

**Seleção de características em um sistema de refrigeração para identificar degradações em seus componentes****Characteristics selection in a refrigeration system to identify degradations in its components**

DOI:10.34117/bjdv6n10-281

Recebimento dos originais:01/10/2020

Aceitação para publicação:14/10/2020

**Tiago Mendes**

Formação acadêmica: 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**

Formação acadêmica: 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

**Ronald de Paiva Gonçalves**

Formação acadêmica: 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: ronaldpaiva07@hotmail.com

**Oswaldo José Venturini**

Formação acadêmica: 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**

Formação acadêmica: 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**

Os sistemas de refrigeração por compressão mecânica de vapor são utilizados para condicionar e armazenar uma extensa categoria de alimentos. Esses sistemas são grandes consumidores de energia, estando sujeitos a inúmeras degradações em seus componentes. Essas degradações podem aumentar significativamente o consumo de energia além de comprometer o funcionamento desses sistemas. O objetivo deste trabalho é verificar a quantidade de grandezas lidas em um sistema de refrigeração que são necessárias para caracterizar uma degradação. Para isso serão gerados dados operacionais com e sem degradações em seus componentes através de um modelo computacional. Esses dados serão utilizados para treinar um classificador que identificará os padrões de operação. Ao final, será estabelecida a quantidade mínima de grandezas a serem lidas para que o classificador identifique a degradação com desempenho adequado.

**Palavras-chave:** Máquinas de aprendizado extremo, sistemas de refrigeração, degradações.

**ABSTRACT**

Mechanical vapor compression refrigeration systems are used to condition and store an extensive category of food. These systems are large consumers of energy, being subject to numerous degradations in their components. These degradations can significantly increase energy consumption and compromise the functioning of these systems. The objective of this work is to verify the quantity of quantities read in a refrigeration system that are necessary to characterize a degradation. For this, operational data will be generated with and without degradation in its components through a computational model. This data will be used to train a classifier that will identify operating patterns. At the end, the minimum quantity of quantities to be read will be established for the classifier to identify the degradation with adequate performance.

**Keywords.** Extreme learning machines, cooling systems, degradations.

**1 INTRODUÇÃO**

Sistemas de refrigeração representam uma parcela significativa do consumo de energia no setor comercial e doméstico. Nos países desenvolvidos os sistemas de refrigeração são responsáveis por quase 30% do consumo total de energia [2]. Esse consumo pode aumentar com a presença de degradações em seus componentes.

O monitoramento de sistemas de refrigeração é motivado pela necessidade de se reduzir o consumo de energia [1]. Assim, a detecção e o diagnóstico de degradações nos componentes desses sistemas se tornam necessárias em seu monitoramento.

Em [8] alguns classificadores baseados em inteligência computacional foram testados para identificação de degradações nos componentes de um sistema de refrigeração. Os dados operacionais foram obtidos através de um modelo computacional do sistema de refrigeração. O problema de classificação foi caracterizado como desbalanceado devido à presença de uma classe majoritária. O número de padrões para condição com degradação era muito superior ao da condição

sem degradação. A classificação se baseava na distinção entre condições com e sem degradação, sem fazer referência em qual componente do sistema a degradação se encontrava.

Um modelo computacional para obtenção de dados operacionais de um sistema de refrigeração também foi desenvolvido em [7]. O mesmo foi capaz de gerar dados de funcionamento com e sem a presença de degradações nos seus componentes. Esses dados foram testados em um classificador ELM (*Extreme Learning Machine*), avaliando a sua performance em diagnosticar o estado do sistema de refrigeração. Dentre os sintomas apresentados o classificador foi capaz de isolar o componente degradado. Segundo os autores, essa etapa corresponde à primeira fase de um processo de diagnóstico termodinâmico. Através do isolamento do componente degradado o diagnóstico é direcionado para a interpretação das grandezas lidas no sistema. O objetivo dessa interpretação é de identificar a origem da degradação no componente isolado pelo classificador.

Com isso, através da modelagem computacional de um sistema de refrigeração, dados operacionais que representem seu funcionamento real podem ser obtidos. Esses modelos podem ser construídos através de informações obtidas nos catálogos dos fabricantes dos componentes desses sistemas. Através dos modelos as degradações podem ser simuladas nesses componentes. Essas informações do sistema de refrigeração serão potenciais sensores que auxiliaram no monitoramento dessas instalações.

## **2 MODELO MATEMÁTICO E COMPUTACIONAL PARA O SISTEMA DE REFRIGERAÇÃO**

O funcionamento de um sistema de refrigeração depende do comportamento de seus componentes individuais, que são: compressor, condensador, dispositivo de expansão e evaporador. Cada um desses componentes deve estar em equilíbrio um com os outros, para o perfeito funcionamento do sistema como um todo [9].

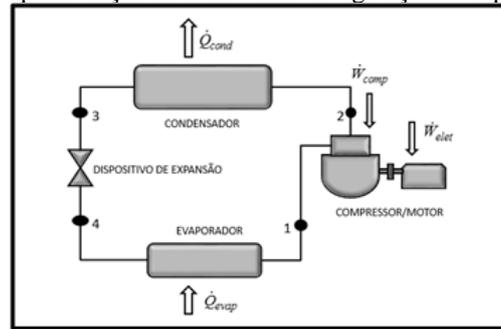
Neste trabalho, a análise será conduzida através do desenvolvimento de um estudo de caso. Assim, foi considerada uma planta com capacidade de refrigeração de 27,5 [TR] (~ 96,7 [kW]). Para o cálculo da carga térmica e dimensionamento do sistema foram considerados os seguintes parâmetros: 32,0 [°C] para a temperatura do ambiente externo,  $T_{ext}$ , e de -2,0 [°C] no interior do espaço refrigerado, temperatura interna ou da câmara,  $T_{int}$ . O refrigerante utilizado foi o HCFC-22. A Figura 1 mostra o sistema idealizado, com os seus principais componentes.

A simulação do sistema de refrigeração é obtida através da solução de um conjunto de equações não-lineares que regem a operação do sistema. Com esse modelo pode-se obter o

comportamento do sistema para as várias condições de temperatura do ambiente externo e do espaço refrigerado.

As informações necessárias para a confecção do conjunto de equações mencionadas anteriormente (parâmetros de projeto), foram obtidas a partir dos dados de catálogos dos fabricantes de cada um dos componentes. Os parâmetros são os seguintes:

Fig. 1. - Representação do sistema de refrigeração. Adaptado de [7].



- Deslocamento volumétrico do compressor,  $\dot{V}_{desl}$  ;
- Tensão elétrica nominal do motor do compressor,  $U$  ;
- Fator de potência do motor do compressor,  $FP$  ;
- Eficiência volumétrica do compressor,  $\eta_{vol}$ , em função da relação de pressão,  $RP$ ;
- Capacidade por diferença unitária de temperatura para o condensador,  $C_{cond}$ , e evaporador,  $C_{evp}$ , ambas em função da vazão de ar dos ventiladores;
- Coeficiente característico da válvula termostática,  $Ka$ , utilizada como dispositivo de expansão;

Os parâmetros mencionados anteriormente foram utilizados para caracterizar cada componente do sistema, com o objetivo de simular o comportamento dos mesmos trabalhando em conjunto. O sistema de equações não-lineares, obtido através da modelagem matemática e do balanço de Primeira Lei da Termodinâmica do compressor, condensador, dispositivo de expansão e evaporador foi resolvido com o auxílio do *software* Scilab. Sendo utilizado o método da bissecção para a convergência dos resultados dessas equações para as temperaturas de evaporação,  $T_{evp}$ , condensação,  $T_{cond}$ , grau de superaquecimento,  $DTSA$  e sub-resfriamento,  $DTSR$ . Para cada condição considerada, a solução do sistema formado pelas equações governantes de cada componente, corresponde a uma condição de equilíbrio do sistema, isto é, corresponde a um ponto onde o sistema pode ser considerado operando em regime permanente, ou seja, considera-se operação em regime quase-estático [9].

A análise de Primeira Lei requer uma formulação matemática baseada em princípios da termodinâmica e da conservação de massa, além do estabelecimento de condições de contorno. As seguintes considerações foram adotadas para a análise em questão:

- Perdas de calor, exceto no compressor (compressão não isentrópica), são negligenciadas;
- Variações de energia cinética e potencial são negligenciadas;
- Perdas de carga nas tubulações, condensador e evaporador são negligenciadas.

Os subscritos em forma de números se relacionam aos pontos mostrados na Fig.1. A partir das considerações mencionadas anteriormente, em conjunto com o princípio da conservação de massa e com a Primeira Lei da Termodinâmica, aplicados ao volume de controle formado pelo evaporador, obtém-se a capacidade de refrigeração do sistema,  $\dot{Q}_{evap}$ , representada pela Eq. (1).

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

O evaporador é modelado de acordo com o apresentado por [5]. A modelagem é baseada na definição da sua capacidade de transferência de calor por diferença unitária de temperatura, Eq. (2). Esta metodologia é satisfatória para representar este componente em aplicações de engenharia, uma vez que o coeficiente global não é normalmente fornecido pelos fabricantes desses equipamentos.

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

onde:

$C_{evap}$ : 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).

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

Segundo [10], a eficiência volumétrica,  $\eta_{vol}$ , e isentrópica,  $\eta_{isent}$ , podem ser calculadas em função da relação de pressão,  $R_P$  na Eq. (4). A eficiência volumétrica do compressor é dada pela Eq. (5) cujos coeficientes são determinados através de um processo de regressão utilizando os dados de catálogo do fabricante do componente. A eficiência isentrópica é dada pela Eq. (6), obtida de curvas típicas de compressores utilizados em refrigeração.

$$RP = \frac{P_{cond}}{P_{evap}} \quad (4)$$

$$\eta_{vol} = a \cdot RP^2 + b \cdot RP + c \quad (5)$$

$$\eta_{isent} = d \cdot RP^2 + e \cdot RP + f \quad (6)$$

Onde:

$P_{cond}$  : pressão de condensação;

$P_{evap}$  : pressão de evaporação.

Com o deslocamento volumétrico pelo compressor ( $\dot{V}_{dest}$ ) obtido a partir dos dados de catálogo do fabricante, juntamente com o volume específico do refrigerante na sucção desse componente ( $v_s$ ), a vazão mássica de refrigerante ( $\dot{m}_f$ ) pode ser calculada pela Eq. (7) [10].

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

Utilizando a eficiência global ( $\eta_{global}$ ) que é composta pelas eficiências mecânica ( $\eta_{mec}$ ) e isentrópica ( $\eta_{isent}$ ) e a eficiência elétrica ( $\eta_{elet}$ ) do motor elétrico de acionamento, é possível determinar a potência elétrica consumida pelo compressor 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 ( $FP$ ) obtidos através do catálogo do compressor, pode-se calcular a corrente elétrica consumida pelo motor elétrico do mesmo ( $I_{comp}$ ) através da Eq. (9).

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

Para o condensador, aplicando os princípios de conservação de massa e a Primeira Lei da Termodinâmica, é possível determinar a sua taxa de rejeição de calor,  $\dot{Q}_{cond}$ , como apresentado na Eq. (10).

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

Utilizando o mesmo método adotado para modelar o evaporador [5], também é possível determinar a taxa de rejeição de calor no condensador como uma função de suas temperaturas de funcionamento, como apresentado na Eq. (11).

$$\dot{Q}_{cond} = C_{cond} \cdot (T_{cond} - T_{AEC}) \quad (1)$$

onde:

$C_{cond}$  : 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.

O tempo de residência do fluido refrigerante no interior do condensador estabelece o grau de sub-resfriamento,  $DTSR$ . Assim, o mesmo é modelado em função da diferença entre a temperatura do ambiente externo,  $T_{ext}$  e a temperatura de condensação,  $T_{cond}$ , como apresentado na Eq. (12).

$$\begin{aligned} (T_{cond} - T_{ext}) < 4 &\Rightarrow DTSR = 0 \\ 4 \leq (T_{cond} - T_{ext}) \leq 12 &\Rightarrow DTSR = (T_{cond} - T_{ext}) - 4 \\ (T_{cond} - T_{ext}) > 12 &\Rightarrow DTSR = 8 \end{aligned} \quad (2)$$

O processo de expansão na válvula pode ser considerado isentálpico, o que também pode ser verificado utilizando os princípios de conservação da massa e da Primeira Lei da Termodinâmica, resultando na Eq. (13).

$$h_3 = h_4 \quad (3)$$

O dispositivo de expansão utilizado no sistema de refrigeração em análise foi uma válvula de expansão termostática de equalização externa. 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. (14). Os coeficientes dessa equação são determinados através de um processo de regressão utilizando os dados de catálogo do fabricante do componente. Esse coeficiente equivale ao produto entre o coeficiente de descarga e o diâmetro do orifício da válvula, valores esses na

maioria das vezes não fornecido pelos catálogos do fabricante desse equipamento [6]. Através da Eq. (15), é possível determinar a vazão máxima de refrigerante fornecida pela válvula,  $\dot{m}_{f \max}$ . O coeficiente característico e a vazão máxima de refrigerante, em conjunto com a Eq. (16), podem ser utilizados para simular o funcionamento da válvula em qualquer outra condição operacional, obtendo assim o grau de superaquecimento,  $DTSA$  [11].

$$Ka = g + h \cdot T_{\text{evap}} - i \cdot T_{\text{evap}}^2 \quad (4)$$

$$Ka = \frac{\dot{m}_{f \max}}{\sqrt{2 \cdot \rho_3 \cdot (P_{\text{cond}} - P_{\text{evap}})}} \quad (5)$$

$$DTSA = \left( \frac{\dot{m}_{f \max}}{\dot{m}_f} \right) DTSA_{OS} + DTSA_{SS} \quad (6)$$

onde:

$\rho_3$ : massa específica do refrigerante na entrada da válvula;

$DTSA$ : grau de superaquecimento;

$DTSA_{OS}$ : superaquecimento dinâmico;

$DTSA_{SS}$ : superaquecimento estático.

A Equação (17) apresenta o coeficiente de performance do sistema de refrigeração,  $COP$ .

$$COP = \frac{\dot{Q}_{\text{evap}}}{\dot{W}_{\text{comp}}} \quad (7)$$

O presente trabalho tem foco na detecção e diagnóstico de degradações nos sistemas de refrigeração de vapor utilizando modelos e técnicas de inteligência computacional. A partir do modelo matemático computacional apresentado, a presença de degradações de maneira individual em cada componente será representada por:

- Redução da capacidade por diferença unitária de temperatura  $C$  dos trocadores de calor (Condensador,  $C_{\text{cond}}$  e Evaporador,  $C_{\text{evap}}$ ). 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,  $\eta_{iso}$ . A ineficiência na compressão simula, por exemplo, uma maior dissipação de calor a partir dos cilindros durante o processo de compressão do fluido refrigerante;
- Redução no coeficiente característico da válvula termostática ( $Ka$ ) utilizada como dispositivo de expansão. A ineficiência na válvula simula, por exemplo, a obstrução no escoamento do fluido refrigerante através desse componente.

As degradações apresentadas anteriormente, estão relacionadas às capacidades do compressor, condensador, evaporador e dispositivo de expansão. O comportamento dessas degradações de maneira individual é observado através da combinação da leitura das seguintes grandezas do sistema de refrigeração:

- Temperatura do ambiente externo ( $T_{ext}$ );
- Temperatura do espaço refrigerado, interna 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 na sucção do compressor ( $P_1 = P_{suc}$ );
- Vazão mássica de fluido refrigerante ( $\dot{m}_f$ );
- Grau de superaquecimento ( $D TSA$ );
- Grau de subresfriamento ( $D T SR$ )
- Rotação do compressor ( $N$ )

Combinações dessas grandezas lidas são utilizadas como dados de entrada para um classificador. Com diversos dados de degradação e de situações de referência é possível treinar um classificador para detectar a presença de degradações nos componentes do sistema de refrigeração. Essas condições operacionais de referência e com degradações irão compor a camada de saída do classificador. O classificador utilizado neste trabalho será detalhado na próxima seção.

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

A técnica de máquinas de aprendizado extremo (ELM), foi desenvolvida para o treinamento de redes neurais artificiais. Para redes como a ELM, os parâmetros de camada escondida podem ser definidos aleatoriamente, restando apenas os pesos da camada de saída para serem determinados durante o treinamento. Estes pesos por sua vez podem ser obtidos de maneira analítica, como solução de um sistema de equações lineares [12]. A ELM é normalmente utilizada em duas camadas, tendo as seguintes características [3]:

- O número de neurônios escondidos é grande;
- O treinamento dos pesos da camada escondida e da camada de saída é feito separadamente;
- Os pesos da camada escondida são ajustados aleatoriamente;
- Os pesos da camada de saída não são ajustados interativamente, mas obtidos diretamente utilizando o método de pseudoinversa, sem necessidade de interações.

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. (18).

$$X = \begin{bmatrix} X_1^T \\ \vdots \\ X_N^T \end{bmatrix} = \begin{bmatrix} x_{11} & \cdots & x_{1r} \\ \vdots & \ddots & \vdots \\ x_{N1} & \cdots & x_{Nr} \end{bmatrix} \quad (8)$$

A matriz  $X$  é então propagada em uma rede *feedforward* com uma 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. (19), na saída dos neurônios escondidos. A saída da rede  $T$ , pode ser expressa pelo sistema linear da Eq. (20).

$$H = \begin{bmatrix} g(w_1 X_1 - b_1) & \cdots & g(w_p X_1 - b_p) \\ \vdots & \ddots & \vdots \\ g(w_1 X_N - b_1) & \cdots & g(w_p X_N - b_p) \end{bmatrix} \quad (9)$$

$$H\beta = T \quad (20)$$

Assim tem-se  $\beta$  definido na Eq. (21), onde “ $r$ ” é o número de neurônios na camada de saída.

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_p^T \end{bmatrix} = \begin{bmatrix} \beta_{11} & \cdots & \beta_{1r} \\ \vdots & \ddots & \vdots \\ \beta_{p1} & \cdots & \beta_{pr} \end{bmatrix} \quad (10)$$

E ainda  $T$ , como apresentado na Eq. (22).

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

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 [4] a solução para o sistema linear em que  $\beta$  que possui a menor norma e que fornece o menor erro de treinamento é a apresentada pela Eq. (23). Nessa equação  $\hat{H}$  é a pseudoinversa de Moore-Penrose.

$$\beta = \hat{H}T \quad (12)$$

Após a etapa de treinamento e obtenção de todos os parâmetros da rede  $w$ ,  $b$  e  $\beta$ , 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  $H_{teste} \cdot \beta$  obtém-se um valor de saída para cada neurônio. A resposta  $Y$  corresponderá ao índice do neurônio que tiver o maior valor de ativação [4].

#### 4 RESULTADOS E DISCUSSÃO

Cada degradação gera um efeito físico nos componentes do sistema. Para a degradação no compressor ocorre aumento da potência de compressão, de acordo com a Eq. (3). A degradação na válvula resulta em uma redução da vazão mássica de fluido refrigerante, de acordo com a Eq. (15), ocasionando uma redução da pressão de evaporação, que resulta em aumento da potência de compressão. As degradações no condensador e evaporador resultam em aumento da temperatura de condensação e redução na de evaporação, conforme Eq. (11) e Eq. (2), respectivamente. Portanto, esses efeitos resultam em aumento da potência de compressão para o sistema. Assim para uma mesma capacidade de refrigeração ocorre a redução no coeficiente de performance ( $COP$ ) para todas essas modalidades de degradações.

Com o objetivo de avaliar as potenciais grandezas a serem lidas em um sistema de refrigeração, combinações das mesmas foram geradas. O classificador ELM foi utilizado para identificar as degradações para conjuntos dessas combinações gerando assim um experimento. Para cada um desses experimentos a matriz de dados foi ordenada de forma aleatória e dividida em 2/3 para treinamento e 1/3 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 [4] 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.

A Tabela 1 apresenta a quantidade de possibilidades para cada combinação utilizada. Na Tabela 2 são apresentados exemplos dessas possibilidades, que são as que obtiveram melhor resultado dentro da sua combinação entre as grandezas mencionadas ao final da seção 2. Essas combinações foram as que obtiveram maior desempenho ao se utilizar o classificador para identificação das degradações no sistema de refrigeração. A tabela 3 apresenta os resultados para a acurácia de teste para as combinações da Tabela 1.

Tabela 1. Possibilidades de combinações, entre os dados analisados

Nº da Combinação	Combinações Possíveis
Combinação 1	7
Combinação 2	21
Combinação 3	35
Combinação 4	37
Combinação 5	21
Combinação 6	7
Combinação 7	1

Tabela 2. Combinações de grandezas obtidas para identificação das degradações

Nº da Combinação	$T_{ext}$	$T_{int}$	$I_{comp}$	$P_1$	$P_2$	$m_f$	D TSA	D T SR	N
Combinação 1	X	X					X		
Combinação 2	X	X	X				X		
Combinação 3	X	X	X	X			X		
Combinação 4	X	X	X	X	X		X		
Combinação 5	X	X	X	X	X	X	X		
Combinação 6	X	X	X	X	X	X	X	X	
Combinação 7	X	X	X	X	X	X	X	X	X

Tabela 3. Acurácia do classificador para as combinações de grandezas.

Nº da Combinação	Acurácia
Combinação 1	0,833-/+0,005
Combinação 2	0,975-/+0,003
Combinação 3	0,986-/+0,002
Combinação 4	0,994-/+0,001
Combinação 5	0,994-/+0,001
Combinação 6	0,992-/+0,002
Combinação 7	0,613-/+0,093

Os parâmetros, Temperatura do ambiente externo ( $T_{ext}$ ), Temperatura do espaço refrigerado, interna ou da câmara ( $T_{int}$ ), são fixos nas combinações, ou seja, sempre estarão presentes nas possibilidades avaliadas, por serem parâmetros básicos e fundamentais para a caracterização do ciclo de refrigeração.

O experimento foi realizado partindo das 9 grandezas e variando de forma decrescente as combinações. Inicialmente, foi avaliado o desempenho da rede com as 9 grandezas, logo após avaliou-se com 8 delas, de forma a abranger todas as possibilidades de 8 combinações dentre as 9 iniciais. Da mesma forma foi realizado com 7 entradas, e assim por diante até que restassem apenas 2 entradas. A partir desse experimento foi possível também avaliar dentre as 9 grandezas iniciais quais são mais influentes no resultado da rede.

Esses experimentos identificam o desempenho do classificador em detectar a presença de degradação desde pequenas variações nas capacidades dos componentes. Essa detecção na fase inicial da deterioração do componente é de muita importância para o procedimento de diagnóstico

e detecção de degradações. Quando se identifica uma degradação em sua fase inicial as ações de equipes de manutenção podem ser melhor planejadas, além de garantir o desempenho do sistema de refrigeração. O planejamento das atividades de manutenção reduz o tempo de inatividade da instalação. Por sua vez, o melhor desempenho é traduzido em economia de energia e melhor qualidade em seu funcionamento.

Com base na tabela 3, percebe-se que as combinações que apresentaram melhor acurácia foram a 4 e 5 com um empate entre elas. Porém, torna-se mais viável considerar a combinação 4 como o melhor grupo de característica para identificar as falhas no sistema. A justificativa para adotar 4 combinações melhor que 5 combinações é a quantidade de características em cada grupo. O número reduzido de características em 4 combinações implica em redução no custo de instalação e operação do sistema. Adicionar uma quinta característica seria redundante, e não melhoraria a eficácia do classificador.

As entradas da combinação escolhida como a que melhor define o sistema (4) são:

- Temperatura do ambiente externo ( $T_{ext}$ );
- Temperatura do espaço refrigerado, interna 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 na sucção do compressor ( $P_1 = P_{suc}$ );
- Grau de superaquecimento ( $D TSA$ );

Uma vantagem da seleção destas grandezas é a boa classificação do sistema, e a redução na quantidade de sensores a serem instalados no sistema de refrigeração, conseqüentemente reduzindo o custo de implantação e manutenção.

## 5 CONCLUSÃO

Os sistemas de refrigeração estão sujeitos os mais diversos tipos de falhas, que podem comprometer o seu funcionamento. A detecção dessas falhas oferece vários benefícios como a otimização de manutenções, economia de energia e redução no custo de instalação.

Neste trabalho se verificou que monitorar apenas 6 características do sistema de refrigeração é suficiente para detectar a ocorrência de degradações nos componentes. A detecção foi realizada utilizando máquinas de aprendizado extremo (ELM), tendo uma acurácia de 99%.

Assim as diferentes formas dos dados foram apresentadas à técnica avaliada (ELM). Os dados de entrada foram divididos aleatoriamente em um grupo de treinamento e outro de teste e

feito o procedimento de treinamento e teste cem vezes, assim colhendo o desempenho obtido dos quais são avaliados a acurácia para cada combinação.

### 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.

### REFERÊNCIAS

1. Ashrae Handbook, Refrigeration. SI Edition, 2010. 758 pg.
2. Buzelin, L., O., S., Amico, S., C., Vargas, J., V., C., Parise, J., A., R., Experimental development of an intelligent refrigeration system. *International Journal of Refrigeration*, Vol. 28, pp.165-175, 2005.
3. 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.
4. Huang, G., B.; Zhu, Q., Y.; Siew, C., K., 2006 “Extreme Learning Machine: Theory And Applications”. *Neurocomputing*, V. 70, P. 489–501.
5. Khan, J., Zubair, S., M., 1999 “Design and performance evaluation of reciprocating refrigeration systems”, *International Journal of Refrigeration*, Vol. 22, pp. 235–243.
6. 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.
7. Mendes, T., Horta, E., G., Pereira, J., F., Guzella, M., S., Venturini, O., J., Pirani, M., J. 2016. Diagnóstico Termodinâmico em um Sistema de Refrigeração por Compressão Mecânica de Vapor Utilizando Modelos e Técnicas de Inteligência Computacionais. SIMMEC XII Simpósio de Mecânica Computacional 23 a 25 de maio (2016), Diamantina, MG, Brasil.
8. Pereira, J., F., Horta, E., G., Mendes, T., 2015. Detecção de Falhas em Um Sistema de Refrigeração por Compressão de Vapor. CBIC (Brazilian) XII Congress on Computational Intelligence. Outubro, 13-16 (2015). Universidade Tecnológica Federal do Paraná - Curitiba-Paraná, Brasil.
9. 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.
10. Venturini, O., J., Almeida, M., S., V.; Silva, E., 1999. “Modelo Computacional Para La Simulación de Sistemas de Aire Acondicionado Con Termoacumulacion”, *Información Tecnológica*, La Serena - Chile, Vol. 10, No. 2, pp. 273-278.

11. Yassuda, H., Touber, S., Machielsen, C., H., M., 1983 “Simulation Model of Vapour Compression Refrigeration System”, ASHARE Transactions, part 2a, pp. 408-425.
12. 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.