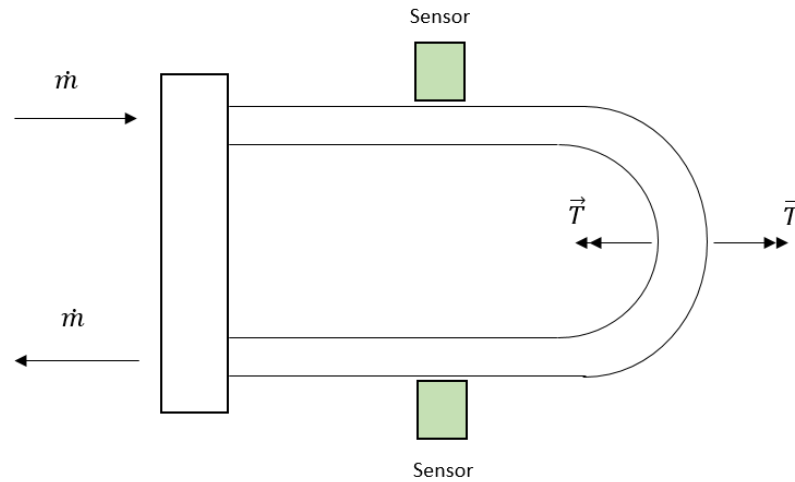


Fonte: Autor, 2022

Nas últimas décadas, o interesse e o uso dos medidores de vazão mássica Coriolis têm aumentado constantemente, sendo utilizados em muitas aplicações industriais (Anklin, Drahm e Rieder, 2006). Portanto, as pesquisas envolvendo medidores de vazão baseados no efeito Coriolis ficaram entre as mais importantes nas últimas duas décadas, na área de desenvolvimento de medidores de vazão mássica (Wang e Roger, 2014).

Nos medidores de vazão mássica do tipo Coriolis o fluido passa por um tubo em forma de U e uma força alternada faz com que o tubo comece a vibrar. Então, o fluido passante induz uma torção no tubo por causa da aceleração de Coriolis. Os sensores na entrada e saída do tubo medem o movimento e a frequência de vibração do tubo, a partir dos seus sinais, é possível calcular a vazão mássica. A Figura 4 ilustra o esquema de funcionamento do medidor de vazão mássica Coriolis.

Figura 4 - Esquema de um medidor de vazão mássica Coriolis



Fonte: Autor, 2022

O medidor Coriolis pode oferecer vantagens como a acurácia, a repetibilidade e a independência das propriedades do fluido (Kolhe e Edlabadkar, 2021). Hu, Chen e Chang (2021) também destacam a alta precisão do medidor de vazão de massa Coriolis por ser menos afetado por fatores como densidade, pressão e temperatura ambiente. Maia (2013), complementa a análise dos medidores de vazão Coriolis discutindo seu alto custo com instalação e manutenção, além disso, também é invasivo e muitas vezes sensível a vibrações e campos magnéticos, o que pode dificultar uma medição correta. Além disso, os medidores de vazão mássica Coriolis também são produtos altamente personalizados, com operação e fabricação complexas, que podem levar cerca de quatro meses para serem produzidos (Hu, Chen e Chang, 2021).

A Tabela 1 resume as principais características de cada tipo de medidor de vazão, comparando-os de forma qualitativa, e incluindo alguns autores que já os utilizaram.

Tabela 1 – Comparação qualitativa entre medidores de vazão

Tipo	Acurácia	Precisão	Invasivo?	Preço (Aproximado)	Princípio de funcionamento	Estudos
Eletromagnético	-	+	-	De R\$ 3.000,00 a R\$ 5.000,00	Forças de Loretz	Linnert, et al., 2019; Yang et al. 2020b
Turbina	+	+	++	R\$ 8.000,00	Rotor	Wang, et al. 2018; Dzemic, Sirok e Bizjan, 2018
Ultrassônico	-	-	-	De R\$ 2.500,00 a R\$ 12.000,00	Ondas ultrassônicas	Lynnworth e Liu, 2006; Murakawa, et al 2020; Willigen, Massaad e Verweij, 2021
Coriolis	++	++	+	Até R\$ 40.000,00	Efeito coriolis	Kolhe e Edlabadkar, 2021; Hu, Chen e Chang, 2021; Anklin, Drahm e Rieder, 2006; Wang e Roger, 2014

Fonte: Autor, 2022

Considerando a necessidade de se medir a vazão mássica de fluidos a um custo baixo, uma abordagem muito comum é a utilização de modelos matemáticos. Existem correlações na literatura que podem ser utilizadas como base para esses modelos, sendo possível estimar a vazão mássica a partir de algumas variáveis conhecidas no sistema.

2.3 Modelagem de sistemas de refrigeração

Modelar um sistema de refrigeração consiste em representar o seu comportamento por meio de relações matemáticas. As relações utilizadas em modelagem de sistemas físicos são normalmente baseadas em princípios físicos fundamentais ou em correlações empíricas que representam a dinâmica do sistema (Maia, 2005).

Os modelos podem ser divididos em diferentes tipos, dentre eles o modelo caixa branca (White-box) e o modelo caixa preta (Black box). Os modelos caixa branca são elaborados a partir das leis físicas que governam o funcionamento do sistema em estudo. Já os modelos caixa preta são elaborados a partir de dados experimentais extraídos do sistema que se deseja modelar. Essa abordagem apenas cria uma relação empírica entre as grandezas de entrada e as grandezas de saída (Wang & Touber, 1991). Dessa maneira, um evaporador, por exemplo, pode ser representado por um conjunto de funções de transferência com diversas constantes obtidas empiricamente.

Um sistema de refrigeração possui componentes com diferentes funções, sendo possível criar modelos individuais para esses componentes com objetivos diferentes. Existem, por exemplo, os modelos que são usados para estimar a vazão mássica no compressor. Esses modelos são necessários no estudo de desempenho dos sistemas de refrigeração, análise energética e simulações dinâmicas (Fang *et al.*, 2014).

De maneira semelhante aos modelos caixa preta, a modelagem por redes neurais artificiais pode ser utilizada para modelar sistemas físicos complexos sem precisar de uma representação matemática explícita. As RNAs podem funcionar como modelos de caixa preta, que não precisam de detalhes a respeito do sistema ou dos equipamentos (Gill & Singh, 2017). Mesmo sem essas informações, as redes conseguem aprender a relação entre as entradas e as saídas baseado nos dados de treinamento (Mohanraj, Jayaraj & Muraleedharan, 2012). Para definir as entradas do modelo, deve-se utilizar grandezas independentes, e todas elas devem se correlacionar à saída de alguma maneira (Zhang, 2005). Assim como nos modelos caixa preta, a faixa de validade do modelo baseado em RNA depende da faixa de operação em que os dados experimentais utilizados no treinamento da rede foram obtidos.

Em sistemas de refrigeração, conhecer as características do fluido refrigerante é essencial para analisar o desempenho do sistema. Dentro desse mesmo contexto, torna-se necessário conhecer a vazão mássica de fluido refrigerante. Definir uma simples função para modelar um problema complexo pode ser difícil, então, soluções com inteligência artificial podem ser utilizadas, como as RNAs. Essa abordagem tem algumas vantagens dentre as quais importa destacar a facilidade em modelar sistemas não lineares, facilidade de entendimento, tolerância para dados imprecisos, cálculo rápido e rápida construção com um bom custo benefício (Gill & Singh, 2017).

Zhang, 2004 utiliza a abordagem das RNAs para construir um modelo capaz de prever a vazão mássica em tubos capilares. Ao construir o modelo, o autor consegue relacionar a vazão mássica com sete entradas diferentes, sendo elas: pressão de entrada, subresfriamento, geometria do tubo, densidade, duas constantes de atrito e uma constante calculada através do calor latente de vaporização.

Saleh e Aly (2016) fizeram um trabalho sobre a previsão da vazão mássica em uma válvula de expansão eletrônica para diferentes fluidos refrigerantes, R22, R407C e R410A. Os autores utilizam RNAs para construir o modelo utilizado no trabalho, e destacam a vantagem dessa abordagem sobre a utilização de modelos de regressão, em que, as redes neurais fornecem

uma alternativa eficiente para criar relações complexas e não lineares sem se conhecer detalhadamente as relações físicas. Além disso, para escolher os parâmetros de entrada para a rede, os autores partem de uma equação teórica. O modelo proposto foi construído utilizando nove entradas diferentes: pressão de entrada, pressão de saída, diferença de pressão, subresfriamento, diâmetro equivalente da válvula de expansão, tensão superficial na entrada, viscosidade na entrada, densidade na entrada, e título na saída.

Uma grande vantagem da utilização de RNAs em sistemas de refrigeração é a capacidade de personalização dos dados de entrada e saída para modelar o sistema. Rosiek e Batlles (2011) realizam testes com diferentes combinações de entradas, atingindo resultados satisfatórios com diferentes opções. No fim, os autores optam por utilizar um modelo alimentado apenas com temperaturas na entrada, com o objetivo de prever o COP e a capacidade térmica de um sistema de refrigeração assistido por energia solar.

Kilzikan (2011) desenvolveu um modelo de RNA para prever a vazão mássica de fluido refrigerante utilizando uma rede com seis entradas diferentes: frequência no compressor, capacidade de refrigeração, temperatura de condensação e evaporação, pressões de condensação e evaporação. O autor utiliza um algoritmo de *backpropagation* e destaca não só o seu bom desempenho, mas também a dificuldade em se selecionar o algoritmo mais apropriado para cada caso, visto que, normalmente, essa escolha é feita por tentativa e erro.

Em uma abordagem alternativa, Ertunc e Hosoz (2005) utilizam um modelo de RNA para prever a temperatura de evaporação, o COP e o trabalho no compressor, utilizando apenas a vazão mássica de fluido refrigerante e a capacidade de refrigeração. Os autores trabalharam em um sistema de refrigeração em cascata, defendendo, também, a vantagem de se utilizar redes neurais para simplificar a modelagem, pois quanto mais complexo o sistema, mais variáveis físicas e geométricas estão envolvidas.

A utilização de RNAs também possui limitações importantes. Mohanraj, Jayaraj e Muraleedharan (2012) destacam a dificuldade em se conseguir resultados precisos sem atingir um estado de *overfitting*. Além disso, as redes neurais não são eficientes em generalizar as previsões fora do conjunto de dados de treinamento e, a otimização dos hiperparâmetros se torna um grande desafio ao buscar resultados satisfatórios.

A maioria dos sistemas de refrigeração opera em condições transientes, sendo possível considerar que um regime permanente puro praticamente não existe. Sendo assim, a modelagem

completa desses sistemas também deve incluir o regime transiente de operação (Wang & Touber, 1991). Nesse contexto, Chiang et al (2014) discutem a dificuldade e a importância de se modelar um sistema de refrigeração que opera em condições transientes quando aplicado a um ar condicionado de automóvel. Como um carro em movimento passa por diferentes ambientes, em velocidades variadas, tem-se uma carga térmica variando constantemente. Os autores desenvolvem um modelo baseado em redes neurais capaz de prever a temperatura dentro da cabine de um automóvel, funcionando como modelo de caixa preta, que pode ser usado em aplicações reais que buscam otimizar esse sistema de refrigeração. Apesar de existirem modelos físicos complexos baseados em equações diferenciais de alta ordem, o uso de RNAs permite um desenvolvimento mais simples e rápido.

Considerando essa necessidade de se medir a vazão mássica de fluido refrigerante a um baixo custo, os modelos matemáticos devem ser considerados, pois podem calcular a vazão a partir de variáveis conhecidas. Nesse contexto, foram analisados modelos matemáticos termodinâmicos capazes de estimar a vazão mássica de fluido refrigerante. A partir desses modelos é possível ter uma ideia do número de variáveis que normalmente são utilizadas como entrada e quais são elas. A Tabela 2 apresenta um resumo dos estudos encontrados na literatura que realizaram uma modelagem de compressores. A maioria dos modelos se encaixa em duas categorias, *phenomena-oriented* (um ou mais volumes de controle) e *construction-oriented* (um ou mais volumes de controle com modelos dinâmicos), conforme descrito por Ramussem e Jakobsen, (2000). Em ambos os casos, o compressor é dividido em partes individuais (volumes de controle), que são acopladas de acordo com vazão mássica e energia. Esses modelos normalmente necessitam de alta capacidade computacional, utilizando algoritmos iterativos em suas resoluções. Em contrapartida, tem-se os modelos de RNAs que, após o treinamento, conseguem operar com uma capacidade de processamento menor, dependendo do tamanho da rede, sendo viáveis em aplicações com sistemas embarcados.

Tabela 2 – Resumo dos modelos matemáticos para compressores alternativos

Estudo	Tipo do modelo	Tipo do compressor
Hafner and Gaspersic (1990)	<i>Construction-oriented</i>	-
Winandy <i>et al</i> (2002)	<i>Phenomena-oriented</i>	Aberto
Hosoz and Ertunc (2006)	Redes Neurais Artificiais	Aberto
Duprez <i>et al</i> (2007)	<i>Phenomena-oriented</i>	-
Castaing-Lasvignottes e Gibout (2010)	<i>Construction-oriented</i>	-
Ndiaye and Bernier (2010)	<i>Construction-oriented</i>	Hermético
Damle <i>et al</i> (2011)	<i>Phenomena-oriented</i>	-
Kizilkan (2011)	Redes Neurais Artificiais	Semi-hermético
Yang <i>et al</i> (2013)	<i>Construction-oriented</i>	Semi-hermético
Kamar <i>et al</i> (2013)	Redes Neurais Artificiais	-
Hu <i>et al</i> (2014)	<i>Construction-oriented</i>	Semi-hermético
Dutra e Deschamps (2015)	<i>Construction-oriented</i>	Hermético
Ledesma <i>et al</i> (2015)	Redes Neurais Artificiais	Aberto
Roskosch <i>et al</i> (2017)	<i>Construction-oriented</i>	Semi-hermético
Gill and Singh (2017)	Redes Neurais Artificiais	Hermético
Duarte <i>et al</i> (2019)	<i>Phenomena-oriented</i>	Aberto
Bell <i>et al</i> (2020)	<i>Construction-oriented</i>	-
Wang <i>et al</i> (2020)	<i>Construction-oriented</i>	Semi-hermético
Kim <i>et al</i> (2021)	<i>Phenomena-oriented</i>	Semi-hermético
Silva e Dutra (2021)	<i>Phenomena-oriented</i>	Hermético

Fonte: Autor, 2022

2.4 Conclusões parciais

Esse capítulo apresentou uma visão geral sobre alguns dos principais medidores de vazão mássica utilizados em aplicações industriais. Além disso, foram apresentados diversos exemplos de aplicações de modelagem em sistemas de refrigeração, com o foco em modelagens utilizando RNAs, que conseguiram alcançar resultados satisfatórios. Apesar disso, em muitos casos a dependência de várias entradas diferentes é grande.

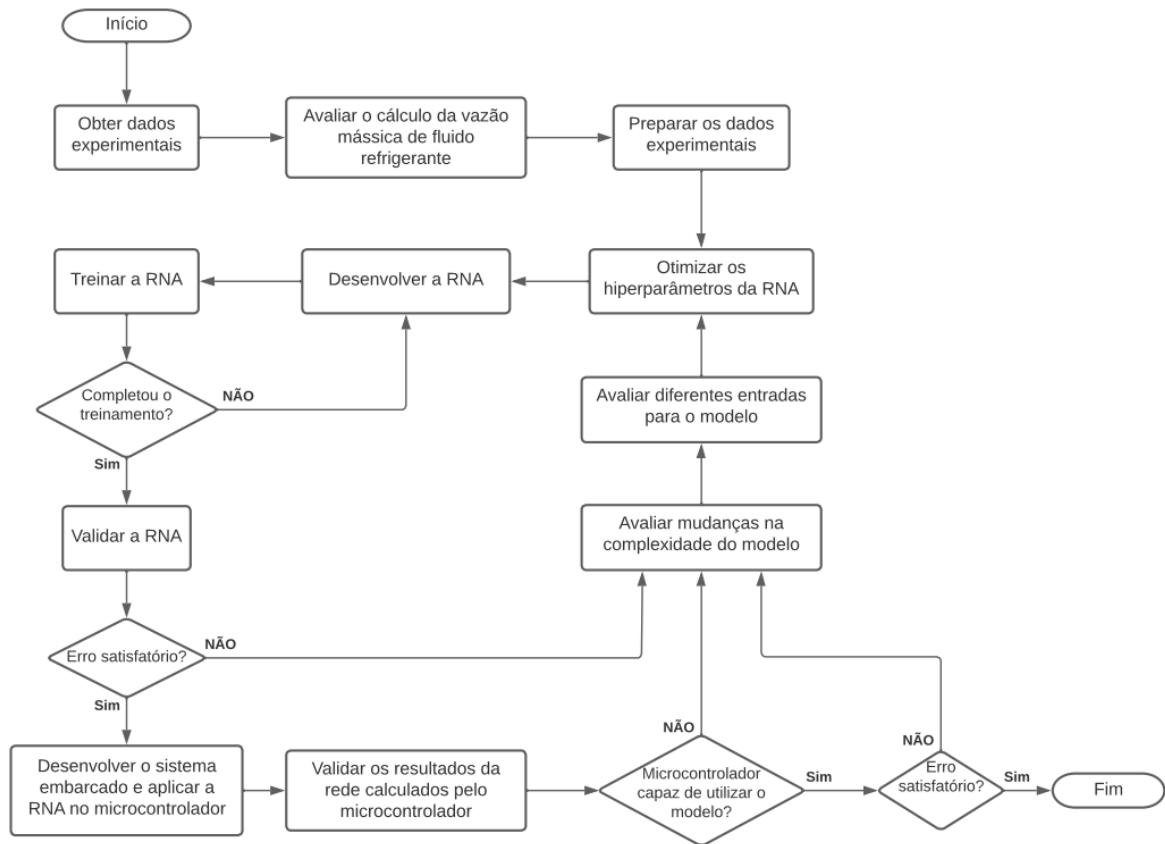
Não foi percebido nos trabalhos pesquisados alguma preocupação de se reduzir o número de variáveis de entrada e de se desenvolver modelos mais simples com poucas camadas e com número reduzido de neurônios. Esses fatores favorecem a resolução dos cálculos necessários de forma mais rápida mesmo com recursos computacionais limitados no que diz respeito à capacidade de processamento e memória.

3 METODOLOGIA

3.1 Introdução

Este capítulo tem como objetivo descrever todos os procedimentos realizados durante o desenvolvimento desse trabalho, que incluem obter os dados experimentais para o treinamento da RNA, avaliar o cálculo da vazão mássica de fluido refrigerante, preparar os dados experimentais, otimizar os hiperparâmetros da RNA, desenvolver a RNA, treinar a RNA, validar a RNA, desenvolver o modelo do sistema embarcado e programar a RNA no microcontrolador e validar os resultados da rede calculados pelo microcontrolador.

A Figura 5 mostra o fluxograma com todas as fases do trabalho e suas interações. Durante a validação da RNA, caso o erro médio do modelo fosse maior que a incerteza dos dados experimentais, era necessário retornar às etapas de treinamento, desenvolvimento ou otimização dos hiperparâmetros, pois a configuração previamente encontrada poderia ser inviável para atingir o desempenho esperado. Na validação dos resultados da rede calculados pelo microcontrolador, caso o sistema embarcado apresente um erro maior que a incerteza dos dados experimentais, a etapa de desenvolver o modelo do circuito pode ser refeita, realizando ajustes e correções. Entretanto, caso exista algum impedimento para o sistema embarcado executar o modelo em RNA, deve-se retornar à etapa de otimização dos hiperparâmetros, trocando as condições de contorno do problema.

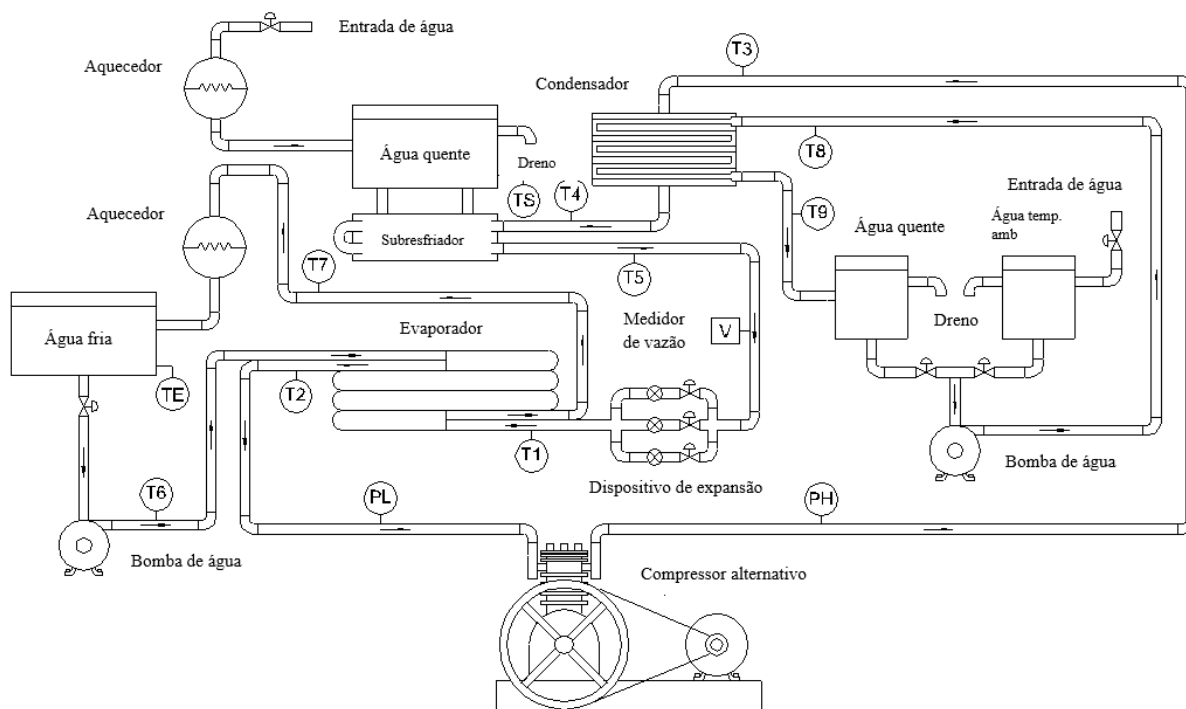
Figura 5 – Fluxograma com o resumo da metodologia

Fonte: Elaborado pelo autor, 2022

3.2 Obter os dados experimentais

Os dados experimentais utilizados nesse trabalho, foram provenientes da tese de doutorado de autoria de Maia (2005). O banco de testes utilizado consistiu em um sistema de refrigeração e aquecimento por compressão de vapor, tendo como fluido primário o R134a e como fluido secundário água pura no evaporador e no condensador. O sistema é composto por um compressor alternativo, um condensador, um evaporador, um subresfriador, três válvulas de expansão montadas em paralelo e um sistema de medição e aquisição de dados. A Figura 6 mostra o esquema da máquina frigorífica utilizada (Maia *et al.*, 2013).

Figura 6 – Esquema do banco de testes experimentais utilizado



Fonte: Maia *et al.*, 2013

Nesse trabalho, foram utilizados os dados de seis ensaios diferentes, com variações na rotação do compressor e na temperatura de evaporação. Em cada um dos ensaios, o sistema foi ligado e operou até atingir um estado de regime permanente. Uma vez nesse estado, a vazão mássica foi reduzida em cerca de 5% através do fechamento parcial da válvula de expansão manual. A partir disso, o sistema começou a operar em regime transiente até ele estabilizar e atingir um novo regime permanente. Portanto, para cada ensaio, foram coletados dados do regime permanente inicial, do regime transiente intermediário, e do novo regime permanente.

As duas rotações utilizadas nos ensaios foram de 650 e 750 rpm. As temperaturas de evaporação foram de $-5\text{ }^{\circ}\text{C}$, $0\text{ }^{\circ}\text{C}$, $5\text{ }^{\circ}\text{C}$ e $10\text{ }^{\circ}\text{C}$. Foram coletados dados de vazão mássica do R134a, temperaturas em diversos pontos da máquina frigorífica e pressões de evaporação e condensação. As medidas de vazão mássica foram feitas por um medidor de vazão a efeito Coriolis da marca Fisher-Rosemount. A sua faixa de medição é de 15 a 200 kg/h. Para as medições de temperatura, foram utilizados nove termopares do tipo T (cobre-constantan), com 1,5 mm de diâmetro, instalados no interior da tubulação, na entrada e saída de cada um dos componentes do sistema. Para as pressões, foram utilizados dois manômetros do tipo Bourdon,

da marca Keywest, instalados na entrada e saída do compressor. O resumo dos equipamentos utilizados e informações sobre os instrumentos de medição estão na Tabela 3.

Tabela 3 – Equipamentos utilizados na bancada de testes

Equipamento	Marca	Características
Compressor	Bitzer	Modelo III, com cilindrada de 157 cm ³ e potência de 7,56 kW
Motor elétrico	Eberle	Rotação nominal 1720 rpm e potência de 3,0 cv
Inversor de frequência	WEG	Modelo CFW08
Condensador	Apema	Tipo casca e tubos com dissipação térmica de 6 kW
Sub-resfriador	-	Coaxial, com potência nominal de 0,4 kW e 10 °C de subresfriamento
Válvula de expansão eletrônica	Danfoss	Modelo TQ-5, orifício N° 1, capacidade nominal 10,8 kW
Válvula de expansão termostática	Danfoss	Modelo TEN2 e capacidade nominal 1,86 kW
Evaporador	-	Coaxial multitubular, potência máxima de refrigeração de 3 kW
Termopares	-	Tipo T, 1,5 mm de diâmetro e incerteza de medição 1,5 °C
Manômetros	Keywest	Incerteza de medição 0,37 MPa
Medidor de vazão a efeito Coriolis	Fisher-Rosemount	Faixa de medição de 15 a 200 kg/h, incerteza de medição de 1,35 kg/h
Tacômetro digital	Mitutoyo	Medições até 5000 rpm

Fonte: Autor, 2022

3.3 Definição dos parâmetros de entrada da RNA

Uma etapa importante na elaboração da RNA é a definição dos parâmetros de entrada mais adequados para se determinar o parâmetro de saída de interesse. Esse processo pode ser melhorado com o conhecimento prévio das variáveis envolvidas e como que elas se correlacionam com a variável de saída. Na definição dos parâmetros de entrada, pode ser útil o conhecimento de relações matemáticas que possam ser usadas para se estimar a vazão mássica.

A estratégia utilizada para se determinar as variáveis de entrada mais adequadas consistiu em investigar a expressão utilizada por Maia *et al.*(2013) para se estimar a vazão mássica (Equação 1).

$$\dot{m} = N \cdot V \cdot \rho \cdot \eta \quad (1)$$

Em que \dot{m} é a vazão mássica de fluido refrigerante na entrada do compressor, N é a rotação do compressor, V é a cilindrada do compressor, ρ é a massa específica do fluido refrigerante na entrada do compressor e η é a rendimento volumétrico do compressor. O rendimento volumétrico pode ser calculado através da Equação 2 (Maia *et al.*, 2013):

$$\eta = 1 + c - c \cdot \left(\frac{P_c}{P_e}\right)^{\frac{1}{n}} \quad (2)$$

Em que η é o rendimento volumétrico do compressor, c é o coeficiente de espaço morto do compressor, P_c é a pressão de condensação, P_e é a pressão de evaporação e n é a razão entre os calores específicos do fluido frigorífico a volume constante e a pressão constante.

Analisando as Equações 2 e 3 é possível perceber que a vazão de fluido refrigerante depende diretamente da rotação do compressor, da massa específica e do rendimento volumétrico. Esse rendimento, por sua vez, depende da razão entre as pressões de condensação e evaporação. Como as pressões estão termodinamicamente relacionadas às temperaturas, foram consideradas como possíveis entradas para o modelo da RNA a rotação do compressor, a massa específica do fluido refrigerante na entrada do compressor, e as temperaturas de condensação e evaporação, e a razão das pressões de condensação e evaporação.

3.3.1 Cálculo da massa específica

A massa específica do fluido refrigerante pode ser estimada através de relações disponíveis na literatura como aquelas propostas originalmente por Cleland em 1986, mostradas nas Equações 3 e 4.

$$\rho = \frac{1}{v_v \cdot (1 + a_1 \cdot \Delta T + a_2 \cdot \Delta T^2 + a_3 \cdot \Delta T \cdot T_e + a_4 \cdot T_e \cdot \Delta T^2 + a_5 \cdot \Delta T \cdot T_e^2 + a_6 \cdot (\Delta T \cdot T_e)^2)} \quad (3)$$

$$v_v = \exp\left(\left(a_7 + \frac{a_8}{T_e + 273.15}\right) \cdot (a_9 + a_{10} \cdot T_e + a_{11} \cdot T_e^2 + a_{12} \cdot T_e^3)\right) \quad (4)$$

Em que v_v é o volume específico de vapor saturado do fluido refrigerante, T_e é a temperatura de evaporação, ΔT é o super aquecimento, e a_1 a a_{12} são constantes, cujos valores são mostrados pela Tabela 4.

Tabela 4 – Constantes das equações de cálculo do volume específico de vapor saturado e da massa específica

Constante	Valor
a_1	$5.029847 \cdot 10^{-3}$
a_2	$-5.313493 \cdot 10^{-6}$
a_3	$2.696488 \cdot 10^{-5}$
a_4	$-1.603707 \cdot 10^{-7}$
a_5	$4.673455 \cdot 10^{-7}$
a_6	$-2.016173 \cdot 10^{-9}$
a_7	$-1.2408669 \cdot 10^1$
a_8	$2.658307450 \cdot 10^3$
a_9	1.006543
a_{10}	$6.990186 \cdot 10^{-4}$
a_{11}	$-4.971119 \cdot 10^{-6}$
a_{12}	$-3.051019 \cdot 10^{-7}$

Fonte: Cleland, 1986

A vantagem de se utilizar essas equações é que a temperatura de evaporação necessária já seria utilizada como entrada do modelo. Então, basta apenas acrescentar o valor do superaquecimento. Obter a massa específica do fluido refrigerante a partir das relações de Cleland (1986) apenas utilizando medições de temperatura é vantajoso para se conseguir um código computacional final mais simples e funcional para ser utilizado em um sistema microcontrolado.

3.3.2 Cálculo das pressões

De forma semelhante ao cálculo da massa específica, foi decidido que seriam usadas as medições de temperaturas para se calcular as pressões. Considerando que os sistemas embarcados possuem limitações de processamento e de memória, é sempre desejável optar por soluções mais simples. Como as pressões que serão utilizadas nos modelos são as pressões de saturação, tanto da evaporação quanto da condensação, elas podem ser estimadas a partir das temperaturas de evaporação e de condensação, respectivamente, utilizando a Equação 5, proposta por Cleland, 1986.

$$P = \exp \left(a_{13} - \frac{a_{14}}{T + a_{15}} \right) \quad (5)$$

Em que, P é a pressão de saturação, T é a temperatura de saturação, e a_{13} a a_{15} são constantes cujos valores são mostrados pela Tabela 5.

Tabela 5 – Constantes da equação de cálculo da pressão saturada

Constante	Valor
a_{13}	21.30086
a_{14}	2087.523
a_{15}	239.58

Fonte: Cleland, 1986

3.4 Preparação dos dados

Antes de se utilizar os dados experimentais para o treinamento da RNA é necessário realizar alguns procedimentos prévios de limpeza e normalização.

3.4.1 Limpeza dos dados

Levando em consideração as imperfeições do sistema de medição, todas as medições experimentais sempre estão sujeitas a ruídos e variações no resultado. Então, é necessário realizar uma limpeza dos dados experimentais, de forma a eliminar os *outliers*, que são os dados experimentais que se diferenciam drasticamente de todos os outros, provavelmente causados por erros durante as medições. Para isso, o filtro escolhido foi o escore Z , mostrado pela Equação 6 (Angoff, 1984):

$$Z = \frac{X - \mu}{\sigma} \quad (6)$$

Em que, Z é o escore Z do ponto em questão, X é o valor do ponto, μ é a média e σ é o desvio padrão. Para cada ponto, o escore Z foi calculado e, caso o seu valor seja maior que 1,0, o ponto é considerado um *outlier*, provavelmente causado por algum ruído ou erro de medição. Nesse caso, o valor do ponto é substituído pela média local das medições próximas.

3.4.2 Normalização dos dados

O modelo das redes neurais funciona multiplicando todas as entradas por diversos pesos, e somando os resultados até chegar na saída do modelo. Todos esses pesos são valores entre 0 e 1. Caso as entradas não sejam normalizadas para a mesma faixa de valores, a ordem de grandeza de cada variável influenciaria no cálculo dos pesos durante o treinamento, uma vez que a RNA entenderia os valores maiores como mais significativos para o cálculo das saídas. Assim, após a limpeza dos dados, todos os dados foram normalizados para se estabelecerem dentro da faixa de 0 a 1. Essa normalização foi feita utilizando a Equação 7:


$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \cdot (r_{max} - r_{min}) + r_{min} \quad (7)$$

Em que x_n corresponde ao valor normalizado, x ao valor inicial, x_{min} o menor valor daquela variável, x_{max} o maior valor daquela variável, r_{max} o limite máximo da nova escala e r_{min} o limite mínimo da nova escala. A escala utilizada nesse trabalho foi de 0 a 1.

Com os dados limpos e normalizados, antes de serem utilizados na RNA, foi necessário dividi-los entre dados de treinamento, validação e teste. Os dados de treinamento são utilizados para ajustar o modelo. Os de validação são para avaliar o andamento do treinamento, de forma a evitar que a RNA atinja o estado de *overfitting*. Estes dados passam pela rede com uma frequência menor que os dados de treinamento. Os dados de teste são utilizados para verificar se a RNA realmente conseguiu aprender e se conseguiu generalizar as previsões com resultados satisfatórios. A proporção escolhida para o trabalho foi de 70% dos dados para o treinamento, 15% para a validação e 15% para os testes. Essa divisão é comumente vista em trabalhos na área, como Mohanraj, Jayaraj e Muraleedharan, (2012), e Hosoz e Ertnuc, (2006).

3.5 Redes neurais artificiais

As redes neurais artificiais (RNAs) são baseadas nos neurônios biológicos e sistemas nervosos. A estrutura das redes é baseada no modelo de um neurônio artificial, que surgiu com a intenção de imitar a realidade biológica (Barreto, 2002). O funcionamento do neurônio artificial foi interpretado como sendo um circuito binário e sua estrutura é mostrada na Figura 7. Este modelo de neurônio é uma generalização do primeiro modelo de um neurônio artificial que foi proposta por McCulloch e Pitts (1943).

Figura 7 – Equação do neurônio artificial

Fonte: Adaptado de Haykin, 2009


A Figura 5 ilustra todos os componentes principais que envolvem um neurônio artificial, sendo eles: a entrada (x_i), os pesos de cada entrada (w_i), o viés (b), a função de ativação (f) e a saída (y). A ideia por trás do neurônio artificial consiste em se somar várias entradas diferentes multiplicando-as pelos respectivos pesos. Depois o viés do neurônio é somado, e o valor obtido passa pela função de ativação para se obter a saída do neurônio, Equação 8.

$$y = f\left(\sum_{i=1}^n x_i w_i + b\right) \quad (8)$$

Em que x_i é a entrada, w_i é o peso do neurônio, b é o viés, f é a função de ativação e y é a saída do neurônio.

3.5.1 Função de ativação

É possível dividir as funções de ativação em dois tipos principais, linear ou não-linear (Haykin, 2009). O modelo original proposto por McCulloch e Pitts (1943) utilizava uma função de ativação binária, emitindo uma saída de 0 ou 1 (Figura 8). Posteriormente, a utilização de funções de ativação não-lineares foi proposta. A utilização desse tipo de funções permitiu a criação de modelos que solucionam problemas não-lineares (Barreto, 2002).

Figura 8 – Funções de ativação binária

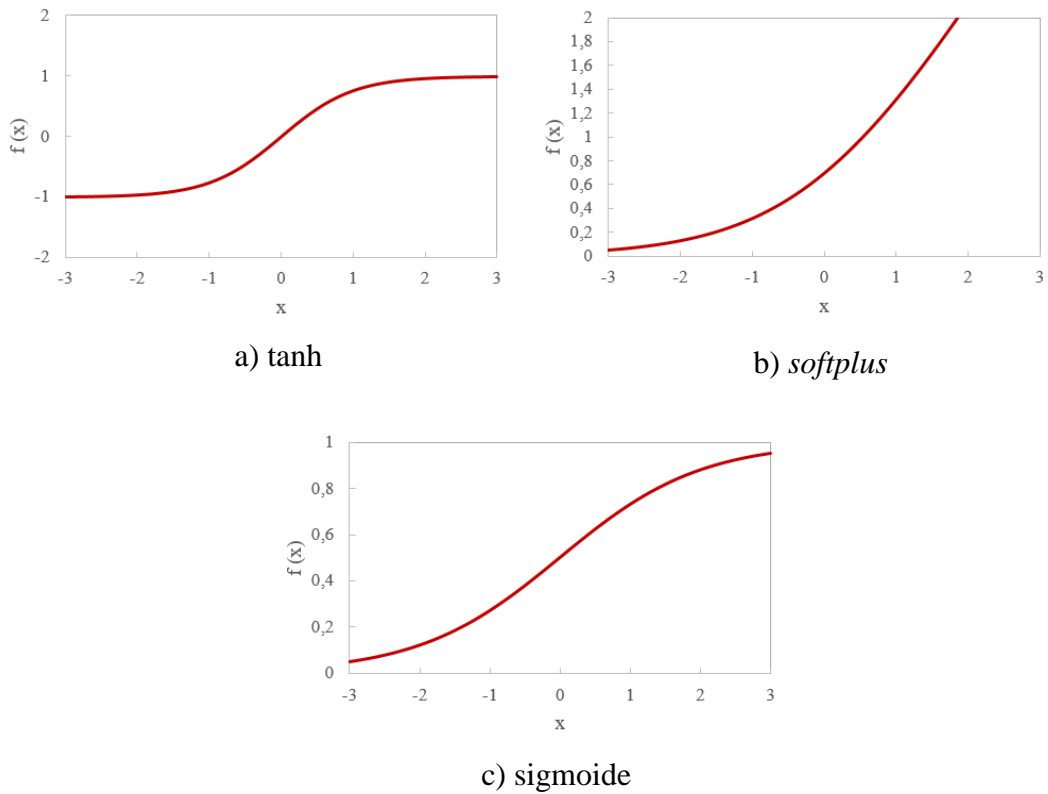
Fonte: Autor, 2022

Dentre as principais funções de ativação não-lineares, tem-se a tangente hiperbólica (\tanh), a *softplus*, e a sigmoide. As Equações 9, 10 e 11, são das funções \tanh , *softplus* e sigmoide, respectivamente. A Figura 9 mostra o comportamento de cada uma delas. É possível perceber que a \tanh (a) varia a saída de -1 a 1, sendo que com uma entrada de acima de 1, ou abaixo de -1, a variação fica cada vez menor. Já a *softplus* possui apenas saídas positivas, sendo que a partir de 0, o valor da saída aumenta cada vez mais. A sigmoide (c), tem um comportamento semelhante à \tanh , porém, possui saídas apenas entre 0 e 1. O tipo de função de ativação que deve ser escolhida depende de cada problema. A maneira mais segura de se escolher a função mais adequada é realizando testes para verificar qual delas consegue modelar o problema com um erro menor.

$$f(x) = \frac{(1 - e^{-2x})}{(1 + e^{-2x})} \quad (9)$$

$$f(x) = \ln(1 + e^x) \quad (10)$$


$$f(x) = \frac{1}{(1 + e^{-x})} \quad (11)$$

Figura 9 – Funções de ativação

Fonte: Autor, 2022

3.5.2 Perceptron multicamadas (MLP)

A combinação de vários neurônios artificiais permite a construção de diversos modelos de RNAs diferentes. Um deles é o perceptron multicamadas, apresentado na Figura 10. Ele consiste na combinação de uma camada de entrada, camadas escondidas e uma camada de saída. Cada camada possui um determinado número de neurônios, uma matriz de pesos e um vetor de saída.

Figura 10 – Estrutura do MLP

Fonte: Adaptado de Hykin, 2009

É possível dividir dois tipos de fluxo de informação no modelo do MLP. A entrada de um dado que propaga por cada neurônio da rede até gerar uma saída (*feedforward*). E o sinal de erro, proveniente da camada de saída, que é utilizado para corrigir os valores dos pesos da RNA (*backpropagation*).

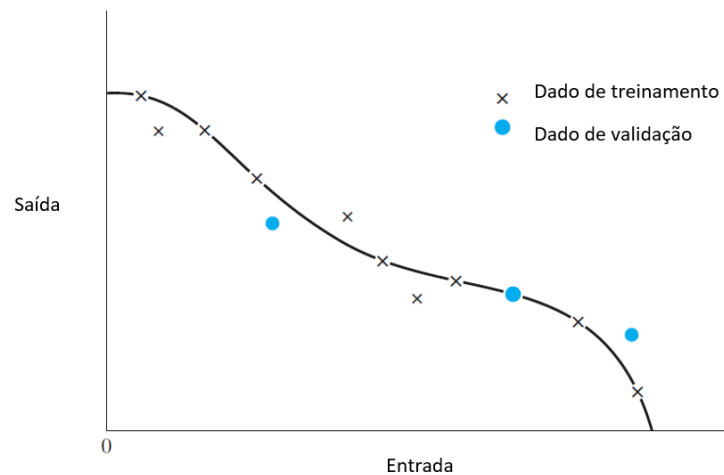
3.5.3 Treinamento da RNA

Existem dois tipos de aprendizado mais comuns ao treinar uma RNA, o supervisionado e o não supervisionado. No aprendizado supervisionado, tem-se exemplos de entradas e saídas. A rede é alimentada com os dados de entrada, e compara-se o resultado com a saída desejada. Então, a diferença entre os valores obtidos e esperados é usada para corrigir os pesos dos neurônios. No aprendizado não supervisionado o resultado final não é fornecido, então o modelo deve encontrar os padrões ou a estrutura dos dados sozinho (Barreto, 2002).


O aprendizado supervisionado com a utilização do *backpropagation* para realizar as correções dos pesos tem como objetivo final fazer com que a RNA consiga generalizar. Para avaliar isso, os dados são divididos em dados de treinamento e dados de teste. Caso a rede consiga uma saída correta com os dados de teste que não foram utilizados na sua criação e nem no treinamento, é considerado que a rede conseguiu aprender (Haykin, 2009).

Uma RNA treinada tem o resultado considerado satisfatório mesmo que os valores sejam pouco diferentes do esperado, visto que, erros nas previsões, tanto do treinamento quanto da validação, são esperados. Caso o modelo treine demais a ponto de atingir resultados totalmente corretos, pode-se ter alcançado um estado de *overtraining* ou *overfitting*. No *overfitting*, o modelo gerado se torna mais complexo que o necessário, apesar de conseguir prever os resultados com um erro mínimo, sua generalização fica comprometida. A Figura 11 mostra a diferença nas previsões entre um modelo sem *overfitting* (a) e com *overfitting* (b) (Hayking, 2009).

Figura 11 – Comparação entre resultados de treinamentos



a) Sem *overfitting*



b) Com *overfitting*

3.6 Otimização dos hiperparâmetros da RNA

Para se construir um modelo de redes neurais artificiais é necessário definir diversos hiperparâmetros, como o número de camadas escondidas e o número de neurônios. Na literatura não existe um consenso sobre o valor ideal para cada hiperparâmetro, porque dependendo do problema e dos dados experimentais, esse ideal pode ser diferente. Isso torna mais difícil o processo de se encontrar um modelo otimizado.

Existem algoritmos de otimização para se determinar o melhor conjunto de hiperparâmetros. Dentre os algoritmos de otimização mais utilizados em trabalhos envolvendo o uso de redes neurais artificiais, tem-se o algoritmo de busca em grade, busca aleatória e o *hyperband*. A busca em grade cria um modelo para cada uma das possíveis combinações, treina o modelo, e avalia o resultado. Após treinar todos, ele consegue indicar a melhor combinação. A desvantagem desse modelo está no tempo de processamento, visto que criar e treinar todas as combinações possíveis demanda um enorme esforço computacional. A busca aleatória, por sua vez, cria apenas alguns modelos aleatórios dentre todas as opções possíveis, apesar de não testar todas as combinações, esse algoritmo consegue chegar em um ótimo local de forma mais eficiente que a busca em grade, conforme mostrado no trabalho realizado por Bergstra e Belgio, 2012. Por último, tem-se o algoritmo *hyperband*, proposto por Li *et al* (2018), que funciona de forma semelhante à busca aleatória, porém utilizado uma parada antecipada no treinamento, caso a configuração testada não seja válida, e uma alocação de recursos computacionais de forma inteligente, de forma a otimizar a busca. Conforme mostrado por Li *et al* (2018), o *hyperband* consegue chegar em um resultado melhor e de forma mais eficiente, por isso ele foi escolhido como algoritmo de otimização para esse trabalho.

Foi decidido utilizar um *framework* da biblioteca *Keras* (biblioteca de código aberto para o desenvolvimento de redes neurais) para a otimização dos hiperparâmetros da RNA. O *KerasTuner* é um *framework* simples e eficiente, que consegue buscar a configuração ótima local dentro do limite definido para cada hiperparâmetro. Ele possui diversos algoritmos que podem ser utilizados incluindo o *hyperband*.

Os hiperparâmetros otimizados pelo algoritmo foram: função de ativação, otimizador, número de neurônios e camadas escondidas, taxa de dropout e taxa de aprendizado. Todos eles foram descritos a seguir.

Função de ativação: A função de ativação é quem define a saída de um neurônio a partir de uma determinada entrada. As funções discretas transmitem apenas uma saída de 0 ou

1 do neurônio, mantendo a linearidade do modelo. Por isso, funções de ativação não lineares são utilizadas para resolver problemas complexos. A escolha da função de ativação impacta no modelo como um todo, pois ela pode afetar no resultado final, mudando o desempenho, e também no treinamento, mudando o esforço computacional.

Otimizador: O otimizador utilizado nas RNAs serve para calcular as correções dos pesos da rede durante o treinamento, tendo como objetivo encontrar a melhor configuração possível para o modelo. Dependendo do otimizador escolhido pode-se obter um resultado melhor. O otimizador influencia diretamente na dificuldade de se realizar o treinamento e no esforço computacional.

Número de neurônios e camadas escondidas: O número de neurônios e camadas escondidas possuem influências semelhantes sobre o modelo da RNA. Eles estão diretamente ligados à complexidade do modelo. Quanto maiores, melhor pode ser o resultado final, pois pode-se obter um modelo mais preciso e que define melhor o problema. Porém, quanto mais neurônios e camadas, mais difícil e demorado é o treinamento, além de aumentar a chance de se ter um *overfitting* ou uma dissipação do gradiente, no caso de RNAs com muitas camadas escondidas. O *overfitting* acontece quando o modelo aprende demais, atingindo um alto nível de adequação aos dados de treinamento, memorizando esses dados e perdendo a sua capacidade de generalização. A dissipação do gradiente é quando o gradiente da função de perda se aproxima cada vez mais de zero, dificultando as correções dos pesos da RNA e, conseqüentemente, impossibilitando o treinamento da rede.

Taxa de dropout: A taxa de *dropout* é utilizada afim de se evitar um *overfitting*. Ela é utilizada para se cancelar alguns dos pesos da RNA, tornando o modelo mais simples. Isso pode resultar em uma generalização melhor do modelo.

Taxa de aprendizado: A taxa de aprendizado define a porcentagem da correção que será utilizada após cada iteração durante o treinamento. Quanto maior for a taxa de aprendizado, mais rápido a rede aprende, porém, mais difícil é de se alcançar um ponto ótimo local. Por outro lado, quanto menor a taxa de aprendizado, maior é o esforço computacional e maior a chance do algoritmo de otimização ficar preso no primeiro ótimo local atingido.

3.7 Desenvolvimento da RNA

Com os dados experimentais prontos e os hiperparâmetros definidos foi possível iniciar a construção do modelo de redes neurais artificiais. Ele foi desenvolvido utilizando a linguagem de programação *Python*. De acordo com a *Python Software Foundation*, *Python* é uma linguagem de alto nível, orientada a objetos, de fácil utilização, amplamente utilizada em aplicações envolvendo redes neurais artificiais. Nesse contexto foi escolhido utilizar uma biblioteca para a criação de modelos de redes neurais artificiais, por oferecerem mais simplicidade na elaboração dos códigos e uma variedade maior de personalização de funcionalidades do modelo. Para isso, a biblioteca *Keras* foi escolhida, por ser amplamente utilizado por grandes organizações pelo mundo, como a NASA e a CERN. Ele foi criado englobando o *Tensorflow 2*, que é a principal biblioteca de código aberto utilizada para elaborar modelos de *Machine Learning*.

Para auxiliar na elaboração do código em *Python* foram utilizadas também outras bibliotecas de código aberto, que facilitam a leitura dos dados experimentais, manipulação dos dados e análise dos resultados. Elas foram:

- *Numpy*: é um pacote fundamental utilizado em *python* que fornece um objeto de matriz multidimensional com vários objetos derivados, utilizada para operações rápidas com matrizes (Numpy, 2021);
- *Pandas*: um pacote feito para *python* que fornece uma estrutura de dados rápida e flexível para trabalhar com dados relacionais (Pandas, 2021);
- *Scikit-learn*: é uma biblioteca com ferramentas simples para uma análise preditiva e pré-tratamento de dados (Scikit-learn, 2021);
- *Matplotlib*: é uma biblioteca abrangente para a criação de visualizações estáticas, animadas e interativas em *python* (Matplotlib, 2021).

Dentro do contexto das RNAs, o tipo de rede escolhido para esse trabalho foi a rede *Multilayer Perceptron* (MLP), por ser um tipo de rede simples, que é específica para descobrir uma relação complexa e não linear entre as entradas e saídas desejadas.

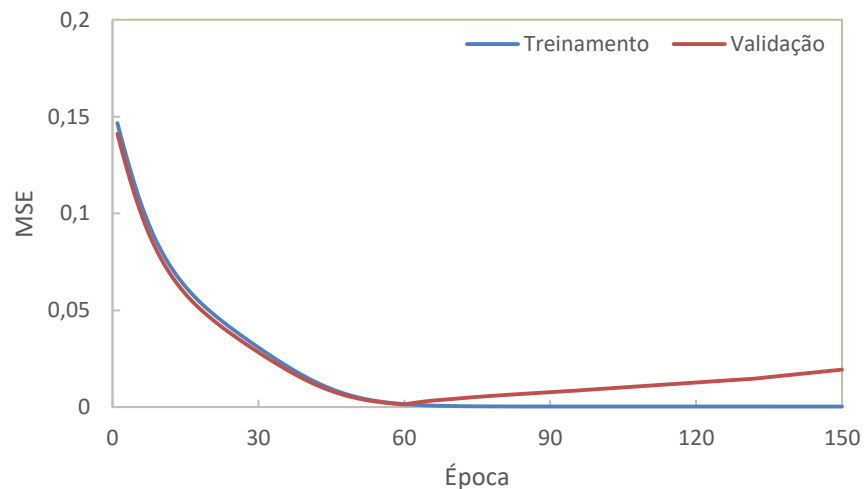
3.8 Treinamento da RNA

Com o modelo da RNA definido e desenvolvido, é possível realizar o treinamento do modelo. Essa é a parte mais difícil em um trabalho com redes neurais, sendo a grande

desvantagem desse modelo. O treinamento de uma RNA pode ser demorado e não levar a resultados satisfatórios no final. Além disso, existem vários tipos de problemas possíveis dependendo do modelo, como o *overfitting*, e a explosão ou dissipação do gradiente.

A fim de evitar o *overfitting*, os treinamentos foram feitos utilizando condições de parada. Elas interrompem o processo de treino assim que os resultados dos dados de teste começam a piorar, enquanto os dos dados de treinamento melhoram. Isso indica que o modelo criado pela RNA está ficando mais complexo que o necessário, e ela está apenas memorizando os dados de treinamento, perdendo a capacidade de generalização. A Figura 12 mostra o momento em que a RNA atinge um estado de *overfitting* com 60 épocas, em que ela começa a piorar a sua capacidade de generalização, apesar do erro durante o treinamento diminuir. O erro médio quadrático (MSE) de cada época, é calculado pela Equação 12.

Figura 12 – Exemplo de um treinamento resultante em um RNA com *overfitting*



Fonte: Elaborado pelo autor, 2022

$$\text{MSE} = \frac{\sum_{i=1}^n (d_i - y_i)^2}{n} \quad (12)$$

Em que, MSE é o erro médio quadrático, d_i é o valor real de uma amostra, y_i é o valor previsto dessa amostra, e n é o número de pontos.

O problema da explosão do gradiente depende muito dos hiperparâmetros utilizados. Ele acontece quando o erro da rede aumenta, resultando em uma correção maior para os pesos, o que gera um erro ainda maior, fazendo com que as correções cheguem em valores tão altos que o treinamento não consegue prosseguir. Caso esse seja um problema recorrente, pode ser necessário mudar o otimizador, a função de ativação, ou até mesmo criar limites para os valores dos gradientes.

A dissipação do gradiente é mais comum em rede neurais profundas, com mais de uma camada oculta, e com funções de ativação sigmóides. Como no *backpropagation* o cálculo da derivada da função de ativação é feito para cada camada, caso ele seja feito várias vezes, o resultado da derivada se aproxima cada vez mais de uma reta fixa em zero, o que resulta na perda da capacidade de correção da RNA. A melhor forma de se evitar esse problema é com redes neurais mais simples, com menos camadas escondidas, e que utilizem funções de ativação menos sensíveis a esse comportamento.

Com o treinamento da RNA finalizado, é possível obter o modelo usado para prever a vazão mássica na forma de uma equação matricial, que poderá ser utilizada em um micro controlador. A Equação 13 mostra um exemplo do equacionamento para uma rede com uma camada escondida, no caso de múltiplas camadas, a equação final repete o processo de multiplicação pelos pesos, soma das tendências e cálculo do resultado pela função de ativação:

$$\dot{m} = f (f ([I_n] \cdot [W_1] + [b_1]) \cdot [W_2] + [b_2]) \quad (13)$$

Em que \dot{m} corresponde à vazão mássica do fluido refrigerante, $[I_n]$ à matriz de entradas, $[W_1]$ à matriz de pesos da entrada para a camada escondida, $[b_1]$ à matriz de tendências da camada escondida, $[W_2]$ à matriz de pesos da camada escondida para a camada de saída, $[b_2]$ à matriz de tendências da camada de saída e $f()$ à respectiva função de ativação.

O processo de escrever o modelo da rede em forma de uma equação matricial é essencial para o desenvolvimento do código utilizado no sistema embarcado. Ele permite a criação de um código capaz de reproduzir os cálculos realizados pela RNA em qualquer linguagem de programação, utilizando apenas operações simples.

3.9 Validação da RNA

Depois do treinamento, a rede deve ser validada de forma a avaliar se as previsões de dados completamente novos foram satisfatórias. Para isso são utilizados os dados de teste que nunca foram vistos pela rede. A importância de se ter esses dados reservados é avaliar como a RNA se comportaria em um caso real, com novas medições. Essa é a etapa mais importante da criação da RNA, pois é ela que verifica se o processo de otimização e treinamento deram certo.

Caso os resultados não sejam satisfatórios, deve-se retornar a algum dos passos anteriores, podendo refazer o treinamento, tentar uma nova otimização dos hiperparâmetros, mudar os dados de entrada da rede, ou até mesmo mudar a preparação dos dados experimentais.

O treinamento da rede é feito com a inicialização dos pesos de forma aleatória, o que normalmente produz um resultado diferente para cada treinamento. Caso a validação dê errado, pode se ter a causa em algum problema com o treinamento. Outra opção é refazer a otimização dos hiperparâmetros. Como um processo de otimização dificilmente encontra o ponto ótimo global, pode-se tentar buscar um novo ponto ótimo local de forma a se desenvolver um novo modelo que se adeque melhor ao problema proposto. Caso a otimização tenha resultado em uma boa configuração e o treinamento dê certo, mas mesmo assim os resultados não sejam satisfatórios, pode ser necessário rever a escolha de dados de entrada para a rede. É possível que apenas com as informações fornecidas seja inviável atingir os resultados desejados. Isso torna necessário providenciar novas entradas para o modelo.

Outra razão possível é que os dados experimentais são suficientes, porém foram tratados de forma errada, ou então a normalização utilizada não atende ao problema em questão. Isso faz com que seja necessário refazer a etapa de preparação dos dados experimentais.

3.10 Desenvolvimento do sistema microcontrolado para a medição da vazão mássica em tempo real

Um dos objetivos desse trabalho é a elaboração de um produto capaz de medir a vazão mássica de fluido refrigerante de uma máquina frigorífica de forma não invasiva. Para isso, foi elaborado um sistema embarcado utilizando o *software Proteus 8*, atuando como uma alternativa a um medidor tradicional. Esse programa é muito utilizado em aplicações semelhantes pois permite a simulação de sistemas eletroeletrônicos microcontrolados.

Para construir o modelo do sistema embarcado, foi utilizado um micro controlador PIC 16F877A, um display de LCD para mostrar a medição da vazão mássica em tempo real e três sensores de temperatura. A rotação do compressor foi calculada através da contagem do número de pulsos recebidos do compressor em um pino digital do próprio PIC.

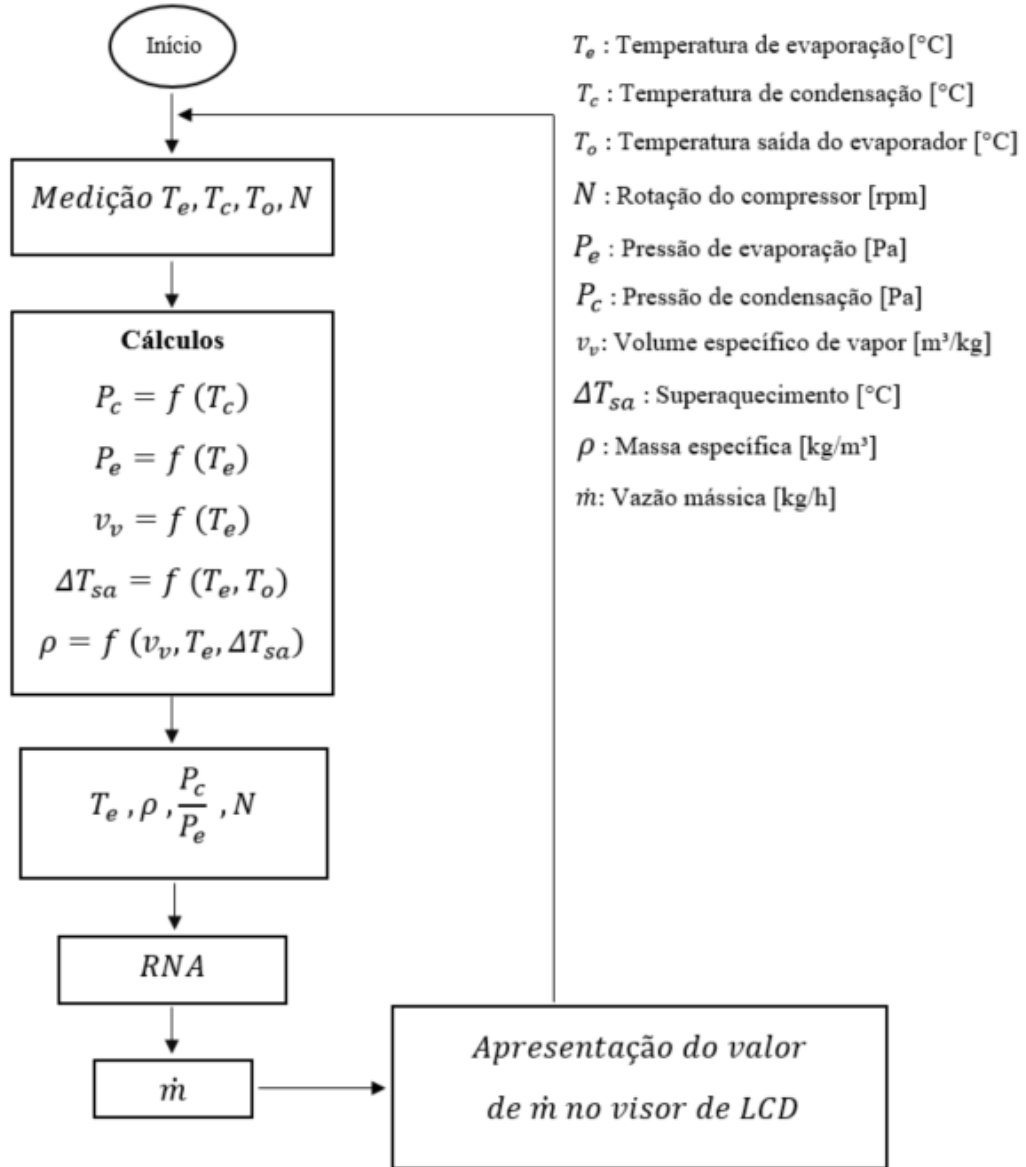
Para os sensores de temperatura, dois modelos amplamente utilizados em sistemas embarcados foram avaliados. Primeiramente, o sistema foi feito com o LM35, um sensor que mede a temperatura com uma tensão de saída proporcional à temperatura medida em Celsius ($10 \text{ mV}/^{\circ}\text{C}$). A principal desvantagem desse sensor sendo que ele é que ele gera tensões negativas para temperaturas abaixo de zero, tornando necessário a inclusão de componentes adicionais para adequar esses sinais à faixa de medição do microcontrolador. Depois, também foi utilizado o LM335, que, por sua vez, mede a temperatura proporcional à temperatura medida em Kelvin ($10 \text{ mV}/^{\circ}\text{K}$), porém, consegue medir temperaturas negativas diretamente, sempre produzindo tensões positivas de saída. Como a temperatura varia constantemente ao longo do tempo de forma analógica, é necessário acoplar a saída dos sensores nos pinos analógicos do microcontrolador, que consegue transformar o sinal digital do sensor em uma medição analógica de temperatura, utilizando com um conversor A/D.

Com o circuito do sistema embarcado pronto, foi possível programar o código da RNA desenvolvida no microcontrolador. Sistemas embarcados possuem limitações importantes tanto em relação à memória quanto em relação ao processamento. Em contra partida, redes neurais podem envolver equações complexas para solucionar o problema proposto. Caso o modelo da rede neural seja muito grande, pode ser que o micro controlador não tenha memória suficiente para armazenar todas as variáveis e o programa desenvolvido, ou então pode ter um processamento lento, falhando em mostrar a medição da vazão mássica em tempo real. Assim, caso existam problemas nessa parte, pode ser necessário retornar à otimização da rede, colocando restrições maiores na busca, de forma a se ter uma RNA mais simples.

A Figura 13 mostra o fluxograma do processo de funcionamento do código do sistema embarcado. Com a início, o sistema começa o loop de medição. Primeiro, são medidas a rotação e as temperaturas de evaporação, condensação e de saída do evaporador. Depois, com esses valores, é possível obter as entradas necessárias para o modelo da RNA: a rotação do compressor, a temperatura de evaporação, a massa específica na entrada do compressor e a razão das pressões de condensação e evaporação. Com todas as entradas calculadas, é possível

alimentar o modelo, escrito a partir da Equação 8, e calcular a vazão mássica de fluido refrigerante.

Figura 13 – Fluxograma da estimação da vazão mássica com o sistema microcontrolado



Fonte: Elaborado pelo autor, 2022

3.10.1 Modelo do sistema embarcado

A Figura 14 mostra o primeiro modelo do sistema embarcado, ainda com o LM35, elaborado para servir de alternativa a um medidor de vazão mássica do fluido refrigerante. Esse sistema integra todos os componentes eletrônicos necessários para formar um circuito capaz de

MAX232. A rotação é calculada através da contagem do número de pulsos recebidos em um pino digital. Com o objetivo de se obter um produto final acessível, primeiramente, foi escolhido o LM35 como sensor de temperatura por ser barato, aproximadamente 15 reais, e que consegue medir a temperatura com uma incerteza de 0,5 °C. Uma desvantagem do LM35 é a geração de tensões negativas para temperaturas negativas, o que requer componentes adicionais no circuito, já que o microcontrolador mede apenas tensões positivas. A fim de corrigir essa limitação, foram utilizados dois diodos e um resistor, para se obter tensões positivas, possibilitando a leitura de temperaturas (tensões) negativas. Posteriormente, o sensor de temperatura foi trocado para o LM335, por apresentar um erro final menor.

3.10.2 Funcionamento do sistema embarcado para a medição da vazão mássica

Os três medidores de temperatura medem os valores da temperatura de evaporação, condensação e o a temperatura na saída do evaporador. A partir do valor da temperatura de evaporação e saída do evaporador, é possível calcular o grau de superaquecimento. Com o superaquecimento e a temperatura de evaporação, é possível calcular a massa específica na entrada do compressor, utilizando as Equações 3 e 4, proposta por Cleland, 1986. As temperaturas de evaporação e condensação são utilizadas para calcular as pressões de evaporação e de condensação, respectivamente. A rotação do compressor é calculada a partir de pulsos enviados por um sensor instalado na polia do compressor, dividindo pelo tempo entre as voltas.

3.11 Validação dos resultados da RNA gerados pelo micro controlador

Considerando que a capacidade de processamento de um micro controlador é significativamente inferior à de um computador comum como o que foi utilizado para elaborar o modelo da RNA, foi necessário verificar se a rede neural sendo executada no sistema embarcado produzia os mesmos resultados. As diferenças podem surgir das limitações de tamanho quando trabalhando com números reais e dos erros de truncamento que ocorrem durante o processo de conversão analógico/digital, no momento da leitura das temperaturas pelo microcontrolador.

Então, após conseguir simular o sistema embarcado no *Proteus* e obter medidas de vazão para entradas de temperaturas, os resultados dessas medidas foram comparados com os

resultados obtidos pela RNA original. Caso os resultados fossem diferentes do esperado, seria necessário retornar ao desenvolvimento do modelo no *Proteus* para corrigir possíveis erros no código do micro controlador.

4 RESULTADOS E DISCUSSÃO

4.1 Introdução

Neste capítulo serão apresentados todos os resultados correspondentes ao tratamento dos dados experimentais, à análise das entradas do modelo, aos resultados das otimizações de hiperparâmetros e aos resultados das validações dos modelos de redes neurais artificiais criados. Todas as previsões finais das RNAs foram comparadas levando em consideração o MSE do resultado, a complexidade do modelo e o cumprimento dos objetivos propostos no trabalho.


4.2 Tratamento dos dados experimentais

4.2.1 Exemplo dos dados coletados

Foram coletados no banco de testes experimentais, dados correspondentes a sete pontos de operação diferentes. Cada conjunto de dados continha a resposta do sistema em regime permanente, a resposta do sistema a um distúrbio na vazão mássica e o novo regime permanente alcançado depois deste processo. Então, para a realização desse trabalho, dispôs-se de dados de 14 regimes permanentes e 7 regimes transientes. Cada ensaio tinha um total de aproximadamente 500 pontos, divididos em 400 em regime permanente e 100 em regime transiente.


O ponto de operação foi definido variando a rotação no compressor e a temperatura de evaporação. Para a rotação de 650 rpm, foram feitos testes nas temperaturas de evaporação de 10 °C, 5°C e 0°C. Para 750 rpm, as temperaturas utilizadas foram 10 °C, 5°C, 0°C e -5°C. A temperatura de condensação foi mantida em aproximadamente 45°C em todos os pontos de operação. As Figuras 15 e 16 mostram exemplos de medições da temperatura de evaporação em função do tempo, e da vazão mássica em função do tempo, respectivamente. Ambas para o ponto de 650 rpm e 0 °C.

Figura 15 – Temperatura de evaporação em função do tempo para 650 rpm e 0 °C



Fonte: Elaborado pelo autor, 2022

Figura 16 – Vazão mássica em função do tempo para 650 rpm e 0 °C



Fonte: Elaborado pelo autor, 2022


Analisando as duas figuras é possível ver claramente a distinção entre os regimes permanentes e o regime transiente. Um dos objetivos desse trabalho é avaliar se o modelo da

RNA consegue prever dados de regime transiente utilizando apenas dados do regime permanente, então, posteriormente, esses dados foram separados.

4.2.2 Limpeza dos dados experimentais

Conforme discutido anteriormente no Capítulo 3, os dados experimentais foram filtrados de forma a eliminar os ruídos e os possíveis erros de medição. A Figura 17 mostra o resultado da aplicação da Equação 6 do score Z, para os dados experimentais de um dos pontos de operação.

Figura 17 – Temperatura de evaporação original e filtrada, em função do tempo, para 650 rpm e 0 °C



Fonte: Elaborado pelo autor, 2022

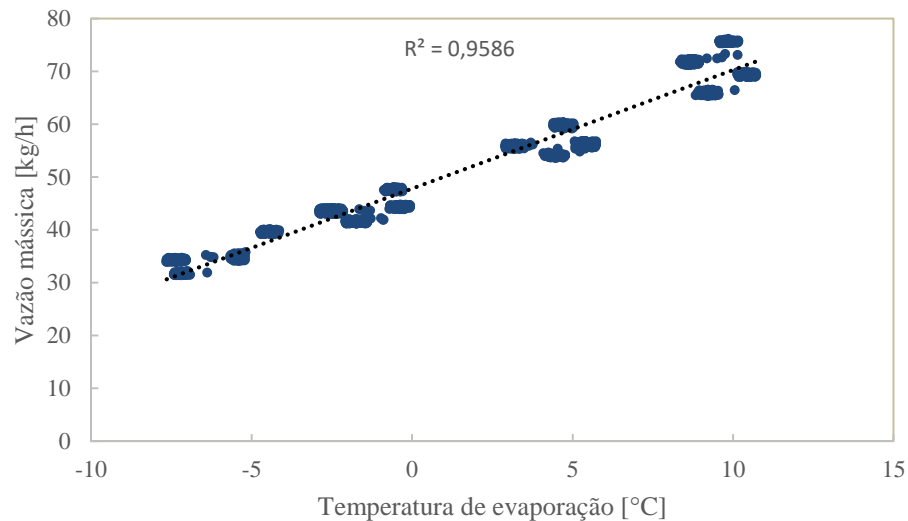
Analisando o resultado da limpeza dos dados é possível perceber que a quantidade de *outliers* reduziu significativamente. Os dados experimentais utilizados nos modelos das RNAs apresentam um comportamento mais suave, sem perder as características do regime transiente.

4.3 Avaliação das possíveis entradas para o modelo

Conforme descrito anteriormente, um dos objetivos do trabalho é medir a vazão mássica do fluido refrigerante de forma indireta, utilizando o menor número de entradas possíveis. Após analisar as Equações 1 e 2, foi possível perceber a relação direta da vazão mássica com a razão das pressões de condensação e evaporação. Como as pressões estão termodinamicamente relacionadas com as temperaturas, foram consideradas como entradas a razão das pressões e as temperaturas de evaporação e condensação. Como as pressões podem ser calculadas a partir das medições de temperatura, o uso das pressões como entrada não encarece e não complica o produto final.


Antes de serem utilizadas no modelo foi feita uma relação entre as entradas e a vazão mássica para avaliar se elas realmente possuem um efeito significativo sobre a saída desejada. As Figuras 18, 19 e 20 mostram a relação entre a vazão mássica e a temperatura de evaporação, a temperatura de condensação e a razão das pressões de condensação e evaporação, respectivamente.

Figura 18 – Relação entre a temperatura de evaporação e a vazão mássica



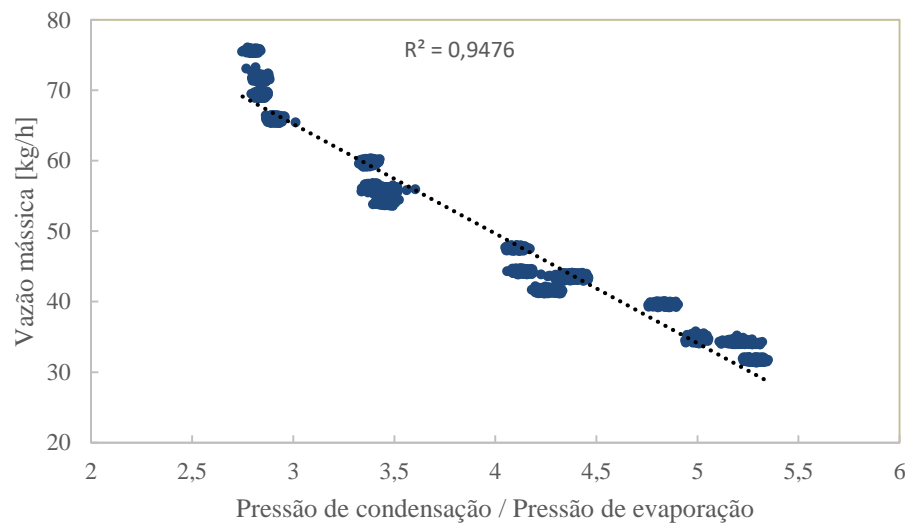
Fonte: Elaborado pelo autor, 2022

Figura 19 – Relação entre a temperatura de condensação e a vazão mássica



Fonte: Elaborado pelo autor, 2022

Figura 20 – Relação entre as pressões de condensação e evaporação e a vazão mássica



Fonte: Elaborado pelo autor, 2022

É possível perceber que a temperatura de evaporação e a razão das pressões possuem uma influência significativa sobre a vazão mássica, por isso foram mantidas como entradas para o modelo. Para esses dados experimentais, a temperatura de condensação não mostrou uma

grande influência sobre a vazão mássica. Isso pode ter acontecido porque nos experimentos a temperatura de condensação ficou praticamente constante. Em todos os testes, a temperatura de condensação apresentou uma variação de 4 °C. Assim, inicialmente foram utilizados como entradas apenas a temperatura de evaporação e a razão das pressões.

A rotação do compressor também possui uma influência direta na vazão mássica, conforme visto na Equação 1. Como foram utilizadas apenas duas rotações para cada temperatura de evaporação, a correlação entre a rotação e a vazão mássica não abrange uma ampla variedade de dados. Nesse caso, foram construídos dois tipos de modelos, primeiro foi feita uma RNA para cada rotação, e depois utilizando a rotação como entrada, para verificar se é possível distinguir os dois casos em uma mesma rede neural.

4.4 Otimização dos hiperparâmetros

A otimização dos hiperparâmetros foi feita utilizando o algoritmo *hyperband*. Foram otimizados o número de camadas escondidas, o número de neurônios em cada camada, o otimizador, a função de ativação e a taxa de *dropout*. Os limites para cada hiperparâmetro e o resultado da otimização são mostrados na Tabela 7.

Tabela 7 – Resultado da primeira otimização dos hiperparâmetros

Hiperparâmetro	Opções testadas	Opção escolhida
Função de ativação	tanh, softplus, sigmoide	tanh
Otimizador	Adam, SGD	Adam
Número de camadas escondidas	1 a 3	3
Neurônios da 1ª camada	1 a 36	32
Neurônios da 2ª camada	1 a 36	26
Neurônios da 3ª camada	1 a 36	10
Taxa de aprendizado	0,01 ; 0,001 ; 0,0001	0,001
Taxa de dropout	0,1 ; 0,01 ; 0,001	0.01

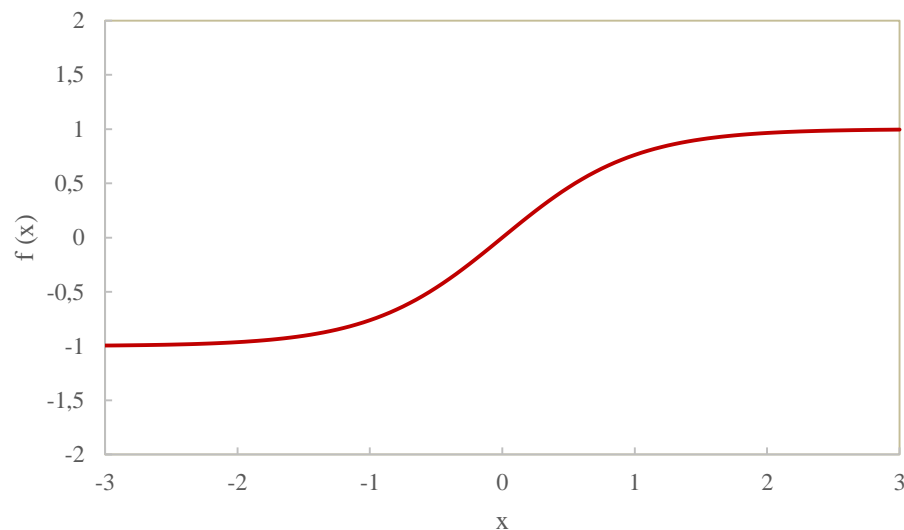
Fonte: Elaborado pelo autor, 2022

É possível perceber que a configuração ótima local encontrada propôs uma rede neural profunda, com mais de uma camada escondida. Isso permite a criação de um modelo mais complexo que, possivelmente, consegue realizar previsões em mais casos, porém, possui uma dificuldade maior para ser treinada. A taxa de *dropout* escolhida foi um valor médio de 0,01,

que ajuda a prevenir um estado de overfitting, mas também não dificulta muito o treinamento. O otimizador escolhido foi o Adam, que é muito utilizado em aplicações envolvendo redes neurais artificiais por sua facilidade de uso. De acordo com Kingma e Ba, 2014, o Adam é um otimizador computacionalmente eficiente e com baixo uso de memória. A função de ativação foi a tangente hiperbólica, cuja fórmula é mostrada na Equação 14 e o comportamento é mostrado na Figura 21.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (14)$$

Figura 21 – Função tangente hiperbólica



Fonte: Elaborado pelo autor, 2022


Essa função de ativação aceita valores de entrada entre -1 e 1, e também tem como saída valores positivos e negativos. Como a normalização feita resultou em dados no intervalo de 0 a 1, essa função consegue ser aplicada no problema. A desvantagem da tangente hiperbólica está na possível saturação dos neurônios, pois a função rapidamente converge para 1 com entradas positivas grandes ou -1 com entradas negativas grandes. Apesar disso, essa função possui a vantagem de normalmente alcançar um desempenho melhor, conforme discutido por Sá, 2019.

4.5 Resultados do primeiro modelo da RNA

4.5.1 Resultados utilizando a rotação do compressor, temperatura de evaporação e razão das pressões de entrada

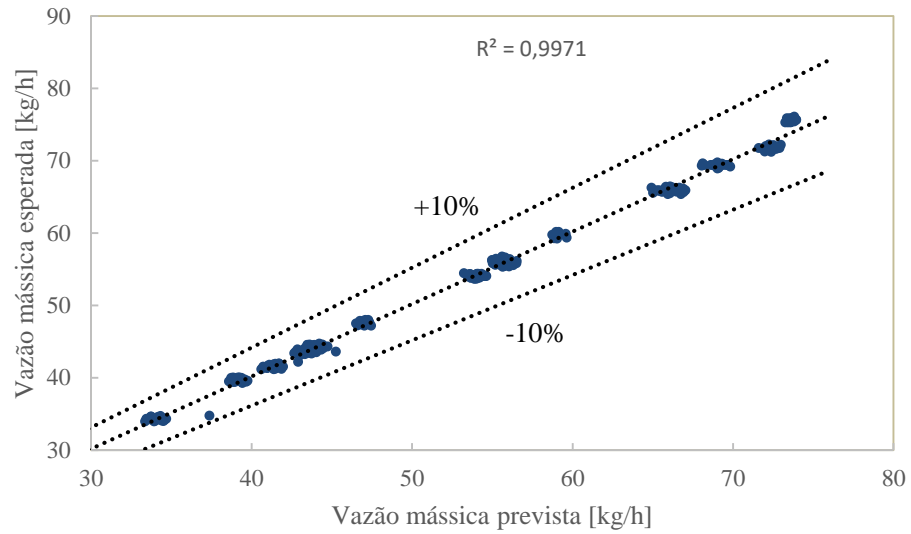
Primeiramente foram utilizadas como entradas da RNA a temperatura de evaporação, a rotação do compressor e a razão das pressões de condensação e evaporação. Em todos os treinamentos realizados nesse trabalho foram analisados o MSE do treinamento e o MSE da validação. Quando o erro na validação começa a aumentar enquanto o erro durante o treinamento diminui, isso caracteriza um estado de *overfitting*. Nestes casos, os treinamentos foram interrompidos quando o erro nos dados de validação parou de diminuir conforme o número de épocas aumentava. A Figura 22 mostra o resultado do treinamento do modelo da RNA utilizando a rotação, a temperatura de evaporação e a razão das pressões como entrada.

Figura 22 – Evolução do MSE durante o treinamento e a validação



Fonte: Elaborado pelo autor, 2022


Após o treinamento foi feito o teste do modelo utilizando 15% dos dados que nunca foram vistos pelo modelo da RNA. A Figura 23 mostra o resultado dos testes do primeiro modelo, utilizando a rotação, a temperatura de evaporação e a razão das pressões como entrada.

Figura 23 – Testes da RNA com a rotação do compressor de entrada

Fonte: Elaborado pelo autor, 2022


Nos testes o erro médio da rede foi de 0,93 %, equivalente à 0,51 kg/h. De forma a analisar como são as previsões de um ponto de operação feitas pela RNA, as Figuras 24 e 25 mostram a comparação entre os valores esperados e valores previstos para a vazão mássica nos pontos de operação de 5 °C com 650 e 750 rpm, respectivamente.

Figura 24 – Previsão do ponto 650 rpm e 5 °C com a rotação, temperatura de evaporação e razão das pressões de entrada



Fonte: Elaborado pelo autor, 2022

Figura 25 – Previsão do ponto 750 rpm e 5 °C com a rotação, temperatura de evaporação e razão das pressões de entrada



Fonte: Elaborado pelo autor, 2022

Neste caso é possível perceber que os valores previstos apesar de estarem próximos aos valores esperados depois do regime transiente, as previsões da operação inicial ficaram diferentes da esperada. Nesses casos, o erro médio de 0,66 %, equivalente a 0,36 kg/h para 650 rpm, e 0,86 %, equivalente a 0,50 kg/h para 750 rpm. A Tabela 8 mostra os erros em todos os pontos de operação para essa RNA.

Tabela 8 – Resumo dos resultados utilizando a rotação do compressor, temperatura de evaporação e razão das pressões de entrada

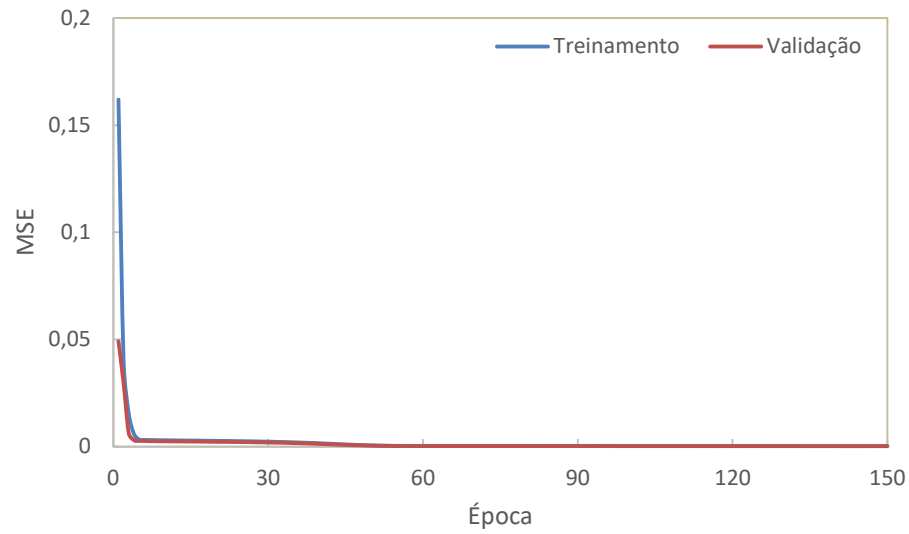
Ponto de operação			
Rotação do compressor	Temperatura de evaporação	MSE [kg/h]	Erro médio [kg/h]
650 rpm	10 °C	0,26	0,42
	5 °C	0,23	0,36
	0 °C	0,17	0,32
750 rpm	10 °C	0,45	0,53
	5 °C	0,38	0,50
	0 °C	0,42	0,56
	-5 °C	0,72	0,89

Fonte: Elaborado pelo autor, 2022

4.5.2 Resultados utilizando uma RNA para cada rotação do compressor


Na segunda abordagem avaliada, foram criados dois modelos de redes neurais sendo que cada modelo foi alimentado com os dados de uma rotação específica, utilizando apenas a temperatura de evaporação e a razão das pressões como entrada. As mesmas análises foram feitas durante o treinamento. As Figuras 26 e 27 mostram a evolução do MSE durante o treinamento para 650 e 750 rpm, respectivamente.

Figura 26 – Evolução do MSE durante o treinamento e a validação para 650 rpm




Fonte: Elaborado pelo autor, 2022

Figura 27 – Evolução do MSE durante o treinamento e a validação para 750 rpm

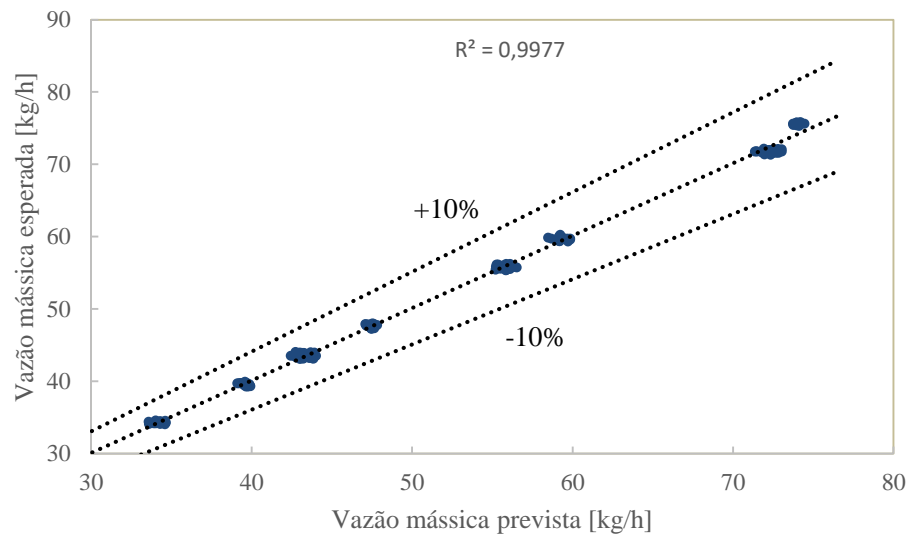


Fonte: Elaborado pelo autor, 2022

É possível observar que em ambos os casos os testes de cada uma das rotações obtiveram resultados melhores, mostrado pelas Figuras 28 e 29. Nestes casos, o erro médio foi de 0,68 %, 0,38 kg/h, para 650 rpm, e, 0,84 %, 0,47 kg/h, para 750 rpm.

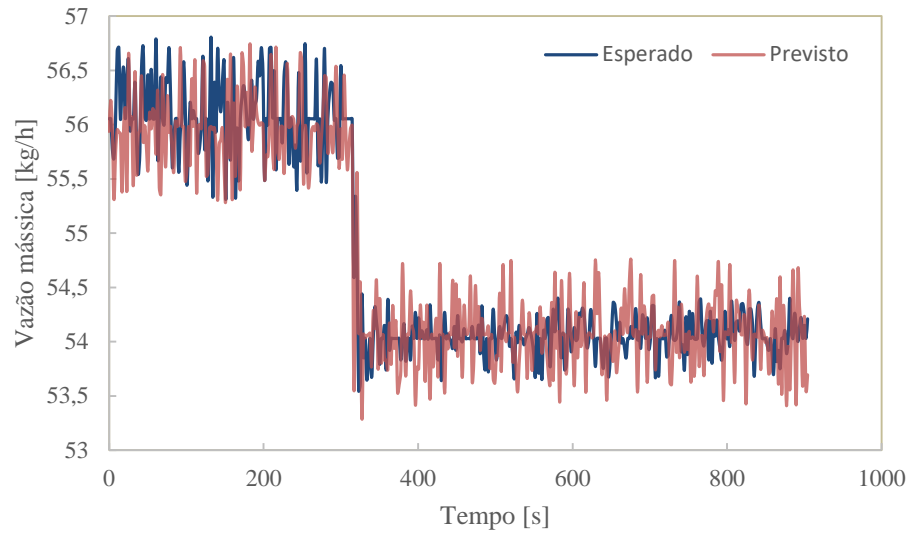
Figura 28 – Testes da RNA para 650 rpm

Fonte: Elaborado pelo autor, 2022

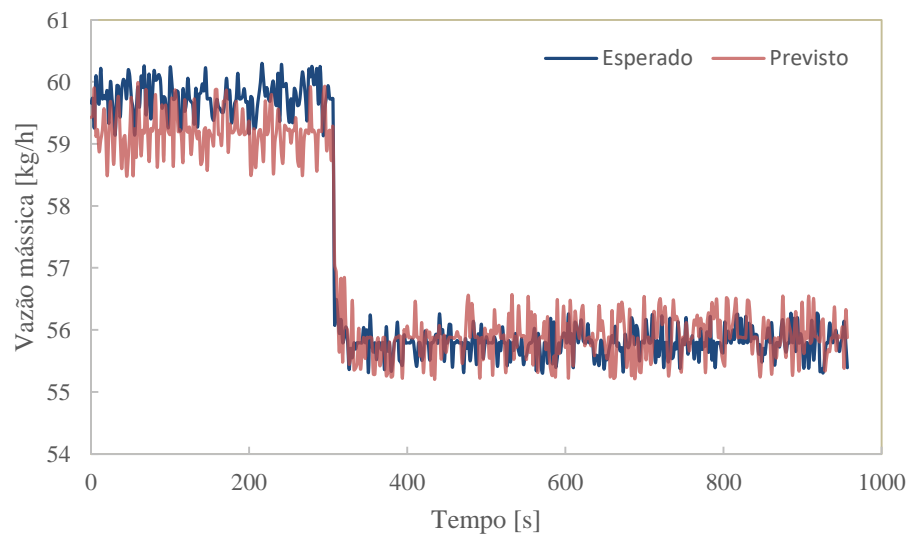
Figura 29 – Testes da RNA para 750 rpm

Fonte: Elaborado pelo autor, 2022

As Figuras 30 e 31 mostram, respectivamente, a previsão de um ponto de operação para a rotação de 650 rpm e 750 rpm. Para 650 rpm o erro médio foi de 0,59 %, 0,32 kg/h, e, para 750 rpm, 0,72 %, 0,41 kg/h.

Figura 30 – Previsão do ponto 650 rpm e 5 °C

Fonte: Elaborado pelo autor, 2022

Figura 31 – Previsão do ponto 750 rpm e 5 °C

Fonte: Elaborado pelo autor, 2022

Resultados melhores para o caso de uma rede para cada rotação já eram esperados, visto que dessa maneira, divide-se o problema em dois casos diferentes, em que cada rede só precisa aprender o comportamento esperado para uma rotação específica. A desvantagem dessa

abordagem é que, caso seja desejado prever a vazão mássica para inúmeras rotações diferentes, será necessário treinar uma rede para cada uma das rotações. Levando em consideração que um dos objetivos do trabalho é colocar o modelo da RNA em um micro controlador para se desenvolver um produto final que pode ser utilizado em uma máquina frigorífica real, essa não é a melhor abordagem, apesar dos resultados melhores. Como a memória e a capacidade de processamento são fatores limitantes em um sistema embarcado, a criação de várias RNAs para diferentes rotações seriam inviáveis de serem reproduzidas pelo micro controlador. Assim, a abordagem escolhida para ser desenvolvida no trabalho foi a de utilizar a rotação do compressor como entrada, apesar de que uma rede para uma rotação específica pode ser o ideal para aplicações específicas.

A Tabela 9 mostra os erros em todos os pontos de operação para os dois modelos de RNA, um para cada rotação.

Tabela 9 – Resumo dos resultados com uma RNA para cada rotação do compressor

Ponto de operação			
Rotação do compressor	Temperatura de evaporação	MSE [kg/h]	Erro médio [kg/h]
650 rpm	10 °C	0,39	0,51
	5 °C	0,18	0,32
	0 °C	0,25	0,42
750 rpm	10 °C	0,35	0,47
	5 °C	0,29	0,41
	0 °C	0,28	0,41
	-5 °C	0,75	0,92

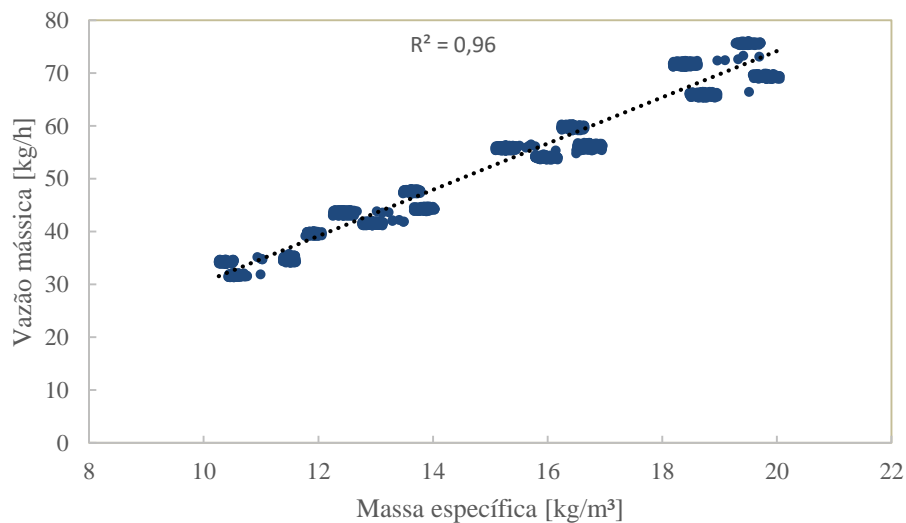
Fonte: Elaborado pelo autor, 2022

4.6 Aprimorando os resultados da RNA

4.6.1 Avaliando a massa específica como entrada do modelo

De forma a se conseguir resultados melhores pelo modelo da RNA, outro dado de entrada foi considerado. Analisando novamente a Equação 1, é possível perceber que a vazão mássica também depende diretamente da massa específica. Como a massa específica pode ser calculada pelas Equações 3 e 4 a partir de valores apenas de temperaturas, a sua utilização não deixa o produto final mais caro e nem requer sensores diferentes. Assim, a massa específica foi calculada para todos os pontos dos dados experimentais. Depois, foi feita uma análise para se observar como a vazão mássica se comporta com a variação da massa específica (Figura 32).

Figura 32 – Relação entre a massa específica e a vazão mássica




Fonte: Elaborado pelo autor, 2022

Como é possível perceber, há uma influência significativa da massa específica sobre a vazão mássica. Desta forma, ela foi escolhida como entrada e outro modelo foi construído.


4.6.2 Resultados do modelo utilizando a massa específica como entrada

Um novo modelo foi desenvolvido e treinado utilizando a massa específica na entrada do compressor como entrada da rede, além da temperatura de evaporação, rotação do compressor e razão das pressões. A Figura 33 mostra a evolução do erro durante o treinamento, e a Figura 34 mostra o resultado dos testes respectivos.

Figura 33 – Evolução do MSE durante o treinamento e a validação utilizando a massa específica como entrada




Fonte: Elaborado pelo autor, 2022

Figura 34 – Testes da RNA utilizando massa específica na entrada

Fonte: Elaborado pelo autor, 2022


É possível observar que a utilização da massa específica aprimorou o resultado do modelo. Na validação, o erro médio foi de 0,81 %, equivalente a 0,40 kg/h. A Figura 35 mostra o resultado da previsão de um ponto de operação de 650 rpm e 5 °C utilizando esse modelo da RNA, que obteve um erro médio de 0,62 %, 0,34 kg/h. A Figura 36, de forma semelhante, mostra a previsão para o ponto em 750 rpm, com um erro médio de 0,63 %, ou 0,36 kg/h.

Figura 35 – Previsão do ponto 650 rpm e 5 °C com a massa específica de entrada



Fonte: Elaborado pelo autor, 2022

Figura 36 – Previsão do ponto 750 rpm e 5 °C com a massa específica de entrada



Fonte: Elaborado pelo autor, 2022

É possível perceber que, com a massa específica de entrada, os resultados melhoraram significativamente. As previsões para 650 rpm se equipararam ao resultado obtido com o teste de uma rede para cada rotação e, para 750 rpm, foi possível observar a correção na diferença

na previsão da parte inicial. De forma a determinar se os resultados obtidos pelos modelos são ou não satisfatórios, eles foram comparados com a incerteza padrão do medidor de vazão mássica utilizado para coletar os dados. Assim, caso o erro médio obtido pela RNA seja menor que a incerteza dos dados utilizados no próprio treinamento, os resultados serão considerados satisfatórios. A incerteza padrão do medidor de vazão mássica a efeito Coriolis utilizado era de 1,35 kg/h. Então, para esse caso, todos os resultados foram satisfatórios. Sendo assim, o modelo utilizando a rotação, temperatura de evaporação, razão das pressões e massa específica como entradas, foi transferido para o micro controlador para operar em um sistema embarcado de uma máquina frigorífica. A Tabela 10 mostra os erros em todos os pontos de operação para a rede adicionando a entrada de massa específica.

Tabela 10 – Resumo dos resultados utilizando a massa específica como entrada

Ponto de operação			
Rotação do compressor	Temperatura de evaporação	MSE [kg/h]	Erro médio [kg/h]
650 rpm	10 °C	0,33	0,45
	5 °C	0,19	0,34
	0 °C	0,14	0,28
750 rpm	10 °C	0,26	0,41
	5 °C	0,21	0,36
	0 °C	0,28	0,42
	-5 °C	0,24	0,39

Fonte: Elaborado pelo autor, 2022


4.6.3 Comparando resultados com apenas dados de regime permanente no treinamento

Um dos objetivos do trabalho é verificar se o modelo da RNA treinado apenas com dados de regimes permanentes consegue prever a vazão mássica de fluido refrigerante para regimes permanentes e transientes. Caso consiga, o produto final conseguirá atingir uma variedade muito maior de casos de uso. Reduzindo a quantidade de dados necessários para treinar o modelo, reduz também o custo e aumenta a viabilidade do produto.

Como essa rede, que utilizou a rotação, temperatura de evaporação, razão das pressões e massa específica como entradas, foi a escolhida para ser utilizada no micro controlador, essa análise foi feita para esse modelo. Assim, os dados foram divididos em permanente e transiente.


Cada ponto de operação possui dados de duas partes permanentes diferentes, com uma parte transiente entre elas. O conjunto de dados do regime permanente foi constituído por ambas as partes permanentes, antes e depois do degrau aplicado (transiente). Dentro dos dados permanentes, foi feita a divisão entre treinamento, validação e teste. Nesse treinamento, apenas dados de regime permanente do treinamento foram utilizados. A Figura 37 mostra a evolução do MSE durante o treinamento e a validação. A Figura 38 mostra os resultados das previsões utilizando os dados de teste dos dados de regime permanente.

Figura 37 – Evolução do MSE durante o treinamento com apenas dados de regime permanente



Fonte: Elaborado pelo autor, 2022

Figura 38 – Testes da RNA treinada com dados de regime permanente




Fonte: Elaborado pelo autor, 2022

Um ponto importante que deve ser observado é a velocidade do decaimento do erro durante o treinamento. O modelo treinado apenas com dados do regime permanente teve um treinamento que demandou um tempo e esforço computacional maiores. Mesmo assim, é possível perceber que a RNA conseguiu treinar com apenas os dados de regime permanente e conseguiu um erro médio de 0,73 % nos testes, equivalente a 0,39 kg/h. Comparando com os resultados das Figuras 4.18 e 4.19, que foram feitas utilizando todos os dados no treinamento, é possível perceber que o desempenho dos modelos é muito semelhante, visto que o erro médio dos testes vai de 0,40 kg/h para 0,39 kg/h.


Após os testes com os dados de regime permanente, o modelo foi utilizado para prever a vazão mássica em uma situação com um regime transiente. A Figura 39 mostra o resultado da previsão da vazão mássica para o ponto de 650 rpm e 5 °C, e, a Figura 40 para 750 rpm e 5 °C.

Figura 39 – Previsão do ponto de 650 rpm e 5°C com uma rede treinada apenas com o regime permanente



Fonte: Elaborado pelo autor, 2022

Figura 40 – Previsão do ponto de 750 rpm e 5°C com uma rede treinada apenas com o regime permanente



Fonte: Elaborado pelo autor, 2022

Nesse caso, o erro médio foi de 0,61 %, equivalente a 0,33 kg/h para a rotação de 650 rpm. Para a rotação de 750 rpm, 0,61 %, ou 0,35 kg/h. É possível perceber que o erro médio teve uma diferença de apenas 0,01 ou 0,02 pontos percentuais nas previsões. De forma semelhante aos testes, pode-se afirmar que não há uma diferença significativa nos resultados. Assim, pode-se inferir que, uma rede treinada apenas com dados de regime permanente tem informação o suficiente para prever o comportamento de um regime transiente entre dois dos regimes permanentes utilizados. Além disso, todos os resultados obtidos se mantiveram abaixo da incerteza padrão do medidor de vazão, 1,35 kg/h. A Tabela 11 mostra os erros em todos os pontos de operação com a massa específica de entrada adicional e utilizando apenas dados do regime permanente no treinamento. A Tabela 12 mostra a comparação do erro médio quadrático para todos os casos anteriormente comentados.

Tabela 11 – Resumo dos resultados utilizando a massa específica como entrada e apenas dados do regime permanente no treino

Ponto de operação			
Rotação do compressor	Temperatura de evaporação	MSE [kg/h]	Erro médio [kg/h]
650 rpm	10 °C	0,26	0,43
	5 °C	0,18	0,33
	0 °C	0,21	0,37
750 rpm	10 °C	0,34	0,45
	5 °C	0,19	0,35
	0 °C	0,24	0,39
	-5 °C	0,56	0,61

Fonte: Elaborado pelo autor, 2022

Tabela 12 – Resumo dos resultados obtidos comparando os modelos com três camadas escondidas e diferentes entradas

Ponto de operação		Todos os dados no treinamento			Regime permanente no treinamento
		$T_e, \frac{P_c}{P_e}, N$	$T_e, \frac{P_c}{P_e}$	$T_e, \rho, \frac{P_c}{P_e}, N$	$T_e, \rho, \frac{P_c}{P_e}, N$
Rotação do compressor	Temperatura de evaporação	MSE [kg/h]	MSE [kg/h]	MSE [kg/h]	MSE [kg/h]
650 rpm	10 °C	0,26	0,39	0,33	0,26
	5 °C	0,23	0,18	0,19	0,18
	0 °C	0,17	0,25	0,14	0,21
750 rpm	10 °C	0,45	0,35	0,26	0,34
	5 °C	0,38	0,29	0,21	0,19
	0 °C	0,42	0,26	0,28	0,24
	-5 °C	0,72	0,75	0,24	0,56

Fonte: Elaborado pelo autor, 2022

4.7 Desenvolvimento do modelo do sistema embarcado no *software* Proteus

Ao tentar reproduzir o modelo da RNA no micro controlador, uma dificuldade foi encontrada. Como o modelo resultante da otimização foi de uma rede neural profunda, com três camadas escondidas, e aproximadamente 1350 parâmetros, a memória do PIC não foi suficiente para suportar a rede. Um dos objetivos do trabalho é desenvolver um produto funcional e viável, por isso, decidiu-se por manter o micro controlador mais simples, e buscar uma forma de se utilizar uma RNA mais simples. Assim, foi feita uma nova otimização dos hiperparâmetros, reduzindo os limites possíveis.

4.8 Resultados da nova otimização dos hiperparâmetros da RNA

Para se ter um modelo menor e mais simples, que caiba dentro da memória limitada do micro controlador, a nova otimização foi realizada limitando o número de camadas e neurônios em valores menores. A Tabela 13 mostra os valores possíveis e o resultado da otimização.

Tabela 13 – Resultado da segunda otimização dos hiperparâmetros

Hiperparâmetro	Opções testadas	Opção escolhida
Função de ativação	tanh, softplus, sigmoide, softmax	softplus
Otimizador	Adam, SGD	Adam
Número de camadas escondidas	1	1
Neurônios da 1ª camada	1 a 6	4
Taxa de aprendizado	0,01 ; 0,001 ; 0,0001	0,001
Taxa de dropout	0,1 ; 0,01 ; 0,001	0.01

Fonte: Elaborado pelo autor, 2022

Dessa vez, o número de camadas escondidas foi limitado a uma. A quantidade ótima local para o número de neurônios foi de 4. Isso resulta em uma rede com aproximadamente 25 parâmetros, que, comparando à quantidade anterior de 1350, é uma redução de mais de 95%. A taxa de *dropout* e o otimizador se mantiveram. A função de ativação escolhida nesse caso é a *softplus*, pois foi a que obteve o menor erro durante a otimização.

A função de ativação *softplus* não responde bem à dados de entrada negativos, pois tem uma resposta pequena ou nula de acordo com a variação da entrada negativa. Como a normalização dos dados utilizada no trabalho resulta em dados na faixa de 0 a 1, a utilização dessa função de ativação não foi um problema.

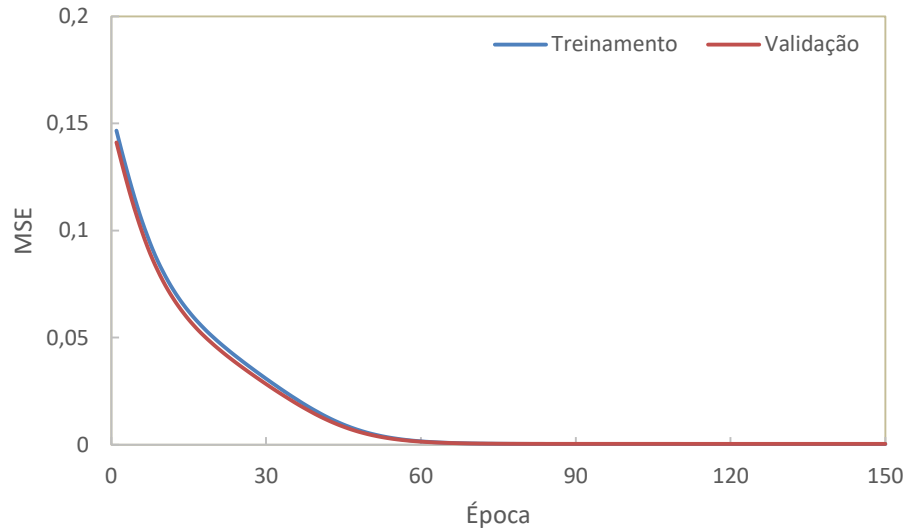
4.9 Resultados do modelo mais simples da RNA

Com a nova otimização foi possível desenvolver um novo modelo da RNA. De forma semelhante à feita anteriormente, foram construídos dois modelos diferentes com essa configuração, um treinado apenas com dados de regimes permanentes e uma treinada com todos os dados.

4.9.1 RNA treinada apenas com dados de regime permanente

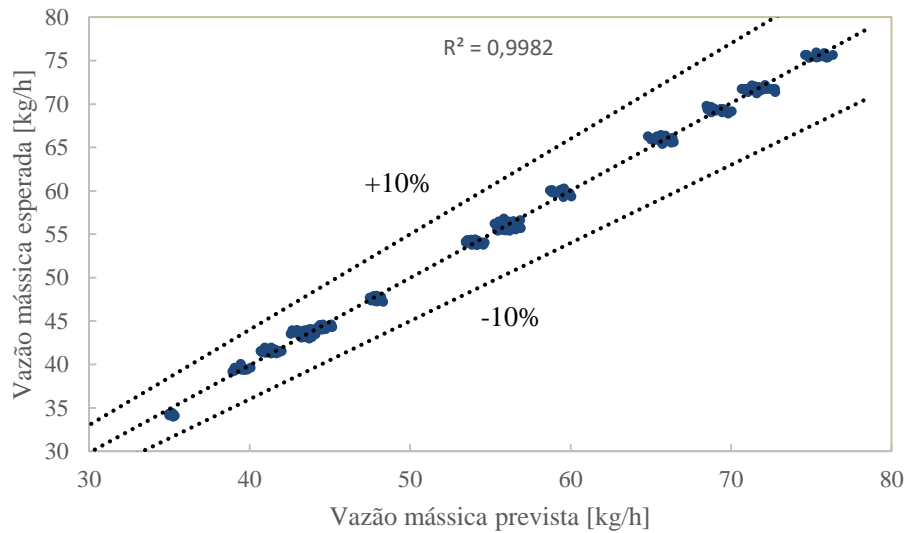
As Figuras 41 e 42 mostram a evolução do MSE durante o treinamento e validação, e o resultado dos testes da RNA, respectivamente.

Figura 41 – Evolução do MSE da rede mais simples treinada com apenas dados de regime permanente



Fonte: Elaborado pelo autor, 2022

Figura 42 – Testes da RNA mais simples treinada com dados de regime permanente




Fonte: Elaborado pelo autor, 2022

Nesse caso, os testes da rede obtiveram um erro médio de 0,81 %, equivalente a 0,41 kg/h. Comparando com o caso semelhante, utilizando a rede mais complexa, é possível perceber

que o desempenho do modelo foi semelhante, apesar de um erro médio 5 % maior, os valores absolutos são muito próximos, de 0,39 kg/h para 0,41 kg/h.


A Figura 43 mostra a previsão do ponto de operação de 650 rpm e 5 °C, em que a rede treinada com dados de regime permanente conseguiu, novamente, prever dados do regime transiente. De forma semelhante, a Figura 44 mostra as previsões para o ponto com 750 rpm.

Figura 43 – Previsão do ponto de 650 rpm e 5 °C com uma rede mais simples treinada apenas com o regime permanente



Fonte: Elaborado pelo autor, 2022

Figura 44 – Previsão do ponto de 750 rpm e 5 °C com uma rede mais simples treinada apenas com o regime permanente



Fonte: Elaborado pelo autor, 2022

Nesse caso, para 650 rpm, o erro médio obtido foi igual a 0,60 %, equivalente a 0,33 kg/h, e, para 750 rpm, 0,66 %, ou 0,38 kg/h. Comparando com a previsão do mesmo ponto utilizando a rede mais complexa, é possível perceber que o desempenho foi semelhante para 650 rpm, em detrimento do desempenho para 750 rpm. Entretanto, em valores absolutos, o erro médio ainda continua pequeno, abaixo da incerteza do medidor de vazão utilizado para coletar os dados experimentais. A Tabela 14 mostra os erros em todos os pontos de operação para a rede mais simples e utilizando apenas dados do regime permanente no treinamento.

Tabela 14 – Resumo dos resultados para a rede mais simples e com apenas dados do regime permanente no treinamento


Ponto de operação			
Rotação do compressor	Temperatura de evaporação	MSE [kg/h]	Erro médio [kg/h]
650 rpm	10 °C	0,27	0,41
	5 °C	0,17	0,33
	0 °C	0,18	0,34
750 rpm	10 °C	0,34	0,44
	5 °C	0,23	0,38
	0 °C	0,3	0,43
	-5 °C	0,61	0,65

Fonte: Elaborado pelo autor, 2022

4.9.2 RNA treinada com dados de regime permanente e transiente


Após as análises com apenas dados de regime permanente na entrada, foi feito o treinamento do modelo com todos os dados. As Figuras 45 e 46 mostram a evolução do erro e o resultado dos testes, respectivamente.

Figura 45 – Evolução do MSE da rede mais simples treinada com todos os dados



Fonte: Elaborado pelo autor, 2022


Figura 46 – Testes da RNA mais simples treinada com todos os dados



Fonte: Elaborado pelo autor, 2022


Nesse caso, o erro médio foi de 0,79 %, equivalente a 0,39 kg/h. Comparando com a rede mais complexa, a diferença no erro médio foi de apenas 0,01 ponto percentual. Novamente, os resultados satisfatórios do modelo se mantiveram para a rede mais simples. A fim de comparar o resultado dessa rede com a rede treinada apenas com dados de regimes permanentes, foi realizada a previsão da vazão mássica dos pontos específicos em 650 rpm, Figura 47, e 750 rpm, Figura 48.

Figura 47 – Previsão do ponto de 650 rpm e 5 °C com uma rede mais simples treinada com todos os dados



Fonte: Elaborado pelo autor, 2022

Figura 48 – Previsão do ponto de 750 rpm e 5 °C com uma rede mais simples treinada com todos os dados



Fonte: Elaborado pelo autor, 2022

O erro médio foi de 0,60 %, equivalente a 0,33 kg/h, para 650 rpm, e 0,66 %, ou 0,38 kg/h, para 750 rpm. Nesse caso, para os dois pontos usados de exemplo, o erro médio foi o mesmo. Como a rede treinada com todos os dados é a rede mais simples e com bons resultados, ela foi escolhida para ser aplicada no micro controlador do sistema embarcado. Porém, é possível inferir que, caso a rede tivesse sido treinada apenas com dados de regime permanente, os resultados seriam igualmente aceitáveis. A Tabela 15 mostra os erros em todos os pontos de operação para a rede mais simples e utilizando apenas dados do regime permanente no treinamento.

Tabela 15 – Resumo dos resultados para a rede mais simples com todos os dados no treinamento

Ponto de operação			
Rotação do compressor	Temperatura de evaporação	MSE [kg/h]	Erro médio [kg/h]
650 rpm	10 °C	0,26	0,40
	5 °C	0,18	0,33
	0 °C	0,19	0,35
750 rpm	10 °C	0,32	0,43
	5 °C	0,23	0,38
	0 °C	0,24	0,38
	-5 °C	0,30	0,45

Fonte: Elaborado pelo autor, 2022

A Tabela 16 compara os resultados de todos os pontos de operação para os dois últimos casos, do modelo mais simples da RNA com apenas dados do regime permanente no treinamento e com todos os dados no treinamento, comparando com os casos semelhantes para o modelo com mais camadas escondidas.

Tabela 16 – Comparação do erro médio entre as duas configurações da rede

Ponto de operação		Uma camada escondida		Três camadas escondidas	
		Regime permanente no treinamento	Todos os dados no treinamento	Regime permanente no treinamento	Todos os dados no treinamento
Rotação do compressor	Temperatura de evaporação	MSE [kg/h]	MSE [kg/h]	MSE [kg/h]	MSE [kg/h]
650 rpm	10 °C	0,27	0,26	0,26	0,33
	5 °C	0,17	0,18	0,18	0,19
	0 °C	0,18	0,19	0,21	0,14
750 rpm	10 °C	0,34	0,32	0,34	0,26
	5 °C	0,23	0,23	0,19	0,21
	0 °C	0,30	0,24	0,24	0,28
	-5 °C	0,61	0,30	0,56	0,24

Fonte: Elaborado pelo autor, 2022

4.10 Aplicação da nova rede no Proteus

Para aplicar o modelo da RNA no microcontrolador, a função que relaciona as entradas com a saída foi traduzida para a linguagem de programação C em forma de equação matricial, conforme discutido na metodologia desse trabalho. Os valores de cada matriz de pesos utilizada no modelo final aparecem na Tabela 17.


Tabela 17 – Matrizes com os pesos do modelo final da RNA

Matriz	Valores			
W_1	-0,0829615	-0,486509	0,3663	-0,306383
	0,793527	-0,0952572	-0,0101221	0,982245
	-1,74824	-0,154079	1,01489	-0,212918
	0,773399	-0,370748	-0,562138	1,9416
W_2		-0,43016		
		0,576953		
		0,83605		
		0,825405		
b_1	-0,189378	-0,309269	-0,0917707	0,345497
b_2			-0,319894	

Fonte: Elaborado pelo autor, 2022

da temperatura de evaporação, para que o LM35 consiga medir as temperaturas negativas, um erro no resultado final já era esperado. Para quantificar essa diferença, uma comparação entre os resultados foi feita, mostrada pela Figura 50.

Figura 50 – Relação entre a RNA no PC e a RNA no sistema embarcado com o LM35




Fonte: Elaborado pelo autor, 2022

A reprodução do modelo da rede pelo micro controlador teve um erro médio de 1,1 %, equivalente a 0,59 kg/h, que, apesar de continuar abaixo da incerteza do medidor de vazão, foi maior que o esperado. Com o objetivo de aprimorar o resultado final, o sensor de temperatura foi substituído para o LM335 que, por ser capaz de medir temperaturas negativas diretamente, dispensa a correção na medição, que foi um dos fatores causadores do erro.

A Figura 51 mostra o modelo no novo sistema embarcado, agora com os sensores de temperatura LM335. Para mais detalhes sobre o funcionamento do programa desenvolvido, veja o código utilizado no Anexo I.

Figura 52 – Relação entre a RNA no PC e a RNA no sistema embarcado com o LM335



Fonte: Elaborado pelo autor, 2022

Com o novo sensor de temperatura, a reprodução do modelo da rede pelo micro controlador teve um erro médio de 0,32 %, equivalente a 0,16 kg/h, o que foi uma melhoria de aproximadamente 73 % em relação ao sistema embarcado anterior. Por fim, o erro se manteve abaixo da incerteza de medição do medidor de vazão mássica. Assim, o resultado final foi considerado satisfatório, e o sistema embarcado conseguiu prever a vazão mássica de fluido refrigerante, usando apenas medições indiretas, com sucesso.

5 CONCLUSÃO

O presente trabalho apresentou um modelo de redes neurais artificiais para prever a vazão mássica de fluido refrigerante em uma máquina frigorífica e a utilização desse modelo no desenvolvimento de um circuito microcontrolado destinado a medição da vazão mássica. Os dados experimentais foram coletados em uma máquina frigorífica operando com o R134a como fluido refrigerante. A aquisição obteve sete pontos de operação diferentes, incluindo dados de resposta permanente e transiente.

A rotação, massa específica, temperatura de evaporação e a razão entre pressões de condensação e evaporação foram utilizadas como entradas para o modelo. A RNA utilizada foi uma Perceptron Multicamadas, com a função de ativação *Softplus* e o otimizador Adam. Dois casos diferentes foram considerados para o treinamento do modelo. Em um deles a RNA foi treinada com dados do regime permanente e transiente e no outro apenas com dados de regime permanente. Em todos os casos o erro médio foi menor que a incerteza dos dados utilizados no treinamento. Para a RNA treinada apenas com dados de regime permanente, o erro médio foi de 0,81 % durante os testes. A rede treinada com todos os dados obteve um erro médio de 0,79 %. Considerando que em ambos os casos o erro médio foi menor que a incerteza padrão do medidor de da vazão mássica utilizado, os resultados foram considerados satisfatórios, indicando que o modelo elaborado em redes neurais artificiais consegue estimar a vazão mássica de um sistema de refrigeração. Além disso, também é possível concluir que um modelo treinado apenas com dados de regime permanente consegue eficientemente prever a vazão mássica durante a resposta transiente. Se a RNA possui informações sobre dois pontos de regime permanente próximos, ela também consegue prever a vazão mássica durante a transição entre esses dois pontos.

Depois da validação o modelo foi programado em um microcontrolador de uma aplicação destinada a medir a vazão mássica de uma máquina frigorífica. O sistema embarcado foi desenvolvido e testado utilizando o *software* Proteus. Uma comparação entre as previsões do modelo no PC e no microcontrolador foi feita. O sistema simulado no microcontrolador teve um desvio médio em relação aos dados calculados utilizando um PC de 0,32 %, o que mostra que o sistema desenvolvido consegue reproduzir o modelo da RNA com erro abaixo da incerteza padrão dos dados de treinamento. Assim, é possível concluir que um sistema embarcado utilizado, programado com a RNA desenvolvida neste trabalho, é capaz de estimar

com sucesso e com erro inferior a incerteza do medidor utilizado, a vazão mássica de fluido refrigerante em uma máquina frigorífica real.

6 SUGESTÕES DE TRABALHOS FUTUROS

Para dar continuidade a esse trabalho, podem-se citar as seguintes sugestões:

- Criação e validação de um modelo feito com dados experimentais variando a temperatura de condensação;
- Desenvolvimento de uma RNA capaz de prever a vazão mássica de fluido refrigerante em uma faixa de atuação maior;
- Comparar o desempenho de diferentes modelos matemáticos que podem ser utilizados no microcontrolador para prever a vazão mássica de fluido refrigerante;
- Construir o sistema embarcado proposto e aplicá-lo em uma máquina frigorífica real para ser utilizado como medidor de vazão mássica.

7 REFERÊNCIAS BIBLIOGRÁFICAS

- Angoff, W. H. 1984. "Scales, Norms, and Equivalent Scores". Princeton, New Jersey, *Educational testing service*.
- Anklin, M., Drahm, W., Rieder, A. 2006. "Coriolis mass flowmeters: Overview of the current state of art and latest research". *Flow Measurement and Instrumentation*, Vol. 17, pp. 317-323.
- Azizi, S., Ahmadloo, E., 2016. "Prediction of heat transfer coefficient during condensation of R134a in inclined tubes using artificial neural networks". *Applied Thermal Engineering*, Vol. 106, pp. 203-210.
- Barreto, J.M.. 2002 "Introdução às redes neurais artificiais". *Laboratório de Conexão e Ciências Cognitivas UFSC – Departamento de Informática e de Estatística*.
- Bell, I. H. *et al* 2020. PDSim: A general quasi-steady modeling approach for positive displacement compressors and expanders. *International Journal of Refrigeration*, Vol. 110, pp. 310-322.
- Bergstra, J., Bengio, Y., 2012. "Random Search for Hyper-Parameter Optimization". *Journal of Machine Learning Research*, Vol. 13, pp. 281-305.
- Castaing-Lasvignottes, J., and Gibout, S., 2010. "Dynamic simulation of reciprocating refrigeration compressors and experimental validation". *International Journal of Refrigeration*, Vol. 33, pp. 381-389.
- Chiang, Ng. *et al*. 2014. "Dynamic modelling of an automotive variable speed air conditioning system using nonlinear autoregressive exogenous neural networks". *Applied Thermal Engineering*, Vol. 73, pp. 1255-1269.
- Cleland, A. C., 1986. "Computer subroutines for rapid evaluation of refrigerant thermodynamic properties". *International Journal of Refrigeration*, Vol. 9, pp. 346-351.
- Damle, R., Rigola, J., Pérez-Segarra, C. D., Castro, J., and Oliva, A., 2011. Object-oriented simulation of reciprocating compressors: Numerical verification and experimental comparison. *International Journal of Refrigeration*, Vol. 34, pp. 1989-1998.
- Duarte, W. M., Pabon, J. J. G., Maia, A. A. T., and Machado, L., 2019. "Nonisentropic Phenomenological Model of a Reciprocating Compressor". *International Journal of Air-Conditioning and Refrigeration*, Vol. 27, paper 1950039.
- Duprez, M. E., Dumont, E., and Frère, M., 2007. Modelling of reciprocating and scroll compressors. *International Journal of Refrigeration*, Vol. 30, pp. 873-886.

- Dutra, T., and Deschamps, C. J., 2015. "A simulation approach for hermetic reciprocating compressors including electrical motor modeling". *International Journal of Refrigeration*, Vol. 59, pp. 168-181.
- Dzemic, Z., Sirok B., Bizjan B, 2018. "Turbine flowmeter response to transitional flow regimes". *Flow Measurement and Instrumentation* Vol. 59, pp. 18-22.
- Ertunc, H. M., Hosoz, M. 2005. "Artificial neural network analysis of a refrigeration system with an evaporative condenser". *Applied Thermal Engineering*, Vol. 26, pp. 627-635.
- Fang, X. et al. 2014. "Empirical models for efficiency and mass flow rate of centrifugal compressors". *International Journal of Refrigeration*, Vol. 41, pp. 190-199.
- Gill J., Singh J. 2017. " Use of artificial neural network approach for depicting mass flow rate of R134a /LPG refrigerant through straight and helical coiled adiabatic capillary tubes of vapor compression refrigeration system". *International Journal of Refrigeration*, Vol. 86, pp. 228-238.
- Hafner, J. and Gaspersic, B. 1990. "Dynamic Modeling of Reciprocating Compressor". *International Compressor Engineering Conference*. Paper 708.
- Haykin, S. 2009. "Neural Networks and Learning Machines". Editora Pearson Prentice Hall.
- He, Z. et al. 2020. "Investigation on the Mass Flow Rate of a Refrigerator Compressor Based on the p-V Diagram". *Applied Sciences*, Vol. 10, pp. 6650.
- Hosoz, M., Ertunc H. M., 2006. "Artificial neural network analysis of automobile air conditioning system". *Energy Convers*, Vol. 47, pp. 1574-1587.
- Hu, J., Yang, L., Shao, L. L., and Zhang, C. L., 2014. Generic network modeling of reciprocating compressors. *International Journal of Refrigeration*, Vol. 45, pp. 107-119.
- Hu, Y., Chen Z., Chang, P. 2021. "Fluid-Structure Coupling Effects in a Dual U-Tube Coriolis Mass Flow Meter". *Sensors*, Vol. 21, pp. 982.
- Kamar et al. 2013. "Artificial neural networks for automotive air-conditioning systems performance prediction". *Applied Thermal Engineering*, Vol. 50(1), pp. 63-70.
- Kim, S. S., Kim, M. J., Lee, J. H., Lee, J. S., Cho, H. J., and Kang, C. G. 2021. "Mathematical Modeling and Simulation of a Two-stage Reciprocating Air Compressor Considering Heat Transfer Effect". In *21st International Conference on Control, Automation and Systems (ICCAS)* (pp. 2240-2242). IEEE.
- Kingma, D., Ba, J. 2014 "Adam: A Method for Stochastic Optimization". *International Conference for Learning Representations*, San Diego.
- Kizilkan, Ö. 2011 "Thermodynamic analysis of variable speed refrigeration system using artificial neural networks". *Expert Systems with Applications*, Vol. 38(9), pp.11686-11692.

- Kolhe, V. A., Edlabadkar, R. L. 2021 "Performance evaluation of Coriolis mass flow meter in laminar flow regime". *Flow Measurement and Instrumentation*, Vol.77, pp.101837.
- Ledesma, S., Belman-Flores, J. M., and Barroso-Maldonado, J. M., 2015. "Analysis and modeling of a variable speed reciprocating compressor using ANN". *International Journal of Refrigeration*, 59, 190-197.
- Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., Talwalkar, A., 2018. "Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization". *Journal of Machine Learning Research*, Vol. 18, pp. 1-52.
- Linnert, M. A., et al. 2019. "Dynamic Offset Correction of Electromagnetic Flowmeters". *IEEE Transactions on instrumentation and measurement*, Vol. 68, pp. 1284-1293.
- Lynnworth, L. C., Liu, Y. 2006. "Ultrasonic flowmeters: Half-century progress report, 1955-2005". *Ultrasonics*, Vol. 44, pp. 1371-1378.
- Maia, A. A. T. 2005 Metodologia de Desenvolvimento de um Algoritmo para o Controle Simultâneo da Carga Térmica e do Grau de Superaquecimento de um Sistema de Refrigeração (in Portuguese). Doctoral Dissertation, Federal University of Minas Gerais.
- Maia, A. A. T., Koury, R. N. N., Machado, L. 2013. "Development of a control algorithm employing data generated by a white box mathematical model". *Applied Thermal Engineering*, Vol. 54, pp. 120-130.
- Manivannan M, Najafi B, Rinaldi F. 2017. " Machine Learning-Based Short-Term Prediction of Air-Conditioning Load through Smart Meter Analytics". *Energies*, Vol. 10(11).
- Matplotlib, 2021. Matplotlib. Disponível em: <https://matplotlib.org>. Acesso em: 12 de dezembro de 2021.
- McCulloch, W.S., Pitts, W., 1943. "Optimization of time-varying systems". *IEEE Transactions on Automatic Control*, Vol. 10, pp. 289-294.
- Mohanraj, M., Jayaraj, S., Muraleedharan, C., 2012. "Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems—A review". *Renewable and Sustainable Energy Reviews*, Vol. 16, pp. 1340-1358.
- Murakawa, H. et al. 2020. "Evaluation method of transit time difference for clamp-on ultrasonic flowmeters in two-phase flows". *Experimental Thermal and Fluid Science*, Vol. 112, pp. 109957.
- Ndiaye, D., and Bernier, M., 2010. "Dynamic model of a hermetic reciprocating compressor in on-off cycling operation (Abbreviation: Compressor dynamic model)". *Applied Thermal Engineering*, Vol. 30, pp. 792-799.
- Numpy, 2021. Numpy. Disponível em: <https://numpy.org>. Acesso em: 12 de dezembro de 2021.

- Pandas, 2021. Python Data Analysis Library. Disponível em: <https://pandas.pydata.org/index.html>. Acesso em: 12 de dezembro de 2021.
- Rasmussen, B. D. and Jakobsen, A., 2000. "Review of Compressor Models and Performance Characterizing Variables". *International Compressor Engineering Conference*, paper 1429.
- Rosiek, S., Batlles, F. J., 2011. "Performance study of solar-assisted air-conditioning system provided with storage tanks using artificial neural networks". *Internal Journal of Refrigeration*, Vol. 34, pp. 1446-1454.
- Roskosch, D., Venzik, V., and Atakan, B., 2017. "Thermodynamic model for reciprocating compressors with the focus on fluid dependent efficiencies". *International Journal of Refrigeration*, Vol. 84, pp. 104-116.
- Sá, L. C. B. et al. 2019 "Prediction of environment parameters inside a greenhouse using an LSTM model". 25° ABCM International Congress of Mechanical Engineering, Uberlândia, Minas Gerais, Brasil.
- Saleh, B., Aly, A. A., 2016. "Artificial neural network models for depicting mass flow rate of R22, R407C and R410A through electronic expansion valves". *Internal Journal of Refrigeration*, Vol. 63, pp. 113-124.
- Scikit-Learn, 2021. Scikit-Learn – Machine Learning in Python. Disponível em: <https://scikit-learn.org/stable>. Acesso em: 12 de dezembro de 2021.
- Silva, Ernane and Dutra, Thiago, 2021. "An Approach to Detach the Thermodynamic Losses of a Reciprocating Compressor". *International Compressor Engineering Conference*. Paper 2682.
- Wang, B. et al. 2018. "Evaluation approach to dynamic characteristic of turbine flowmeters considering calibration system response". *Flow Measurement and Instrumentation*, Vol. 64, pp. 126-132.
- Wang, T., Roger B., 2014. "Coriolis flowmeters: a review of developments over the past 20 years, and an assessment of the state of art and likely future directions". *Flow Measurement and Instrumentation*, Vol. 40, pp. 99-123.
- Wang, T., Wang, J., Guo, Y., Peng, X., Yang, J., and Zhang, Z., 2020. "The study on mass transport process in the cylinder of CO₂ compressor based on pV diagram". *Applied Thermal Engineering*, Vol. 174, p. 115314.
- Wang H, Toubert S. 1991. "Distributed and non-steady-state modelling of an air cooler". *International Journal of Refrigeration*, Vol. 14, pp. 98-111.

- Willigen, D., Massaad, J., Verweij, M. 2021. "An Algorithm to Minimize the Zero-Flow Error in Transit-Time Ultrasonic Flowmeters". *IEEE Transactions on Instrumentation and Measurement*, Vol. 70, pp. 7500109.
- Winandy, E., Saavedra, C., & Lebrun, J., 2002. "Simplified modelling of an open-type reciprocating compressor". *International journal of thermal sciences*, Vol. 41, pp. 183-192.
- Yang, B., Bradshaw, C. R., & Groll, E. A., 2013. "Modeling of a semi-hermetic CO₂ reciprocating compressor including lubrication submodels for piston rings and bearings". *International journal of refrigeration*, Vol. 36, pp. 1925-1937.
- Yang, D. et al 2020a. "Huge-scale capacitance mass flowmeter in gas/solid two-phase flow with rectangular vertical pipeline". *Measurement*, Vol. 216, pp. 107235.
- Yang, Q. et al 2020b. "Measurement of Water Velocity in Gas-Water Two-Phase Flow with the Combination of Electromagnetic Flowmeter and Conductance Sensor". *Sensors*, Vol. 20, pp. 3122.
- Zhang C. 2005. " Generalized correlation of refrigerant mass flow rate through adiabatic capillary tubes using artificial neural network". *International Journal of Refrigeration*, Vol. 28, pp. 506-514.

8 APÊNDICE

```

#include<16F877A.h>
#define ADC=10
#define fuses XT,NOWDT,PUT,NOPROTECT,NODEBUG,NOBROWNOUT,NOLVP
#define use delay(clock=10000000)
#include <lcd2.c>
#include <stdio.h>
#include <math.h>
#define priority ext, timer0

int seg=0, ciclos=0;
#define int_timer0

void tempo(){
    ciclos=ciclos+1;
    if(ciclos==125){
        ciclos=0;
        seg=seg+1;
    }
    set_timer0(131+get_timer0());
}

int32 n=0;
#define INT_ext

void RB_ISR(){
    n=n+1;
}

float PSATU(float t) {
    return exp(21.30086 - 2087.523/(t+239.58));
}

float VVAP(float t){
    return (exp(-12.408669+2658.307450/(t+273.15))*(1.006543+6.990186e-4*t-4.971119e-6*t*t-3.051019e-7*t*t*t));
}

float VFSA1(float t, float dt) {
    return (1+5.029847e-3*dt-5.313493e-6*dt*dt+2.696488e-5*dt*t-1.603707e-7*t*dt*dt);
}

float VFSA2(float t, float dt) {
    return 4.673455e-7*dt*t*t-2.016173e-9*(dt*t)*(dt*t);
}

float softplus(float x){

```

```

    return log(1+exp(x));
}

void config() {
    lcd_init();

    setup_ADC_ports(RA0_RA1_RA3_analog);
    setup_ADC(ADC_CLOCK_INTERNAL);

    setup_timer_0(RTCC_INTERNAL | RTCC_DIV_16);
    enable_interrupts(global | int_timer0);
    set_timer0(131);

    enable_interrupts(global);
    enable_interrupts(INT_ext);
}

void main(void){

    // pesos e biases
    float w1[4][4] = {{-0.0829615,-0.486509,0.3663,-0.306383},{0.793527,-0.0952572,-
        0.0101221,0.982245},{-1.74824,-0.154079,1.01489,-0.212918},{0.773399,-0.370748,-
        0.562138,1.9416}};
    float w2[4][1] = {{-0.43016},{0.576953},{0.83605},{-0.825405}};
    float b1[1][4] = {{-0.189378,-0.309269,-0.0917707,0.345497}};
    float b2[1][1] = {{-0.319894}};

    int i,j;
    float te, tsa, vv, a, b, p, tc;

    float rot = 0;

    float multiply1[1][4], multiply2, sum1[1][4], sum2;

    float temp = 0;

    float inputs[1][4];

    config();

    do{
        if(n > 500)
        {
            rot = n*100.0/(seg);
            seg=0;
            n=0;
            lcd_gotoxy(1,1);
            printf(lcd_putc,"%4.2f", rot);
        }
    }
}

```

```

set_adc_channel(0);
delay_ms(10);
te = read_adc()*0.489-273.25;
if (te<0){
    te = te-0.25;
}

set_adc_channel(1);
delay_ms(10);
tsa = read_adc()*0.489-273.25 - te;

set_adc_channel(2);
delay_ms(10);
tc = read_adc()*0.489-273.25;

p = PSATU(tc)/PSATU(te);

a = VFSA1(te, tsa);
b = VFSA2(te, tsa);
vv = VVAP(te)*(a+b);

inputs[0][0] = (rot-650)/100;
inputs[0][1] = (p-2.75)/(5.32-2.75);
inputs[0][2] = (te+7.65)/(10.73+7.65);
inputs[0][3] = (vv-0.049865745)/(0.09743596-0.049865745);

for ( i = 0 ; i < 4 ; i++ ){
    for ( j = 0 ; j < 4 ; j++ ){
        temp = temp + inputs[0][j]*w1[j][i];
    }
    multiply1[0][i] = temp;
    temp = 0;
}

for (i = 0; i < 4; ++i) {
    sum1[0][i] = multiply1[0][i] + b1[0][i];
}

for (i = 0; i < 4; ++i) {
    sum1[0][i] = softplus(sum1[0][i]);
}

for ( i = 0 ; i < 4 ; i++ ){
    temp = temp + sum1[0][i]*w2[i][0];
}

multiply2 = temp;

sum2 = multiply2 + b2[0][0];

```

```
sum2 = softplus(sum2);  
  
temp = sum2*(76.07 - 33.88)+33.88;  
  
lcd_gotoxy(1,2);  
printf(lcd_putc,"%4.2f", temp);  
  
temp = 0;  
sum2 = 0;  
  
}while(true);  
}
```