

Detecção de Falhas em Um Sistema de Refrigeração por Compressão de Vapor

Jader Fernandes Pereira
Graduando em Engenharia Mecânica
Instituto de Ciência e Tecnologia
Universidade Federal
dos Vales do Jequitinhonha e Mucuri
Diamantina - Minas Gerais
E-mail: jader.fernandes@ymail.com

Euler Guimarães Horta
Instituto de Ciência e Tecnologia
Universidade Federal
dos Vales do Jequitinhonha e Mucuri
Diamantina - Minas Gerais
E-mail: euler.horta@ict.ufvjm.edu.br

Tiago Mendes
Instituto de Ciência e Tecnologia
Universidade Federal
dos Vales do Jequitinhonha e Mucuri
Diamantina - Minas Gerais
E-mail: tiago.mendes@ict.ufvjm.edu.br

Resumo—A crescente demanda por qualidade, confiabilidade e segurança de processos tem motivado a utilização de técnicas para detecção de falhas em diversas aplicações. Os sistemas de refrigeração estão sujeitos a diversos tipos de falhas que podem acarretar prejuízos, sendo importante detectar essas falhas para que o sistema possa operar sempre com máxima eficiência, propiciando economia de energia e otimização da manutenção. O uso de inteligência computacional para realizar tal tarefa vem se tornando uma boa opção para sua implementação devido a versatilidade e a confiabilidade dos resultados alcançados. Neste trabalho foi modelado um sistema de refrigeração para se obter uma base de dados representativa capaz de refletir o comportamento do sistema na presença de falhas e em bom funcionamento. Foram testados diversos classificadores baseados em inteligência computacional quanto ao seu desempenho em discriminar os diferentes padrões de comportamento do sistema e, dessa forma, definir dentre os classificadores testados qual é a melhor opção para implantação do sistema de detecção de falhas no sistema de refrigeração estudado.

Keywords—*Modelagem Computacional, Sistemas de Refrigeração, Detecção de Falhas, Inteligência Computacional, Problemas de Classes Desbalanceadas*

I. INTRODUÇÃO

Sistemas de refrigeração são utilizados em larga escala em diversos setores da sociedade, tendo papéis importantes nos setores industrial, comercial, doméstico, para transporte e para condicionamento de ar. Nesses diversos setores, esses sistemas têm seu uso relacionado principalmente com a conservação e produção de alimentos e a climatização de ambientes. Os sistemas de refrigeração são grandes consumidores de energia. Segundo [1] em 2004 a refrigeração foi responsável por 33,85% do consumo de energia elétrica em indústrias de alimentos, por exemplo.

A crescente demanda por qualidade, confiabilidade e segurança de processos, tem proporcionado o desenvolvimento de diversas técnicas para detecção de falhas. Elas consistem no monitoramento de um determinado sistema e a indicação de quando esse apresenta algum tipo de falha [2]. A adoção dessas técnicas em sistemas de refrigeração podem trazer diversos benefícios, contribuindo para que o sistema opere sempre com máxima eficiência, o que proporciona economia de energia, além de contribuir para a otimização da manutenção.

Neste trabalho propõe-se o uso de técnicas de inteligência computacional para detecção de falhas em sistemas de refrigeração. Para tal, é necessário um conjunto de dados que representem o comportamento do sistema quando em bom funcionamento e na presença de falhas. O que torna o problema de detecção de falhas um problema de classificação binária. Esses dados foram obtidos através da simulação de um sistema de refrigeração, modelado a partir dos catálogos fornecidos pelos fabricantes dos equipamentos selecionados. Foram obtidas as informações necessárias para determinar o comportamento de cada equipamento em diversas situações, possibilitando a simulação dos mesmos em conjunto através do modelo do sistema.

Devido às diversas falhas as quais os sistemas de refrigeração estão sujeitos, sendo que para o sistema em bom funcionamento é possível somente uma configuração, a detecção de falhas em sistemas de refrigeração é um problema de classes desbalanceadas, ou seja, existe um desbalanceamento no número de exemplos associados a cada uma das classes. Em problemas dessa natureza os classificadores convencionais tendem a favorecer a classe que possui a maior quantidade de padrões (majoritária), durante o processo de treinamento e conseqüentemente na classificação de novos exemplos. Dessa forma, surgiu a necessidade da utilização de técnicas voltadas especificamente para a resolução de problemas dessa natureza, assim como a utilização de uma métrica adequada para avaliação do desempenho dos classificadores.

Neste trabalho foram testadas técnicas de inteligência computacional quanto a sua capacidade de realizar detecção de falhas em um sistema de refrigeração, com o objetivo de avaliar qual deverá possuir o melhor desempenho quando utilizada em um sistema de refrigeração real em operação.

II. SISTEMA DE REFRIGERAÇÃO

A maior parte dos sistemas de refrigeração, tais como refrigeradores domésticos, câmaras frigoríficas e sistemas de ar-condicionado funcionam segundo um ciclo de compressão de vapor. Estes se baseiam no princípio de evaporação a baixas temperaturas conseguidas para alguns fluidos, chamados fluidos refrigerantes, onde é possível através da compressão e expansão, a obtenção de baixas temperaturas e assim a retirada de calor de uma fonte quente [3]. O fluido é responsável

pela troca de calor entre o ambiente refrigerado e o ambiente externo. Sistemas de refrigeração que funcionam segundo um ciclo de compressão de vapor são formados por quatro componentes, sendo estes: dois trocadores de calor (evaporador e condensador), um compressor e um dispositivo de expansão (Figura 1).

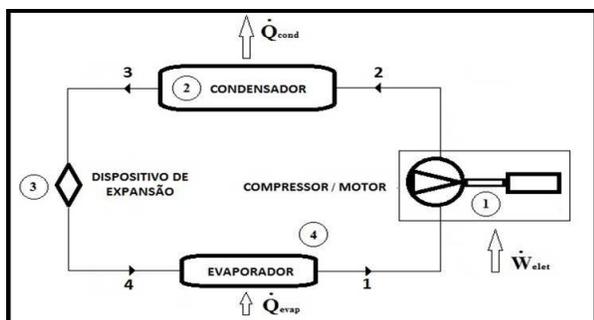


Figura 1. Sistema de Refrigeração

A operação desses sistemas pode ser descrita como um ciclo termodinâmico dividido em quatro etapas, como pode ser visto na Figura 2, onde é mostrado o ciclo teórico que representa uma operação ideal, adiabático e reversível e o ciclo real onde são consideradas as ineficiências características do sistema. Sendo a pressão de vaporização (P_o) e a pressão de condensação (P_c) referentes ao fluido refrigerante.

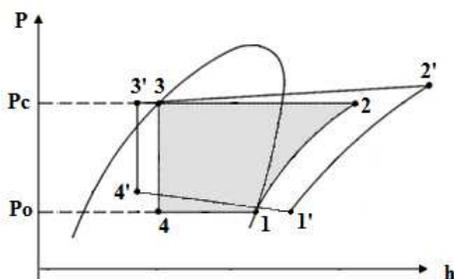


Figura 2. Ciclo Teórico (1,2,3,4) e Ciclo Real (1',2',3',4'). Adaptado de [4]

O ciclo real irá considerar: as perdas de carga no condensador e evaporador; o superaquecimento no compressor, o que garante que não chegue fluido refrigerante no estado líquido na sua entrada; e o sub-resfriamento no dispositivo de expansão para que este opere sempre com o fluido refrigerante no estado líquido [5]. Os componentes de um sistema de refrigeração por compressão de vapor básico são apresentados a seguir.

A. Compressor

É o principal componente de sistemas de refrigeração que funcionam segundo um ciclo de compressão de vapor. O compressor tem a função de elevar a pressão do fluido refrigerante que está inicialmente em um estado de vapor superaquecido (estado 1' na Figura 2) até que atinja a pressão de condensação (estado 2' na Figura 2). O Compressor é também o responsável pelo fluxo do fluido refrigerante pelo sistema [4].

B. Condensador

Responsável por promover a transferência do calor para o meio externo, o condensador receberá o fluido refrigerante no estado de vapor superaquecido (estado 2' na Figura 2), onde o fluido refrigerante será condensado e atingirá o estado de líquido subresfriado (estado 3' na Figura 2), o que garante que o fluido refrigerante esteja totalmente no estado líquido [4].

C. Dispositivo de expansão

O dispositivo de expansão possui a função de provocar uma queda da pressão no fluido refrigerante, ocasionada pela sua expansão e consequente mudança de estado, além de regular a vazão do mesmo para o evaporador. O fluido refrigerante na entrada do dispositivo de expansão estará em estado de líquido comprimido, no seu interior atingirá sua pressão de vaporização, fazendo assim com que o fluido refrigerando seja encontrado na saída do dispositivo como uma mistura líquido-vapor (processo 3' para 4' representado na Figura 2) [5].

D. Evaporador

O fluido refrigerante na entrada do evaporador está no estado de vapor úmido em baixa pressão e temperatura (representado na Figura 2 pelo estado 4'). No seu interior haverá a troca de calor com o ambiente a ser refrigerado através da vaporização do fluido refrigerante de forma que ao final do processo este alcançará o estado de vapor saturado (representado na Figura 2 pelo estado 1') dando início novamente ao ciclo [5]. O evaporador é o responsável pela retirada de calor do ambiente a ser refrigerado/condicionado.

III. BASE DE DADOS

A base de dados utilizada no experimento foi obtida através da simulação do funcionamento de um sistema de refrigeração, onde a partir de dados fornecidos pelos fabricantes dos equipamentos é modelado o funcionamento de cada um dos componentes do sistema, a fim de simular o funcionamento dos mesmos em conjunto.

A. Simulação do Sistema

O comportamento de um sistema de refrigeração depende do comportamento de seus componentes individuais. Cada um desses componentes deve estar em equilíbrio termodinâmico com os outros para o perfeito funcionamento do sistema como um todo [6].

Neste trabalho, a análise será conduzida através de um estudo de caso. Assim, foi considerada uma planta com capacidade de refrigeração de 27,5 [TR] aproximadamente 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, e de -2,0 [°C] no interior do espaço refrigerado (temperatura da câmara). O fluido refrigerante utilizado foi o HCFC-22.

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 ambiente 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:

- Deslocamento volumétrico do compressor
- Eficiência volumétrica do compressor, em função da relação de pressão
- Capacidade por diferença unitária de temperatura para o condensador e evaporador, ambas em função da vazão de ar dos ventiladores
- Vazão mássica máxima fornecida pelo dispositivo de expansão (válvula de expansão termostática)

Os parâmetros mencionados anteriormente foram utilizados para caracterizar cada componente do sistema, com o objetivo de simular o comportamento destes 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*. Foi utilizado o método da bissecção para a convergência dos resultados dessas equações para as temperaturas de vaporização, condensação, superaquecimento e sub-resfriamento. 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 [7].

Desta forma, para todos os componentes foi feita a simulação para duas condições: considerando temperatura ambiente constante em $32^{\circ}C$ e a temperatura da câmara variando de 32 até $-8^{\circ}C$; e considerando a temperatura da câmara constante em $-2^{\circ}C$ e a temperatura ambiente variando de 0 até $40^{\circ}C$.

1) Defeitos nos Trocadores de calor (Evaporador e Condensador): Para simulação de defeitos nesses equipamentos, foi considerada a alteração no fator de troca, a fim de se obter uma simulação de encrustações presentes nos dutos. Além disso foi simulada a parada dos ventiladores responsáveis pela convecção forçada, que por sua vez foi feita alterando a vazão de ar provocada pelos ventiladores.

2) Defeitos no Compressor: Foi feita a alteração do volume deslocado para simulação de um possível problema de queda de rotação, alteração também realizada para a simulação de parada de cilindros do compressor, porém nesse último caso a rotação permanece constante. Outro possível problema está na diminuição do rendimento isoentrópico do compressor, que foi simulado multiplicando os coeficientes da curva de rendimento isoentrópico obtida através de dados fornecidos em catálogo, pelo valor de eficiência a qual se deseja obter os dados. Foi feito também a simulação da diminuição do rendimento volumétrico, onde a exemplo do realizado para simulação da diminuição do rendimento isoentrópico, é utilizado a curva de rendimento obtida através de dados fornecidos em catálogo onde seus coeficientes são multiplicados pelo valor de eficiência a qual se deseja obter os dados.

3) Defeitos no Dispositivo de Expansão: O dispositivo de expansão utilizado foi uma válvula. Os defeitos modelados foram a alteração na pressão da mola e alteração no K_a da válvula. O K_a segundo [5] é dado por:

$$k_a = C_d \cdot A_0 \quad (1)$$

Onde C_d é o coeficiente de descarga do orifício da válvula e A_0 é a área do orifício de passagem do fluido.

Os dois problemas foram simulados a partir da multiplicação de fatores nas suas respectivas curvas obtidas através de dados fornecidos em catálogo, assim como realizado anteriormente para simulação dos rendimentos isoentrópico e volumétrico do compressor. Desta forma as falhas modeladas, em três níveis de intensidade, são as seguintes:

- Fator de troca no **condensador** decaindo para 90% da condição atual
- Vazão de ar no **condensador** decaindo em um terço
- Fator de troca no **evaporador** decaindo para 90% da condição atual
- Vazão de ar no **evaporador** decaindo em um quinto
- K_a da **válvula** decaindo para 90% da condição atual
- Pressão da mola da **válvula** decaindo para 90% da condição atual
- Número de cilindros do **compressor** em 8 e parando de 2 em 2
- Rotação no **compressor** decaindo para 90% da condição atual
- Rendimento isentrópico no **compressor** decaindo para 90% da condição atual
- Rendimento volumétrico no **compressor** decaindo para 90% da condição atual

B. Características Observadas

As características observadas no sistema, a partir das quais será realizada a composição da base de dados são as seguintes:

- Coeficiente de performance (COP)
- Corrente elétrica [A]
- Pressão de sucção [bar]
- Pressão de descarga [bar]
- Rotação do compressor [rpm]
- Temperatura de subresfriamento DTSR [$^{\circ}C$]
- Temperatura de superaquecimento DTSA [$^{\circ}C$]
- Vazão mássica do fluido refrigerante [kg/s]

Por fim, a base de dados obtida é composta por 1365 padrões, dos quais 1260 são dados referentes ao sistema com presença de falhas, sendo estas rotuladas com 1, e 105 padrões para o sistema em bom funcionamento os quais foram rotuladas com -1.

IV. PROBLEMA DE CLASSES DESBALANCEADAS

A detecção de falhas em sistemas de refrigeração é um problema de classes desbalanceadas em virtude da elevada quantidade de possíveis falhas. Esses problemas são caracterizados pela existência de uma classe rara, ou seja, que ocorre com uma menor frequência. Quando se utiliza técnicas de inteligência computacional em problemas dessa natureza, muitos dos algoritmos de aprendizagem populares se mostram inadequados, esses tendem a favorecer a classe predominante e ignorar as classes com exemplos raros [8] [9].

Normalmente a acurácia é a métrica utilizada para a avaliação de classificadores, porém na presença de desbalanceamento entre as classes essa métrica não fornece informação adequada sobre o desempenho do classificador, ou seja, não determina sua capacidade de discriminação entre as classes [10]. Para que ocorra uma avaliação de maneira mais eficaz o classificador pode ser avaliado através de uma distinção dos erros cometidos para cada classe, isso pode ser feito através da matriz de confusão [8], onde TP é verdadeiro positivo, FP é falso positivo, FN é falso negativo, TN é verdadeiro negativo.

Tabela I. MATRIZ DE CONFUSÃO BASEADA EM [8]

	Obtido (f = 1)	Obtido (f = -1)
Desejado (t = 1)	TP	FN
Desejado (t = -1)	FP	TN

A partir da Matriz de Confusão pode-se calcular a métrica *G-mean*. Ela é uma das mais utilizadas quando se deseja medir o desempenho de classificadores quando estes estão expostos a problemas que possuam desbalanceamento de classes [10]. Essa métrica é a média geométrica entre as taxas de verdadeiro positivo e verdadeiro negativo, sendo então calculada pela Equação 2. O *G-mean* calcula o desempenho do classificador equilibrado entre as diferentes classes.

$$G\text{-mean} = \sqrt{\frac{TP}{TP + FN} \times \frac{TN}{TN + FP}} \quad (2)$$

V. DETECÇÃO DE FALHAS

Qualquer mudança indesejada que leve a uma degradação do sistema e prejudique o seu desempenho global pode ser considerada falha. O princípio de um sistema de detecção de falhas consiste basicamente em monitorar um sistema de interesse e detectar quando as condições de funcionamento indicam a presença de anomalias [11]. Foram testadas diferentes técnicas de inteligência computacional quanto ao desempenho em classificar o sistema como em bom funcionamento ou na presença de falhas. As técnicas de inteligência computacional utilizadas foram as seguintes:

- Redes Neurais Artificiais (RNA's) [12]
- *Support Vector Machine (SVM)* [13]
- *Extreme Learning Machine (ELM)* [14]
- *Weighted Extreme Learning Machine (WELM)* [10]
- *Weighted Support Vector Machine (WSVM)* [15]
- *EasyEnsemble* [16]

Todas as técnicas de inteligência computacional utilizadas neste trabalho foram implementadas através do software livre *GNU Octave-3.6.4*. Devido as técnicas de RNA's e SVM serem bem conhecidas, neste trabalho serão detalhadas apenas as técnicas ELM, WELM, WSVM e EasyEnsemble.

A. Extreme Learning Machine (ELM)

Extreme Learning Machine (ELM) é uma técnica de aprendizado de máquina desenvolvida para redes *feedforward* que possuem uma única camada escondida. Em [14] é mostrado que para redes deste tipo os pesos da camada de entrada (w) podem ser definidos aleatoriamente, sem haver perda de generalização, de forma que os pesos da camada de saída (β) podem ser determinados com a resolução do sistema linear da equação 3.

$$\beta = \mathbf{H}' \cdot T \quad (3)$$

Onde T são os resultados desejados e \mathbf{H}' é a pseudo-inversa da matriz de saída da camada escondida \mathbf{H} . Dada uma nova entrada \mathbf{x} a saída pode ser encontrada segundo a Equação 4. Nessa equação $\mathbf{h}(\mathbf{x})$ representa um padrão propagado pela camada escondida.

$$f(x) = \text{sign}(\mathbf{h}(\mathbf{x}) \cdot \beta) \quad (4)$$

B. Weighted Extreme Learning Machine (WELM)

Esta técnica proposta em [10] é utilizada quando o problema abordado possuir desbalanceamento considerável. Para tal, são utilizados pesos (\mathbf{W}) associados à base de dados, afim de balancear o conjunto de treinamento através de diferentes penalidade impostas a cada classe. A forma utilizada para calcular \mathbf{W} é descrita nas equações 5 e 6 [10].

$$\mathbf{W} = \text{diag}\{W_{ii}\} \quad (5)$$

$$W_{ii} = 1/\#(t) \quad (6)$$

Partindo do problema de otimização da Equação 7 encontram-se duas novas formas de se calcular os pesos da camada de saída (β) mostradas na Equação 8 [10].

$$\text{Minimizar: } \|\mathbf{H} \cdot \beta - T\|^2 \text{ e } \|\beta\| \quad (7)$$

$$\beta = \begin{cases} \mathbf{N}<\mathbf{L}: & (\frac{I}{C} + \mathbf{WHH}')^{-1} \mathbf{H}'\mathbf{W}T \\ \mathbf{N}>\mathbf{L}: & \mathbf{H}' (\frac{I}{C} + \mathbf{WHH}')^{-1} \mathbf{W}T \end{cases} \quad (8)$$

N é o número de padrões e L o número de neurônios na camada escondida.

1) *WELM com Sigmoid Node*: Nesta abordagem, dado uma nova entrada \mathbf{x} a saída pode ser encontrada pela Equação 4 como na ELM convencional apenas substituindo o novo β como mostrado na Equação 9. Nessa abordagem os parâmetros que devem ser ajustados são o C e o número de neurônios.

$$f(x) = \begin{cases} \mathbf{N}<\mathbf{L}: & \text{sign} \mathbf{h}(\mathbf{x}) \cdot (\frac{I}{C} + \mathbf{WHH}')^{-1} \mathbf{H}'\mathbf{W}T \\ \mathbf{N}>\mathbf{L}: & \text{sign} \mathbf{h}(\mathbf{x}) \cdot \mathbf{H}' (\frac{I}{C} + \mathbf{WHH}')^{-1} \mathbf{W}T \end{cases} \quad (9)$$

2) *WELM com Gaussian kernel*: Nesta abordagem a função de saída é calculada através de uma função de *Kernel*, sendo escolhido o *Kernel* do tipo Gaussiano por ser o mais popularmente utilizado. O *Kernel* do tipo gaussiano é calculado através da Equação [10].

$$K(u,v) = \exp\left(-\gamma \|u - v\|^2\right) \quad (10)$$

Dessa forma definindo $\Omega = \mathbf{H}\mathbf{H}'$, tem-se:

$$\Omega_{i,j} = h(x_i) \cdot h(x_j) = K(x_i, x_j) \quad (11)$$

A partir da equação 9 a função de saída será a seguinte:

$$f(x) = \text{sign} \left(\left[\begin{array}{c} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{array} \right]' \left(\frac{I}{C} + \mathbf{W}\Omega \right)^{-1} \mathbf{W}\mathbf{T} \right) \quad (12)$$

Assim, os parâmetros a serem ajustados nessa abordagem são o C e o parâmetro γ do *Kernel*.

C. Weighted Support Vector Machine (WSVM)

Weighted Support Vector Machine (WSVM) é um tipo de *SVM* adaptado para aprendizado sensível ao custo, utilizando em sua formulação diferentes parâmetros de penalidade entre as classes, sendo útil para problemas que apresentam desbalanceamento de classes [15]. A definição do hiperplano ótimo para *WSVM* é semelhante à *SVM* convencional, a diferença está na utilização de diferentes custos associados às classes. Um problema com duas classes pode ser escrito como a seguir [15].

$$\begin{cases} \text{Minimizar: } \|w\|^2 + C^+ \sum \xi_i + C^- \sum \xi_i \\ \text{Sujeito a: } y(w' \phi(x_i) + b) \geq 1 - \xi_i \end{cases} \quad (13)$$

Na intenção de balancear o grupo de dados, utiliza-se a Equação 14 para calcular os parâmetros C^+ e C^- . Nessa equação n^+ é o número de dados pertencentes à classe positiva e n^- é o número de dados pertencentes à classe negativa.

$$\begin{cases} C^+ = \frac{C}{n^+} \\ C^- = \frac{C}{n^-} \end{cases} \quad (14)$$

A exemplo da *SVM* os parâmetros a serem ajustados para *WSVM* serão o parâmetros C e os parâmetros do tipo de *Kernel* selecionado.

D. EasyEnsemble

EasyEnsemble é uma técnica de *Boosting* para problemas onde a base de dados apresenta desbalanceamento entre as classes [16]. Técnicas de *Boosting* são utilizadas aliadas à outras técnicas de classificação com o objetivo de transformar classificadores fracos em fortes com a combinação de hipóteses geradas por um mesmo classificador onde seu funcionamento é ajustado de acordo com os erros obtidos na classificação da iteração anterior [17]. O *EasyEnsemble* separa a classe

majoritária em subgrupos, de mesmo tamanho da classe minoritária, que são treinados com a classe minoritária em separado e por fim reunidos para formar a resposta final. A saída do *EasyEnsemble* é calculada da seguinte forma [16]:

$$H(x) = \text{sign} \left(\sum_{i=1}^T \sum_{j=1}^{S_i} \alpha_{i,j} h_{i,j}(x) - \sum_{i=1}^T \theta_i \right) \quad (15)$$

Onde T é o número do subgrupo da classe majoritária, S_i é o número de iterações do *Adaboost*, $h_{i,j}(x)$ é a classificação gerada pelo classificador fraco, $\alpha_{i,j}$ são os pesos e θ_i são os limiares. Os pesos α e os limiares θ , encontrados no *Adaboost*, definem a representatividade de cada resposta parcial na resposta final. Os parâmetros a serem ajustados são o número de iterações S_i e os parâmetros do classificador em questão.

VI. RESULTADOS EXPERIMENTAIS

A realização do experimento que atesta o desempenho dos métodos avaliados foi dividida em duas etapas: Na primeira etapa foi selecionado aleatoriamente 30% dos padrões para realizar o ajuste de parâmetros; na segunda etapa foram utilizados os parâmetros ajustados para treinar os modelos utilizando todo o grupo de dados de treinamento disponíveis, incluindo os 30% utilizados anteriormente. Após a seleção aleatória de 30% da base de dados, foi realizada 10 execuções de uma validação cruzada do tipo *10-fold* e os parâmetros que forneceram o melhor resultado médio em termos de *G-mean* foram selecionados. Tais testes foram realizados em uma determinada faixa de valores indicada na Tabela II. Essa tabela também apresenta os valores selecionados para todos os parâmetros dos modelos utilizados.

Tabela II. SELEÇÃO DE PARÂMETROS

Técnica de Classificação	Parâmetros	Valores Testados	Valor Selecionado
<i>RNA</i>	Neurônios	1, 2, ..., 25	22
<i>ELM</i>	Neurônios	10, 20, ..., 350	310
<i>SVM</i>	C	$2^{-5}, 2^{-4}, \dots, 2^{14}$	8192
	γ	$2^{-5}, 2^{-4}, \dots, 2^{14}$	0.5
<i>WSVM</i>	C	$2^{-5}, 2^{-4}, \dots, 2^{14}$	16384
	γ	$2^{-5}, 2^{-4}, \dots, 2^{14}$	0.5
<i>WELM com Sigmoid node</i>	Neurônios	10, 20, ..., 350	350
	C	$2^{-18}, 2^{-14}, \dots, 2^{30}$	16384
<i>WELM com Gaussian kernel</i>	C	$2^{-18}, 2^{-14}, \dots, 2^{30}$	4194304
	γ	$2^{-18}, 2^{-14}, \dots, 2^{20}$	0.25
<i>RNA com EasyEnsemble</i>	Neurônios	1, 2, ..., 25	15
	S_i	1, 2, 3, 4, 5	5
<i>ELM com EasyEnsemble</i>	Neurônios	10, 15, ..., 50	35
	S_i	1, 2, 3, 4, 5	4

Com a base de dados completa, incluindo os 30% avaliados anteriormente, e utilizando os parâmetros selecionados, foram realizadas 10 execuções da validação cruzada do tipo *10-fold*. Nesta etapa os classificadores além de serem avaliados por *G-mean* também foram avaliados quanto a acurácia, afim de se obter uma comparação entre essas duas métricas. A Tabela

III mostra os resultados obtidos no experimento para todas as técnicas de classificação utilizadas, tanto em termos de *G-mean* quanto em termos da acurácia.

Tabela III. RESULTADOS

Técnica de Classificação	<i>G-mean</i>	Acurácia
<i>RNA</i>	0.46385 ± 0.056726	93.951 ± 0.42906
<i>ELM</i>	0.61746 ± 0.022376	94.543 ± 0.29035
<i>SVM</i>	0.78948 ± 1.1703e-016	96.787 ± 1.498e-014
<i>WSVM</i>	0.90785 ± 1.1703e-016	83.785 ± 1.498e-014
<i>WELM com Sigmoid node</i>	0.87195 ± 0.0053151	82.754 ± 0.47570
<i>WELM com Gaussian kernel</i>	0.92803 ± 0.019603	87.216 ± 3.3444
<i>RNA com EasyEnsemble</i>	0.83257 ± 0.016045	88.824 ± 0.41667
<i>ELM com EasyEnsemble</i>	0.88510 ± 0.0078625	82.861 ± 0.45565

A partir da Tabela III pode-se observar que os classificadores *RNA*, *ELM* e *SVM* apesar de um bom desempenho quando avaliados por *Acurácia* (93.951, 94.543 e 96.787 respectivamente), favorecem apenas uma das classes durante a classificação, o que pode ser verificado pelo desempenho em termos de *G-mean*. Para a técnica de *Boosting EasyEnsemble* foram utilizados como classificadores fracos *RNA* e *ELM*. Esta melhorou o desempenho de ambos, sendo que em termos de *G-mean* o desempenho da *ELM* que era de 0.61746 quando utilizada com *EasyEnsemble* se tornou 0.8851. Esta melhoria do desempenho é possível devido a esta técnica dividir a base de dados em partes onde o número de padrões é igual para ambas às classes, calculando para cada grupo sua representatividade na resposta final. A técnica testada com o melhor desempenho foi a *WELM* com *Gaussian kernel* que obteve 0,92803 em termos de *G-mean*, sendo a técnica selecionada como a melhor opção para implantação do sistema de detecção de falhas. Este desempenho pode ser explicado pelo fato desta técnica utilizar pesos associados à base de dados que determinam diferentes penalidades para os padrões pertencentes a cada classe, o que aumenta a importância da classe minoritária durante o processo de treinamento.

VII. CONCLUSÃO

Sistemas de refrigeração estão sujeitos a diversos tipos de falhas onde sua detecção pode trazer diversos benefícios relacionados principalmente à economia de energia e à otimização da manutenção. Tendo isso em mente, foi proposto neste trabalho o uso de técnicas de inteligência computacional para detecção das falhas em um sistema de refrigeração. Foi observado, a partir dos resultados obtidos, que os classificadores clássicos não obtiveram um bom desempenho quando expostos ao problema avaliado devido ao mesmo apresentar desbalanceamento entre as classes. Dessa forma foi necessário utilizar classificadores que usam alguma estratégia específica para lidar com problemas de classes desbalanceadas. Foi observado também que a métrica *Acurácia* quando utilizada em problemas com classes desbalanceadas se mostra ineficaz, sendo necessária outra métrica que descreva melhor o desempenho do classificador em discriminar as diferentes classes, sendo escolhido para tal a métrica *G-mean*. A técnica *WELM* com *Gaussian kernel*, dentre as testadas, se mostrou a mais

indicada para realizar a tarefa de detectar falhas do sistema de refrigeração por compressão de vapor.

Como trabalhos futuros pretende-se utilizar classificadores para problemas multiclasse com o objetivo de detectar em qual equipamento ocorre a falha. Outra proposta é a seleção de características, que irá indicar dentre as características utilizadas, quais são as mais relevantes, facilitando a implantação desse sistema de detecção de falhas uma vez que diminuirá o número de sensores a serem utilizados.

AGRADECIMENTOS

Os autores agradecem a FAPEMIG e a UFVJM pelo apoio financeiro.

REFERÊNCIAS

- [1] C. R. Rocha, S. Bajay, and F. D. Gorla, "Oportunidades de eficiência energética para a indústria: Relatório setorial: alimentos e bebidas," *Brasília: CNI*, p. 58, 2010.
- [2] E. I. Bueno, "Utilização de redes neurais artificiais na monitoração e detecção de falhas em sensores do reator ic-r1," Dissertação de Mestrado, Universidade de São Paulo, 2006.
- [3] L. C. Schurt *et al.*, "Modelagem matemática e controle multivariável de sistemas de refrigeração por compressão mecânica de vapor," Dissertação de Mestrado, Universidade Federal de Santa Catarina, 2009.
- [4] O. J. Venturini, M. J. Pirani, C. R. Rocha, M. A. G. Monteiro, and C. Efficientia, *Eficiência energética em sistemas de refrigeração industrial e comercial: manual prático*. Eletrobrás, 2005.
- [5] T. Mendes, "Diagnóstico termodinâmico aplicado a um sistema de refrigeração por compressão de vapor," Dissertação de Mestrado, Universidade Federal de Itajaú, 2012.
- [6] D. Richardson, H. Jiang, D. Lindsay, and R. Radermacher, "Optimization of vapor compression systems via simulation," in *International Refrigeration and Air-Conditioning Conference*, 2002, paper 529.
- [7] R. E. Sonntag, C. Borgnakke, G. J. Van Wylen, and E. J. G. de Jesus Zerbini, *Fundamentos da termodinâmica*. Edgard Blücher, 2003.
- [8] C. L. de Castro, "Novos critérios para seleção de modelos neurais em problemas de classificação com dados desbalanceados," Ph.D. dissertation, Universidade Federal de Minas Gerais, 2011.
- [9] Y. Sun, A. K. Wong, and M. S. Kamel, "Classification of imbalanced data: A review," *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 23, no. 04, pp. 687–719, 2009.
- [10] W. Zong, G.-B. Huang, and Y. Chen, "Weighted extreme learning machine for imbalance learning," *Neurocomputing*, vol. 101, pp. 229–242, 2013.
- [11] A. Halm-Owoo and K. Suen, "Applications of fault detection and diagnostic techniques for refrigeration and air conditioning: A review of basic principles," *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, vol. 216, no. 3, pp. 121–132, 2002.
- [12] M. D. Schmid, "A neural network package for octave user's guide version: 0.1. 9.1," 2009.
- [13] C.-C. Chang and C.-J. Lin, "Libsvm: a library for support vector machines," *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol. 2, no. 3, p. 27, 2011.
- [14] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: theory and applications," *Neurocomputing*, vol. 70, no. 1, pp. 489–501, 2006.
- [15] P. Xanthopoulos and T. Razzaghi, "A weighted support vector machine method for control chart pattern recognition," *Computers & Industrial Engineering*, vol. 70, pp. 134–149, 2014.
- [16] X.-Y. Liu, J. Wu, and Z.-H. Zhou, "Exploratory undersampling for class-imbalance learning," *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, vol. 39, no. 2, pp. 539–550, 2009.
- [17] B. B. Chaves, "Estudo do algoritmo adaboost de aprendizagem de máquina aplicado a sensores e sistemas embarcados." Dissertação de Mestrado, Universidade de São Paulo, 2012.