

Previsão da vazão mássica em máquinas frigoríficas utilizando redes neurais artificiais – EVR2021-0012

Vinícius D. Fonseca ^{1,*}, Antônio A. T. Maia ²

¹ Universidade Federal de Minas Gerais, Departamento de Engenharia Mecânica, Laboratório de Automação e Controle
Belo Horizonte, Minas Gerais, Brasil, 31270-901

² Universidade Federal de Minas Gerais, Departamento de Engenharia Mecânica, Laboratório de Automação e Controle
Belo Horizonte, Minas Gerais, Brasil, 31270-901

* Autor para correspondência, vinicius.davidf@gmail.com

Resumo

O projeto de sistemas de controle para máquinas frigoríficas muitas vezes depende da medição da vazão mássica de fluido refrigerante. Essa medida, feita de forma direta, envolve medidores de preço elevado, que exigem a violação do circuito frigorífico para serem instalados. Um modelo baseado em Redes Neurais Artificiais (RNA) pode ser utilizado para prever o valor da vazão mássica através de grandezas facilmente medidas, e a um baixo custo. Esse artigo tem como objetivo construir um modelo de RNA do tipo *perceptron* de multicamada para realizar as previsões. A bancada de testes consiste em um sistema de refrigeração e aquecimento por compressão vapor, tendo como fluido primário R134a e fluido secundário água pura no evaporador e condensador. Os dados experimentais foram coletados para vários regimes permanentes diferentes. Foram comparados dois modelos de RNA diferentes, um geral que previa os valores para qualquer regime permanente, e um modelo específico com uma rede para cada ponto de operação. A rede geral teve um erro máximo de 20,32%, enquanto a específica de 5,73%. No segundo caso, o erro esteve dentro da incerteza da medição da vazão mássica dos dados de treino.

Paravras-chave: Máquinas Frigoríficas, Redes Neurais Artificiais, Previsão da vazão mássica

Introdução

O principal objetivo de sistemas de refrigeração é reduzir a temperatura de um local fechado ou substância, e manter essa temperatura. Para tal, esses sistemas normalmente possuem um controle por termostato, o que resulta em um alto consumo energético (Kizilkan, 2011).

O uso de sistemas de controle em equipamentos de refrigeração se faz cada vez mais necessário, pois permitem a redução do consumo energético e a obtenção da temperatura desejada com maior rapidez (Maia, 2005). Para desenvolver um trabalho de pesquisa e elaborar um sistema de controle, muitas vezes é necessário conhecer a vazão mássica de fluido refrigerante em máquinas frigoríficas. Uma dificuldade encontrada está no fato de que os medidores normalmente empregados para esta finalidade, além de invasivos, possuem custo normalmente elevado. Outro ponto é que esses equipamentos são muitas vezes sensíveis a vibração e a campos magnéticos, podendo apresentar leituras incorretas quando sujeitos a esse tipo de distúrbio.

As redes neurais artificiais (RNAs) são muito usadas em sistemas de refrigeração para a previsão de diversos parâmetros. Kamar et al. (2013) utilizou esse modelo para descobrir o coeficiente de performance, o trabalho no compressor e a capacidade de refrigeração em uma máquina frigorífica. Kizilkan (2011) utilizou uma abordagem semelhante para prever, além dos anteriormente citados, a vazão mássica e a irreversibilidade do ciclo.

Com o uso de RNAs nesse estudo é possível correlacionar os valores de vazão com outras grandezas mais facilmente observadas durante a operação da máquina frigorífica. Dessa

forma, a vazão mássica poderia ser avaliada de forma indireta, a partir de grandezas facilmente medidas e a um custo baixo

O objetivo do trabalho é prever o valor da vazão mássica em uma máquina frigorífica de forma indireta, a partir da correlação de parâmetros facilmente observados, utilizando uma rede neural artificial (RNA).

Metodologia

A metodologia que será utilizada na realização do trabalho consiste, basicamente, na coleta de dados experimentais, formulação teórica e construção do modelo, que envolva a elaboração, treinamento, otimização dos hiperparâmetros e validação da RNA. Cada uma dessas etapas será melhor discutida nas próximas seções a serem apresentadas.

A partir dos dados experimentais, foi possível criar o modelo da RNA e dar início ao treinamento. Para alimentar a rede, os dados de entrada utilizados foram a rotação do compressor, e as temperaturas de condensação e evaporação, porque, conforme será demonstrado (Maia, 2005), essas são as grandezas diretamente relacionadas com a vazão mássica, obtida na saída da rede.

Para o desenvolvimento do modelo, foram avaliadas as funções de ativação: sigmoide e tangente hiperbólica, pois permitem dados de entrada positivos e negativos. Os otimizadores foram o *stochastic gradient descent*, parecido com o utilizado por Kizilkan (2011), e o Adam, utilizado por Sá (2019). Além disso, foram avaliados o número de camadas escondidas e a quantidade de neurônios em cada camada, variando de uma a duas camadas com 5 a 25 neurônios.

Para avaliar o desempenho da rede, foi calculado o erro quadrático médio dos resultados após cada iteração, que é dado pela Equação 1 (Sá, 2019):

$$RMSE = \sqrt{\frac{\sum_i^n (d_i - p_i)^2}{n}} \quad (1)$$

Em que RMSE é o erro quadrático médio, n é o número de dados, d_i é o valor desejado e p_i é o valor previsto.

Assim, cada hiperparâmetro foi avaliado individualmente, utilizando um número de épocas suficientes até que a variação do erro fosse insignificante.

Coleta de dados

Os dados utilizados nesse trabalho foram extratos do estudo apresentado por Maia (2005) e Maia et al. (2013).

Nestes trabalhos, foram coletados os valores de temperaturas de condensação e evaporação, vazão mássica e rotação do compressor, para diferentes pontos de operação de uma máquina frigorífica. O banco de testes foi projetado para operar com uma capacidade de refrigeração máxima de 3 kW. Ele consistia 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 condensador.

Formulação teórica

Em um sistema de refrigeração por compressão de vapor, a vazão mássica de fluido refrigerante pode ser calculada pela Equação 2 (Maia, 2013):

$$\dot{m} = N \cdot V \cdot \rho \cdot \eta \quad (2)$$

As variáveis $\dot{m}$, N , V , ρ e η representam respectivamente a vazão mássica na saída do compressor, a rotação do compressor, a cilindrada, a massa específica do fluido frigorífico na saída do evaporador e o rendimento volumétrico do compressor. Para calcular o rendimento volumétrico foi utilizada a Equação 3 (Maia, 2013):

$$\eta = 1 + c - c \cdot \left(\frac{P_c}{P_e}\right)^{\frac{1}{n}} \quad (3)$$

Em que a variável c representa o coeficiente de espaço morto do compressor, dado pela razão entre o volume residual quando o êmbolo se encontra no ponto morto superior e o volume coberto pelo pistão durante a sucção. O coeficiente de espaço morto do compressor é determinado utilizando-se o valor do rendimento volumétrico obtido em testes experimentais. As variáveis P_c e P_e representam as pressões de condensação e evaporação, respectivamente.

Como o compressor utilizado neste trabalho é considerado como sendo adiabático, a variável, n representa a razão entre os calores específicos do fluido frigorífico a pressão constante e a volume constante.

Dessa forma, a vazão depende diretamente dos valores de pressão de condensação, pressão de evaporação e rotação do compressor. As pressões estão termodinamicamente relacionadas às temperaturas. Por isso, foram escolhidos

como entrada do o modelo, os valores de rotação no compressor, e as temperaturas de saída do condensador e entrada do evaporador.

Modelagem da RNA

O modelo de RNAs foi baseado na anatomia do cérebro humano. Esse possui a capacidade de organizar os neurônios de forma a reconhecer padrões e criar sistemas complexos e não lineares (Haykin, 2009).

O tipo de RNA utilizado nesse trabalho foi o *perceptron* de multicamadas. Ele consiste na combinação da camada de entrada, camadas escondidas e camada de saída. Cada uma delas tem uma determinada quantidade de neurônios, uma matriz de pesos e um vetor de saída. Cada neurônio possui uma tendência (Azizi e Ahmadloo, 2016), que é um valor independente das variáveis de entrada. Esse valor deve ser somado ao resultado final do neurônio para eliminar a influência de fatores externos. A camada de entrada é alimentada pelo valor de três grandezas independentes. Essa camada se conecta a uma camada escondida, em que os valores são passados multiplicando pelos pesos respectivos. Todas as entradas dos neurônios são somadas, e transmite uma informação de acordo com a função de ativação dos neurônios. O resultado passado pelo neurônio é dado pela Equação 4 (Sá, 2019):

$$y_j = f\left(\sum_{i=1}^n x_i w_{ij} + b_j\right) \quad (4)$$

Em que a variável y_j representa a saída de cada neurônio, $f()$ a função de ativação, x_i as entradas, w_{ij} os pesos de cada entrada e b_j a tendência de cada neurônio.

Assim, esse processo é feito até se obter o resultado final na saída. O número de neurônios na camada escondida é definido de forma a se obter um modelo que dê resultados satisfatórios, mas não seja mais complexo que o suficiente.

A Figura 1 mostra a arquitetura do modelo de um *perceptron* de multicamadas (Haykin, 2009).




Figura 1: Modelo representativo de uma rede neural artificial

Esse modelo de redes neurais foi feito utilizando a linguagem de programação python e a biblioteca TensorFlow, que é própria para trabalho com redes neurais. Para a elaboração, deve-se definir os hiperparâmetros de número de camadas, número de neurônios, função de ativação e

otimizador, que serão utilizados inicialmente. Esses hiperparâmetros foram otimizados no decorrer do trabalho através de uma comparação do erro quadrático médio resultante de cada treinamento.

O treino das RNAs é baseado em dados experimentais ou em resultados de modelos numéricos. Esse treino consiste no ajuste dos pesos e tendências de cada neurônio da rede. O processo de treinamento é feito de forma a minimizar o erro final obtido pela RNA (Ertunc, 2005).

O processo de se colocar os valores de entrada, multiplica-los pelos pesos, passar pelos neurônios e somá-los para se chegar no valor final é chamado *feedforward*. Ao comparar o valor obtido com o esperado, tem-se o erro da rede. O uso do erro para corrigir os pesos é chamado de *backpropagation*. Ao se repetir essa etapa várias vezes para os dados de treino, realiza-se o treinamento da rede neural.

Quando um valor entra em um neurônio, ele é passado pela função de ativação, que, normalmente, retorna um valor entre -1 e 1, ou entre 0 e 1. Como essa função não tem um comportamento linear, é ela que traz a não linearidade ao modelo de redes neurais.

Uma vez que os neurônios retornam apenas valores nessa faixa, o dados de entrada devem ser normalizados antes de serem usados, de forma que fiquem todos na mesma ordem de grandeza. Isso é necessário pois caso existam dados com ordem de grandezas diferentes, um irá sobressair, o que resultará na criação de um modelo errado. Os dados desse trabalho foram normalizados dividindo cada grandeza pelo seu valor máximo dentro do conjunto de dados, obtendo, assim, valores entre -1 e 1.

Com cada etapa de testes do treinamento da RNA é possível avaliar parâmetros como o tempo necessário para o treinamento, que está diretamente ligado ao esforço computacional, e o erro quadrático médio, que revela a diferença entre os valores esperados e os previstos.

A partir desses parâmetros, tem-se o desempenho geral da rede. Assim, serão feitas alterações nos hiperparâmetros da RNA de forma a maximizar o desempenho, obtendo melhores resultados com menor esforço computacional.

Os hiperparâmetros mais significantes que podem ser alterados são: o número de camadas escondidas, o número de neurônios em cada camada, a função de ativação dos neurônios e o otimizador. Quanto mais camadas e mais neurônios, mais complexo fica o modelo criado, o que pode resultar em *overfitting* e possui um treinamento lento. Por isso, o ideal é se obter bons resultados com o modelo mais simples possível.

Sempre que um hiperparâmetro for alterado, deve-se recomençar o treinamento da rede do início. Isso acontece pois os pesos podem ter valores completamente diferentes dependendo do modelo.

Para finalizar, é necessário validar a rede neural obtida. Essa validação será feita da seguinte maneira. Uma parcela dos dados experimentais em regime permanente que nunca foram usados no treinamento da RNA, são colocados para teste. É importante utilizar dados inéditos na validação para evitar que se tenha bons resultados apenas porque a RNA já decorou os dados utilizados. Então, é possível comparar os valores estimados para a vazão mássica com os valores reais coletados no experimento. Caso o erro máximo seja menor que a incerteza de medição, prova-se que a RNA consegue prever com sucesso.

Resultados

Para avaliar a influência de cada hiperparâmetro, foram realizados diferentes treinamentos, todos com 2000 épocas, de forma que, em cada treino, algum hiperparâmetro era alterado. Após avaliar várias configurações diferentes, foi possível observar a influência de cada um no resultado. Assim foi possível escolher a combinação ideal de acordo com o RMSE final após cada treinamento. A Tabela 1 mostra os erros para as principais configurações de número de neurônios e número de camadas. Já a Tabela 2 para a funções de ativação e a Tabela 3 para otimizadores.

Tabela 1: RMSE para diferentes números de neurônios e camadas escondidas

Número de neurônios	Uma camada escondida	Duas camadas escondidas
5	0,001215	0,001278
10	0,001771	0,001471
15	0,001525	0,001493
20	0,001664	0,001257
25	0,001994	0,001598

Tabela 2: RMSE para diferentes funções de ativação

Função de ativação	Erro
Sigmoide	0.001966
Tangente hiperbólica	0.001750

Tabela 3: RMSE para diferentes otimizadores

Otimizador	Erro
<i>Stochastic gradient descent</i>	0.001744
Adam	0.001855

A partir dos resultados foi possível observar que aumentar o número de neurônios e camadas escondidas gera um modelo mais complexo, tornando o aprendizado mais difícil. Seria possível atingir os mesmos valores de erro para configurações com mais neurônios e camadas, porém isso poderia provocar um *overfitting*, além de gastar mais esforço computacional desnecessariamente. Por isso, o número de neurônios escolhidos foi cinco, com uma camada escondida, o modelo mais simples com um resultado satisfatório.

A tangente hiperbólica como função de ativação e o *stochastic gradient descent* como otimizador foram escolhidos por possuírem os melhores resultados.

Para definir o número de épocas que seriam usadas durante o treinamento, foi feita uma análise da evolução do erro durante o treino da RNA. A Figura 2 mostra o RMSE em função do número de épocas.




Figura 2: Erro da RNA em função do número de épocas

É possível observar que, a partir de 500 épocas, o erro quase não se altera. Portanto, os treinamentos foram feitos até esse patamar.

Na elaboração das RNAs, duas estratégias foram utilizadas. Na primeira, foi feita uma RNA geral, que engloba todos os pontos de todas as temperaturas de ebulição diferentes. A Figura 3 mostra o resultado obtido na validação da rede.




Figura 3: Resultado da RNA geral

Nesse caso, o erro máximo obtido foi de 20,32%, equivalente a 2,52 kg/h, o que vai além da incerteza de medição máxima de 1,35 kg/h do experimento.

Com o intuito de melhorar os resultados, a base de dados foi dividida entre as diferentes temperaturas de ebulição, cada uma relacionada a um regime permanente diferente. Então, foi feita uma RNA para cada caso, e elas foram treinadas e validadas de forma separada. A Figura 4 mostra o resultado da validação no segundo caso.




Figura 4: Modelo representativo de uma rede neural artificial

Nesta segunda abordagem, o modelo obteve um resultado melhor, com um erro máximo de 5,73%, equivalente a 0,92 kg/h, o que está dentro da faixa de incerteza do experimento.

Conclusões

Nesse artigo, um modelo para previsão da vazão mássica em uma máquina frigorífica foi construído. Foram utilizados como dados de entrada a rotação no compressor e as temperaturas de condensação e evaporação. Os modelos foram elaborados utilizando uma rede neural do tipo *perceptron* de multicamada, com a função de ativação tangente hiperbólica e otimizador *stochastic gradient descent*. A RNA que avaliou todos os pontos de modo conjunto obteve um erro máximo de 20,32%, enquanto as RNAs específicas para cada ponto de regime permanente obtiveram um erro máximo de 5,73%.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico e ao Programa de Pós-Graduação em Engenharia Mecânica da UFMG.

Referências

- Azizi, S., Ahmadloo, E., (2016) Prediction of heat transfer coefficient during condensation of R134a in inclined tubes using artificial neural networks. *Applied Thermal Engineering*, 203-210.
- Ertunc, H. M., Hosoz, M. (2005). Artificial neural network analysis of a refrigeration system with an evaporative condenser. *Applied Thermal Engineering*, 627-635.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. Editora Pearson Prentice Hall.
- Kamar et al. (2013). Artificial neural networks for automotive air-conditioning systems performance prediction. *Applied Thermal Engineering* 63-70.
- Kizilkan, Ö. (2011) Thermodynamic analysis of variable speed refrigeration system using artificial neural networks. *Expert Systems with Applications*, 11686-11692.
- 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. Tese de Doutorado, Universidade Federal de 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* 54: 120-130.
- 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.

Aviso de responsabilidade

Os autores são os únicos responsáveis pelo material incluído neste documento.