

Diagnóstico termodinâmico em um sistema de refrigeração por compressão mecânica de vapor utilizando modelos e técnicas de inteligência computacionais

Thermodynamic diagnosis in a mechanical steam compression cooling system using computational intelligence models and techniques

DOI:10.34117/bjdv7n4-076

Recebimento dos originais: 07/03/2021

Aceitação para publicação: 05/04/2021

Tiago Mendes

Doutor em Engenharia Mecânica

Instituição de atuação atual: UFVJM - Universidade Federal dos Vales do Jequitinhonha e Mucuri

Endereço completo: Rodovia MGT 367 – Km 583, n° 5000, Alto da Jacuba, CEP 39100-000, Diamantina-MG/Brasil

E-mail: tiago.mendes@ict.ufvjm.edu.br

Euler Guimarães Horta

Doutor em Engenharia Elétrica

Instituição de atuação atual: UFVJM - Universidade Federal dos Vales do Jequitinhonha e Mucuri

Endereço completo: Rodovia MGT 367 – Km 583, n° 5000, Alto da Jacuba, CEP 39100-000, Diamantina-MG/Brasil

E-mail: euler.horta@ict.ufvjm.edu.br

Jader Fernandes Pereira

Engenheiro Mecânico

Instituição de atuação atual: UFVJM - Universidade Federal dos Vales do Jequitinhonha e Mucuri

Endereço completo: Rodovia MGT 367 – Km 583, n° 5000, Alto da Jacuba, CEP 39100-000, Diamantina-MG/Brasil

E-mail: jader.fernandes@ymail.com

Matheus dos Santos Guzella

Mestre em Engenharia Mecânica

Instituição de atuação atual: UFVJM - Universidade Federal dos Vales do Jequitinhonha e Mucuri

Endereço completo: Rodovia MGT 367 – Km 583, n° 5000, Alto da Jacuba, CEP 39100-000, Diamantina-MG/Brasil

E-mail: matheus.guzella@ict.ufvjm.edu.br

Oswaldo José Venturini

Doutor em Engenharia Mecânica

Instituição de atuação atual: UNIFEI - Universidade Federal de Itajubá

Endereço completo: Avenida BPS, n° 1303, Pinheirinho, CEP 37500 - 903, Itajubá – MG/Brasil

E-mail: osvaldo@unifei.edu.br

Marcelo José Pirani

Doutor em Engenharia Mecânica

Instituição de atuação atual: UNIFEI - Universidade Federal de Itajubá

Endereço completo: Avenida BPS, n° 1303, Pinheirinho, CEP 37500 - 903, Itajubá –
MG/Brasil

E-mail: pirani@unifei.edu.br

RESUMO

Nos últimos anos, a utilização de sistemas de refrigeração vem aumentando consideravelmente no setor comercial e industrial. Esse fenômeno é fomentado principalmente pela maior demanda por alimentos prontos para o consumo, por conta da mudança de hábitos alimentares da população. Os sistemas de refrigeração por compressão mecânica de vapor, maciçamente empregados nesses setores, são grandes consumidores de energia. Atualmente modelos computacionais vêm sendo aplicados a esses sistemas para analisar suas condições de operação e melhorar a sua eficiência. Diante desse cenário, o objetivo deste trabalho é desenvolver um modelo computacional de um sistema de refrigeração capaz de gerar dados de funcionamento do sistema com e sem a presença de degradações em seus principais componentes. Nestes dados será testado um classificador baseado em inteligência computacional quanto à sua performance em diagnosticar o estado do sistema analisado. Os resultados apresentados neste artigo mostram que a utilização de uma técnica de inteligência computacional é oportuna para o diagnóstico termodinâmico do sistema de refrigeração em estudo.

Palavras-chave: Sistema de Refrigeração, Diagnóstico Termodinâmico, Modelo Computacional, Inteligência Computacional e Degradações nos Componentes.

ABSTRACT

In recent years, the use of refrigeration systems has increased considerably in the commercial and industrial sector. This phenomenon is mainly fostered by the greater demand for ready-to-eat foods, due to the changing eating habits of the population. Mechanical vapor compression cooling systems, massively used in these sectors, are major energy consumers. Currently computational models have been applied to these systems to analyze their operating conditions and improve their efficiency. Given this scenario, the objective of this work is to develop a computational model of a refrigeration system capable of generating system operating data with and without the presence of degradations in its main components. In this data will be tested a classifier based on computational intelligence as to its performance in diagnosing the state of the analyzed system. The results presented in this article show that the use of a computational intelligence technique is opportune for the thermodynamic diagnosis of the refrigeration system under study.

Keywords: Refrigeration System, Thermodynamic Diagnosis, Computational Model, Computational Intelligence and Degradations in Components.

1 INTRODUÇÃO

As possibilidades de degradações nos principais componentes de um sistema de refrigeração para uma determinada condição de referência são muito amplas. Apenas considerando as possibilidades de avarias de forma individual em cada componente (compressor, condensador, dispositivo de expansão e evaporador), pode-se enumerar uma gama enorme de padrões de degradações quando comparado com situações de referência. Técnicas de inteligência computacional são oportunas para identificação desses padrões. Se devidamente estruturado, um algoritmo de aprendizagem pode ser treinado a partir de situações previamente conhecidas, realizando previsões e generalizações com alta velocidade e confiabilidade (Kocyigit, 2015 e Mendes et al., 2020). Por sua vez, a modelagem matemática e computacional tem sido amplamente utilizada para previsão de desempenho e funcionamento de sistemas de refrigeração (Qiao et al., 2010; Mendes et al., 2012, Rasmussen e Shenoy, 2012 e Mendes et al., 2020). Essa modelagem também possibilita a obtenção de dados históricos do sistema analisado para a etapa de treinamento de um algoritmo de classificação (Ding, 2007 e Mohanraj et al., 2012).

Em diagnóstico e detecção de degradações em sistemas em geral, o objetivo é identificar as avarias em seu estado inicial. Esse fato confere uma dificuldade em se obter sucesso através da análise de pequenas variações nas grandezas lidas no sistema analisado. Diante desse contexto o esperado é que técnicas de inteligência computacional sejam capazes de lidar com essa dificuldade além de automatizar o procedimento de detecção de degradações.

Uma técnica de inteligência computacional geralmente utilizada para solução de problemas complexos são as redes neurais artificiais (RNAs) (Braga et al., 2007). Em geral, os algoritmos para treinamento de RNAs são lentos e computacionalmente caros (Mohanraj et al., 2012). Com o objetivo de minimizar esse problema, Huang et al. (2006) propuseram uma forma rápida e eficiente de treinamento de RNAs que denominaram *Extreme Learning Machine* (ELM). A ELM é uma técnica de treinamento que consiste simplesmente em definir de forma aleatória os parâmetros da camada escondida de uma RNA e calcular os pesos de saída através da solução de um sistema de equações lineares (Horta, 2015). Em virtude da facilidade do treinamento de uma ELM, a proposta deste trabalho é aplicar esse tipo de classificador em dados gerados através de um modelo matemático e computacional de um sistema de refrigeração, com o objetivo de identificar degradação nos componentes desse sistema. Esse estudo irá discutir a respeito da oportuna utilização de técnicas de classificação baseadas em inteligência computacional

em diagnóstico e detecção de degradações. O modelo computacional do sistema de refrigeração apresentado nesse trabalho possui o papel de fornecer os dados utilizados para a análise dessa utilidade.

2 MODELO MATEMÁTICO E COMPUTACIONAL PARA O SISTEMA DE REFRIGERAÇÃO

No presente trabalho, o modelo matemático e computacional do sistema de refrigeração será empregado para uma planta frigorífica utilizada para refrigerar e congelar 16 ton/dia de carne de cordeiro, com capacidade de refrigeração de 27,5 TR (~ 96,7 kW). Para o cálculo da carga térmica e dimensionamento do sistema foram considerados os seguintes parâmetros: 32,0 °C para a temperatura do ambiente externo (T_{ext}), e de -2,0 °C no interior do espaço refrigerado (temperatura da câmara T_{int}). O refrigerante utilizado foi o HCFC-22. A Fig. 1(a) apresenta o sistema idealizado, com os seus principais componentes, e a Fig. 1(b) a representação esquemática das grandezas obtidas nesse mesmo sistema.

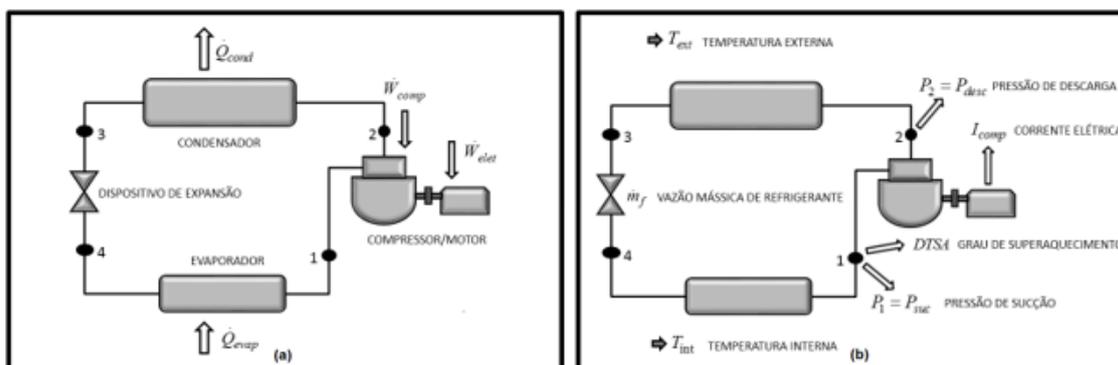


Figura 1. Representação esquemática do sistema de refrigeração (a) e das grandezas obtidas nesse mesmo sistema (b).

Os parâmetros de operação dos componentes do sistema de refrigeração foram obtidos a partir de dados dos fabricantes destes componentes:

- Volume deslocado pelo compressor;
- Eficiência volumétrica do compressor, em função da relação de pressão;
- Capacidades por diferença unitária de temperatura do condensador e do evaporador em função da vazão de ar dos ventiladores;
- Vazão mássica máxima fornecida pelo dispositivo de expansão (válvula de expansão termostática).

As seguintes considerações foram utilizadas para o desenvolvimento do modelo:

- O sistema de refrigeração opera em regime permanente;
- “Perdas de calor” são desprezadas (exceto no compressor);
- Variações de energia cinética e potencial são desprezadas.

A aplicação da 1ª Lei da Termodinâmica ao volume de controle que compreende o evaporador possibilita o cálculo da capacidade de refrigeração do sistema, \dot{Q}_{evap} , dado pela Eq. (1).

$$\dot{Q}_{evap} = \dot{m}_f \cdot (h_1 - h_4) \quad (1)$$

Do lado externo, emprega-se o modelo de Kan e Zubair (1999), dado pela Eq. (2).

$$\dot{Q}_{evap} = C_{evap} \cdot (T_{AEE} - T_{evap}) \quad (2)$$

Em que:

C_{evap} : capacidade por diferença unitária de temperatura;

T_{AEE} : temperatura do ar na entrada do evaporador;

T_{evap} : temperatura de evaporação.

A potência de compressão, $\dot{W}_{12} = \dot{W}_{comp}$, é dada pela Eq. (3).

$$\dot{W}_{12} = \dot{W}_{comp} = \dot{m}_f \cdot (h_2 - h_1) \quad (3)$$

Para o cálculo das eficiências volumétrica η_{vol} , Eq. (04) e isentrópica η_{isent} , Eq. (05), realizou-se um procedimento de regressão linear utilizando dados de catálogo do fabricante do compressor, tomando-se como variável independente a relação de pressão RP (Venturini et al., 1999).

$$\eta_{vol} = a \cdot RP^2 + b \cdot RP + c \quad (4)$$

$$\eta_{isent} = d \cdot RP^2 + e \cdot RP + f \quad (5)$$

A relação de pressão RP é dada pela razão das pressões de condensação, P_{cond} , e evaporação, P_{evap} , Eq. (6).

$$RP = \frac{P_{cond}}{P_{evap}} \quad (6)$$

Com o volume deslocado pelo compressor, \dot{V}_{dest} , obtido a partir dos dados de catálogo do fabricante, juntamente como volume específico do refrigerante na sucção desse componente, v_s , a vazão mássica de refrigerante pode ser calculada segundo Venturini et al. (1999), pela Eq (7).

$$\dot{m}_f = \frac{\dot{V}_{dest} \cdot \eta_{vol}}{v_s} \quad (7)$$

Utilizando a eficiência global (η_{global}) que é composta pelas eficiências mecânica (η_{mec}) e isentrópica (η_{isent}) e a eficiência elétrica (η_{elet}) do motor elétrico de acionamento, é possível determinar a potência elétrica consumida pelo compressor (Richardson et al, 2002.) pela Eq. (8).

$$\dot{W}_{elet} = \frac{\dot{W}_{comp}}{\eta_{global} \cdot \eta_{elet}} \quad (8)$$

Em posse da tensão elétrica (U) e do fator de potência (FP), pode-se calcular a corrente elétrica consumida pelo motor elétrico (I_{comp}) através da Eq. (9).

$$I_{comp} = \frac{\dot{W}_{elet}}{\sqrt{3} \cdot U \cdot FP} \quad (9)$$

A aplicação da 1ª Lei da Termodinâmica ao volume de controle que compreende o condensador possibilita o cálculo da taxa de rejeição de calor, \dot{Q}_{cond} , dado pela Eq. (10).

$$\dot{Q}_{cond} = \dot{m}_f \cdot (h_2 - h_3) \quad (10)$$

Do lado externo, emprega-se o modelo de Kan e Zubair (1999), dado pela Eq. (11).

$$\dot{Q}_{cond} = C_{cond} \cdot (T_{cond} - T_{AEC}) \quad (11)$$

Em que:

C_{cond} : capacidade por diferença unitária de temperatura;

T_{AEC} : temperatura do ar na entrada do condensador (em geral, é igual à temperatura

ambiente);

T_{cond} : temperatura de condensação.

A aplicação da 1ª Lei para o dispositivo de expansão resulta na Eq. (12).

$$h_3 = h_4 \quad (12)$$

O dispositivo de expansão utilizado no sistema de refrigeração em análise foi uma válvula de expansão termostática. A partir de dados fornecidos pelo fabricante, pode-se determinar o coeficiente característico da válvula (Ka) em função da temperatura de evaporação, como mostrado na Eq. (13). Esse coeficiente característico corresponde ao produto do coeficiente de descarga e a área do orifício da válvula (Koury et., 2001). Através da Eq. (14), é possível determinar a vazão máxima de refrigerante fornecida pela válvula ($\dot{m}_{f \max}$). O coeficiente característico da válvula e a vazão máxima de refrigerante, em conjunto com a Eq. (15), podem ser usados para simular o funcionamento da válvula em qualquer outra condição operacional, determinando assim o grau de superaquecimento, $DTSA$, segundo Yassuda et al. (1983).

$$Ka = g + h \cdot T_{evap} - i \cdot T_{evap}^2 \quad (13)$$

$$Ka = \frac{\dot{m}_{f \max}}{\sqrt{2 \cdot \rho_3 \cdot (P_{cond} - P_{evap})}} \quad (14)$$

$$DTSA = \left(\frac{\dot{m}_{f \max}}{\dot{m}_f} \right) DTSA_{OS} + DTSA_{SS} \quad (15)$$

Em que:

ρ_3 : massa específica do refrigerante na entrada da válvula;

$DTSA$: superaquecimento;

$DTSA_{OS}$: superaquecimento dinâmico;

$DTSA_{SS}$: superaquecimento estático.

A solução numérica do conjunto de equações não-lineares que compõem o modelo matemático para o sistema de refrigeração permitem a obtenção do comportamento do mesmo para diferentes condições de temperatura ambiente e do ar no interior da câmara

de refrigeração. O *software Scilab* foi utilizado para solução do sistema de equações, junto ao método da bisseção para a convergência das temperaturas de evaporação, T_{evap} , e condensação, T_{cond} e dos graus de superaquecimento, $DTSA$, e sub-resfriamento, $DTSR$.

O presente trabalho tem foco no diagnóstico termodinâmico de sistemas de refrigeração por compressão de vapor utilizando modelos e técnicas de inteligência computacional. A partir do modelo matemático computacional apresentado, a presença de falhas de maneira individual em cada componente será representada por:

- Redução da capacidade por diferença unitária de temperatura C dos trocadores de calor (Condensador, C_{cond} e Evaporador C_{evap}). O objetivo é simular a presença de incrustações no condensador e formação de gelo no evaporador, ambos na superfície externa desses componentes, reduzindo assim a área de transferência de calor;
- Redução da eficiência isentrópica do compressor (η_{iso} , rendimento isentrópico). A ineficiência na compressão simula, por exemplo, uma maior dissipação de calor a partir dos cilindros durante o processo de compressão;
- Redução no coeficiente característico da válvula utilizada como dispositivo de expansão (Ka coeficiente característico da válvula). A ineficiência na válvula simula, por exemplo, a obstrução no escoamento do fluido refrigerante através da mesma.

As degradações apresentadas anteriormente, estão relacionadas a capacidades do compressor, condensador, evaporador e dispositivo de expansão. O comportamento dessas degradações de maneira individual, será avaliado através da medição das seguintes grandezas do sistema de refrigeração, representadas esquematicamente na Fig. 1(b):

- Temperatura do ambiente externo (T_{ext});
- Temperatura do espaço refrigerado ou da câmara (T_{int});
- Corrente elétrica consumida pelo motor de acionamento compressor (I_{comp});
- Pressão na descarga do compressor ($P_2 = P_{desc}$);
- Pressão de sucção do compressor ($P_1 = P_{suc}$);
- Vazão mássica de fluido refrigerante (\dot{m}_f);
- Grau de superaquecimento ($DTSA$).

Essas grandezas lidas são utilizadas como dados de entrada para o classificador ELM. Com diversos dados de degradação e de situações de referência é possível treinar

uma ELM para detectar a presença de degradações nos componentes do sistema de refrigeração. O classificador ELM será detalhado na próxima seção.

3 MÁQUINA DE APRENDIZADO EXTREMO OU ELM (*EXTREME LEARNING MACHINE*)

O classificador *Extreme Learning Machine* (ELM) é uma técnica de aprendizado de máquina desenvolvida para o treinamento de redes neurais *feedforward* que possuam somente uma camada escondida (Huang et al., 2006). Para redes com essa topologia, os parâmetros da camada escondida podem ser definidos de forma aleatória, restando somente os pesos da camada de saída para serem determinados durante o treinamento, onde tais pesos podem ser obtidos de maneira analítica, com a solução de um sistema de equações lineares (Horta, 2015). A topologia do classificador ELM é apresentada na Fig. 2(a). A Fig. 2(b) apresenta uma topologia particularizada para o problema de diagnóstico termodinâmico do sistema de refrigeração.

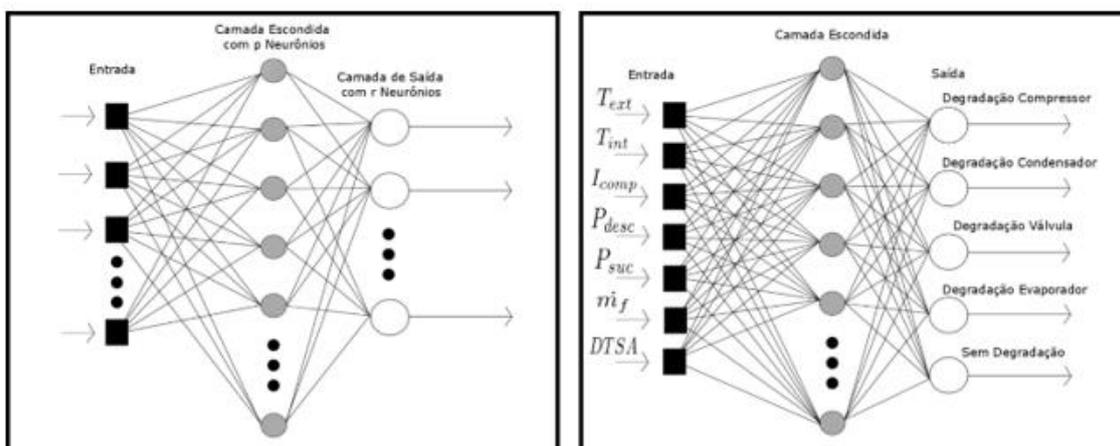


Figura 2. Topologia das ELMs (a) e topologia particularizada para o diagnóstico termodinâmico (b).

Tradicionalmente todos os parâmetros de redes neurais são determinados, em geral, pela retropropagação do erro de treinamento através das camadas da rede (Barcelos et al., 2019). Desta forma, para a determinação de todos os parâmetros são exigidas diversas iterações tornando o processo de aprendizagem mais lento e conseqüentemente o custo computacional mais elevado.

Dentre as características das ELM's tem-se que a determinação dos parâmetros da camada escondida é realizada de forma aleatória, e que os pesos da camada de saída são obtidos diretamente utilizando o método da pseudoinversa, sem a necessidade de iterações (Horta, 2015).

A matriz de entrada X possui “ N ” linhas e “ n ” colunas, onde “ N ” é o número de padrões e “ n ” é a dimensão do espaço de entrada, dada pela Eq. (16).

$$X = \begin{bmatrix} X_1^T \\ \vdots \\ X_N^T \end{bmatrix} = \begin{bmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{N1} & \cdots & x_{Nn} \end{bmatrix} \quad (16)$$

A matriz X é então propagada em um rede *feedforward* com única camada escondida com “ p ” neurônios e função de ativação $g(x)$. Uma vez que os parâmetros da camada escondida, pesos “ w ” e bias “ b ”, são definidos aleatoriamente pode ser calculada a matriz H , Eq. (17), na saída dos neurônios escondidos.

$$H = \begin{bmatrix} g(w_1 X_1 - b_1) & \cdots & g(w_p X_1 - b_p) \\ \vdots & \ddots & \vdots \\ g(w_1 X_N - b_1) & \cdots & g(w_p X_N - b_p) \end{bmatrix} \quad (17)$$

A saída da rede T pode ser expressa pelo sistema linear da Eq. (18).

$$H\beta = T \quad (18)$$

Assim tem-se β definido na Eq. (19), onde “ r ” é o número de neurônios na camada de saída.

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_p^T \end{bmatrix} = \begin{bmatrix} \beta_{11} & \cdots & \beta_{1r} \\ \vdots & \ddots & \vdots \\ \beta_{p1} & \cdots & \beta_{pr} \end{bmatrix} \quad (19)$$

E ainda T , como apresentado na Eq. (20).

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix} = \begin{bmatrix} t_{11} & \cdots & t_{1r} \\ \vdots & \ddots & \vdots \\ t_{N1} & \cdots & t_{Nr} \end{bmatrix} \quad (20)$$

O processo de treinamento se resume em propagar todos os padrões de treinamento na camada escondida ELM, obtendo-se a matriz H e solucionar o sistema linear resultante. Segundo Huang et al. (2006) a soluções para o sistema linear em que β possui a menor norma e que fornece o menor erro de treinamento e a apresentada pela Eq. (21).

$$\beta = \hat{H}T \quad (21)$$

Nessa equação \hat{H} é a pseudoinversa de Moore-Penrose. Para que \hat{H} seja a pseudoinversa da matriz H devem ser satisfeitas as quatro condições na Eq. (22) de Moore-Penrose (Ruiz Quiroz, 2014).

$$\begin{aligned} (i) \quad & H\hat{H}H = H \\ (ii) \quad & \hat{H}H\hat{H} = \hat{H} \\ (iii) \quad & (H\hat{H})^T = H\hat{H} \\ (iv) \quad & (\hat{H}H)^T = (\hat{H}H) \end{aligned} \quad (22)$$

Após a etapa de treinamento e obtenção de todos os parâmetros da rede w , b e β , a resposta Y a novos padrões de entrada X_{teste} é obtida propagando-se X_{teste} através da camada escondida obtendo-se uma nova matriz H , denominada H_{teste} . Realizando a multiplicação $H_{teste}\beta$ obtém-se um valor de saída para cada neurônio. A resposta Y corresponderá ao índice do neurônio que tiver o maior valor de saída (Huang et al., 2006).

4 RESULTADOS E DISCUSSÃO

Com o objetivo de utilizar o classificador ELM para identificar degradações em um sistema de refrigeração, uma base de dados foi gerada utilizando-se o modelo de refrigeração apresentado neste trabalho. Dessa forma, foram gerados 672 padrões compostos por 7 entradas e 5 classes. As entradas são: Temperatura do ambiente externo (T_{ext}); Temperatura do espaço refrigerado, interna ou da câmara (T_{int}); Corrente elétrica consumida pelo motor de acionamento do compressor (I_{comp}); Pressão na descarga do compressor (P_{desc}); Pressão de sucção do compressor (P_{suc}); Vazão mássica de fluido refrigerante (\dot{m}_f); e Grau de superaquecimento ($D TSA$). Foram simuladas 5 situações, ou seja, classes, ver Tab.1(a).

A matriz de dados foi ordenada de forma aleatória e dividida em 70% para treinamento e 30% para teste. Todos os dados foram normalizados para terem média 0 e desvio padrão 1. Os dados de treinamento foram apresentados para uma ELM com 100 neurônios escondidos. O número de neurônios não precisa ser finamente ajustado, pois segundo Huang et al. (2006) para se ter uma boa classificação basta que esse número seja muito maior que o espaço de entrada e menor ou igual ao número de padrões de

treinamento. Os códigos fonte utilizados estão disponíveis no website do autor (Huang, 2016).

Tabela 1: Classes Envolvidas no Problema (a) e Acurácia do Classificador (b).

(a)		(b)	
Classe	Nº Padrões	Acurácia de Treinamento	Acurácia de Teste
Sistema sem Degradação	168	0,999 +/- 0,001	0,994 +/- 0,007
Degradação no Compressor	126		
Degradação no Condensador	126		
Degradação no Evaporador	126		
Degradação na Válvula.	126		

Com a rede treinada, foram apresentados os dados de teste para verificar a acurácia (percentual de acertos de classificação). Esse procedimento foi repetido 100 vezes sendo coletadas a média e o desvio padrão da acurácia de treinamento e da acurácia de teste, apresentados na Tab.1(b).

Como pode ser observado, o classificador foi capaz de acertar aproximadamente 100% dos dados apresentados para treinamento e para o teste. Isso indica que as classes são bem definidas, tendo pouca superposição entre as mesmas. Os dados obtidos para situações com e sem a presença de degradações foram bastante distintos. Distinção essa referente a caracterização dos mesmos quanto as grandezas lidas no sistema de refrigeração. Esse fato é devido à natureza simplificada do modelo, bem como a forma limitada com que foram modeladas e simuladas as degradações. Em trabalhos futuros almeja-se melhorar os modelos dos principais componentes do sistema de refrigeração, assim como a representação das degradações no mesmo. Além disso pretende-se inserir ruídos nas simulações com o objetivo de aproximar os dados de uma situação mais próxima do real.

5 CONCLUSÃO

Neste trabalho foi apresentado um modelo de um sistema de refrigeração que possibilitou a simulação de situações operacionais com e sem a presença de degradação em seu principais componentes. Com esses dados foi treinado um classificador capaz de identificar através das grandezas obtidas no sistema se o mesmo estava operando em uma situação normal ou na presença de degradação. Entre os sintomas apresentados o classificador foi capaz de isolar o componente degradado. Isso corresponde a primeira etapa de um processo de diagnóstico termodinâmico. Dessa forma o procedimento de

diagnóstico é direcionado para a interpretação das grandezas com o objetivo de identificar a origem da degradação no componente isolado pelo classificador.

O uso dessa ferramenta de inteligência computacional pode auxiliar na manutenção de sistemas de refrigeração, identificando desde pequenos desvios de funcionamento de seus componentes direcionando os reparos, contribuindo no desempenho do sistema em termos da qualidade de sua função e no consumo de energia.

AGRADECIMENTOS

Os autores gostariam de agradecer a FAPEMIG, CAPES, CNPq e a PRPPG da UNIFEI e UFVJM pelo apoio financeiro. Além do agradecimento ao ICT/UFVJM e ao NEST/UNIFEI.

NOMENCLATURA

ELM	<i>Extreme Learning Machine</i>
HCFC	Hidroclorohidrocarboneto
RNAs	Redes neurais artificiais
C	Capacidade por diferença unitária de Temperatura
T	Temperatura
h	Entalpia
P	Pressão
RP	Relação de pressão
DTSA	Grau de superaquecimento
DTSR	Grau de sub-resfriamento
I	Corrente elétrica
Ka	Coefficiente característico da válvula
\dot{W}	Potência
\dot{Q}	Taxa de calor
\dot{m}_f	Vazão mássica
U	Tensão
\dot{V}	Vazão volumétrica
FP	Fator de Potência
v	Volume específico
H	Matriz de dados propagados através da camada escondida
\hat{H}	Pseudoinversa da matriz H

Letras gregas

η	Rendimento
--------	------------

ρ Massa específica

Subscritos

evap evaporação ou evaporador
cond condensação ou condensador
AEE Ar na entrada do evaporador
AEC Ar na entrada do condensador
ext Externo
int Interno
desc Descarga
suc Sucção
comp compressão ou compressor
vol Volumétrico
desl deslocado
isent Isentrópico
mec Mecânico
elet Elétrico
global Global
OS Dinâmico
SS Estático

REFERÊNCIAS

Barcelos, A., F., Dias, E., S., Oliveira, J., C., A., Toshimitsu, H., S., Santos, R., A., 2019 “Ferramenta de detecção de padrões de planicidade utilizando redes neurais” DOI:10.34117/bjdv5n11-068, Brazilian Journal of Development, Curitiba, Vol. 5, n. 10, p. 23615-23626, nov. 2019, ISSN 2525-8761.

Braga, A., D., P.; Carvalho, A., P., D., L., F., D.; 2007 Ludermir, T. B. “Redes Neurais Artificiais: Teoria E Aplicações”. 2ª Edição. Ed. Rio De Janeiro: Ltc- Livros Tecnicos E Cientificos.

Ding, G., 2007. “Recent developments in simulation techniques for vapour-compression refrigeration systems”, International Journal of Refrigeration, Vol.30, pp. 1119-1133.

Horta, E., G., 2015 “Aplicação De Máquinas De Aprendizado Extremo Ao Problema De Aprendizado Ativo”. 87 f. Tese (Doutorado). Escola de Engenharia. Universidade Federal de Minas Gerais. Belo Horizonte. 2015.

Huang, G., B., 2016. “Basic ELM Algorithms”. Available: <http://www.ntu.edu.sg/home/egbhuang/elm_codes.html>.

Huang, G., B.; Zhu, Q., Y.; Siew, C., K., 2006 “Extreme Learning Machine: Theory and Applications”. Neurocomputing, V. 70, P. 489–501.

Khan, J., Zubair,S.,M., 1999 “Design and performance evaluation of reciprocating refrigeration systems”, International Journal of Refrigeration, Vol. 22, pp. 235–243.

Kocyyigit, N., 2015 “Fault and sensor error diagnostic strategies for a vapor compression refrigeration system by using fuzzy inference systems and artificial neural network”, International Journal of Refrigeration, Vol.50, pp. 69-79.

Koury, R., N., N., Machado L., Ismail K., A., R., 2001 “Numerical simulation of a variable speed refrigeration system”, International Journal of Refrigeration, Vol. 24, pp.192-200.

Mendes, T., Horta, E., G., Gonçalves, R., P., Venturini, O., J., Pirani, M., J., Seleção de características em um sistema de refrigeração para identificar degradações em seus componentes. Brazilian Journal of Development, Curitiba, v. 6, n. 10, p. 77918-77932 oct. 2020. ISSN 2525-8761.

Mendes, T., Venturini, O., J., Pirani, M., J., 2012 “Thermodynamic Diagnosis Techniques to Assess the Behavior of Vapour Compression Refrigeration Systems” ENCIT - 14th Brazilian Congress of Thermal Sciences and Engineering, November 18-22 2012, Rio de Janeiro, Brazil.

Mohanraj M, Jayaraj S, Muraleedharan C. Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems—A review. Renewable and Sustainable Energy Reviews 16 (2012) 1340– 1358.

Qiao, H.; Radermacher, R.; Aute, V. A Review for Numerical Simulation of Vapor Compression Systems. International Refrigeration and Air Conditioning Conference at Purdue, West Lafayette, USA, 2010.

Rasmussen, B., P., Shenoy, B., 2012 “Dynamic modeling for vapor compression systems- Part II: Simulation tutorial, HVAC&R Research, Vol.18 (No.5), pp. 956-973.

Ruiz Quiroz, J., 2014 “Métodos De Quadrados Mínimos Totais Regularizados”. Dissertação (Mestrado). Pós-Graduação em Matemática Pura e Aplicada. Universidade Federal de Santa Catarina. Florianópolis.

Venturini, O., J., Almeida, M., S., V.; Silva, E., 1999. “Modelo Computacional Para La Simulacion de Sistemas de Aire Acondicionado Con Termoacumulacion”, Información Tecnológica, La Serena - Chile, Vol. 10, No. 2, pp. 273-278.

Yassuda, H., Touber, S., Machielsen, C., H., M., 1983 “Simulation Model of Vapour Compression Refrigeration System”, ASHARE Transactions, part 2a, pp. 408-425.