

Sensor virtual baseado em dados de vibração para estimativa da temperatura de evaporação de sistemas de refrigeração ^{*}

Ahryman S. B. de S. Nascimento ^{**} Gustavo Batista ^{*}
Rodolfo C. C. Flesch ^{*} Gabriel Thaler ^{*}

^{*} Departamento de Automação e Sistemas, Universidade Federal de Santa Catarina, SC, (e-mails: gustavo.witt98@gmail.com, rodolfo.flesch@ufsc.br, gabriel.thaler@labmetro.ufsc.br).

^{**} Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina, SC, (e-mails: a.nascimento@labmetro.ufsc.br).

Abstract: The measurement of the operating condition of refrigeration systems typically requires invasive instrumentation. This work presents procedures for the development of virtual sensors able to estimate one of the operating conditions, the evaporating temperature, by means of non-invasive instrumentation. The proposed virtual sensor uses measurements of vibration on the surface of the refrigeration compressor and machine learning models for estimating the evaporating temperature. A dataset of vibration data collected on different operating conditions was obtained and used to train and test the models. It was found that the proposed method is able to provide reliable estimates of the evaporating temperature, with root mean square errors of about 2 °C, independently of the machine learning model considered in the study.

Resumo: A medição da condição de operação de sistemas de refrigeração tipicamente emprega instrumentação invasiva. Neste trabalho, são propostos procedimentos para o desenvolvimento de sensores virtuais capazes de estimar uma das condições de operação, a temperatura de evaporação, por meio de instrumentação não-invasiva. Tais sensores utilizam medições de vibração no corpo do compressor do sistema de refrigeração e modelos de aprendizado de máquina para estimar a temperatura de evaporação. Um conjunto de dados de vibração em diferentes condições de operação foi obtido e utilizado no treinamento e teste dos modelos. Foi verificado que o método proposto é capaz de retornar uma estimativa coerente da temperatura de evaporação, com erros quadráticos médios da ordem de 2 °C, independentemente do modelo de aprendizado de máquina considerado.

Keywords: Virtual sensors, refrigeration systems, vibration, evaporating temperature.

Palavras-chaves: Sensores virtuais, sistemas de refrigeração, vibração, temperatura de evaporação.

1. INTRODUÇÃO

A caracterização da condição de operação de sistemas de refrigeração é importante para identificar problemas de qualidade (Yang et al., 2019), tanto em linha de produção quanto em campo, e tem potencial para permitir um controle mais eficiente da operação do sistema (Potočnik e Govekar, 2017). Entre as variáveis mais importantes para caracterizar a operação de um sistema estão as temperaturas de evaporação e de condensação (ASHRAE, 2019), porém a medição direta dessas variáveis está muito sujeita a erros, dado que a temperatura não é homogênea nos trocadores de calor, há influência da temperatura ambiente nas medições e as dinâmicas observadas muitas

vezes são rápidas, mas a medição por meio da parede dos trocadores limita a caracterização a baixas frequências. Assim, é comum que a medição dessas variáveis seja realizada com emprego de transdutores de pressão, já que existe uma relação direta entre cada uma dessas temperaturas e as pressões medidas na entrada e na saída do compressor, dado que nos trocadores de calor do sistema o fluido encontra-se saturado (ASHRAE, 2021). Apesar de possibilitar a medição com menor incerteza, a medição de pressão é invasiva, pois necessita que a tubulação do sistema seja aberta para instalação dos transdutores, o que acaba descaracterizando as amostras, em especial quanto à carga de fluido refrigerante presente.

Um método não invasivo capaz de medir a temperatura de operação com um erro de até 2 °C, embora muito aquém do nível de incerteza de $\pm 0,28$ °C necessário para ensaios de desempenho (ASHRAE, 2021), poderia ser útil para

^{*} Este trabalho foi apoiado pela Nidec Global Appliance, pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), por meio do projeto 432116/2018-4, e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

monitorar o sistema, auxiliando na detecção e previsão de falhas.

Técnicas de sensoriamento virtual têm uma grande quantidade de aplicações na indústria, tais como controle de qualidade (Ma e Huang, 2017), detecção de falhas e diagnóstico de produtos (Yin et al., 2015), redução de custos por redução de sensores (Sarkar et al., 2016), cálculo indireto de quantidades (Zeng et al., 2018), entre outros. Muitos artigos sobre sensoriamento virtual têm sido publicados nos últimos anos e mostram a variedade de aplicações e métodos utilizados, assim como a efetividade da abordagem (Ge, 2017; Samad, 2017). Para máquinas rotativas, o uso de dados de vibração para a criação de sensores virtuais para avaliação das condições de operação é muito difundido (Tang et al., 2018; Azamfar et al., 2020). Especificamente para sistemas de refrigeração, os dados de vibração podem ser utilizados no desenvolvimento de sensores virtuais para estimar a potência sonora gerada pelos compressores (Nascimento et al., 2020), para classificação do estado de operação de compressores (Potočnik e Govekar, 2017), e para detecção de falhas de projeto e ferramentas de diagnóstico (Cabrera et al., 2020).

Trabalhos encontrados na literatura exploraram o uso de técnicas de aprendizado de máquina (ML, do inglês *machine learning*) para avaliação de sistemas de refrigeração a partir de dados de vibração a fim de classificar quando um sistema está operando em condições normais ou não. Este artigo propõe o desenvolvimento de um sensor virtual baseado em dados de vibração para estimar a temperatura de evaporação do sistema. No método proposto, os coeficientes filtrados do espectro de frequência dos dados de vibração medidos no corpo do compressor de refrigeração são utilizados para o treinamento de modelos de regressão. Qualquer técnica de ML poderia ser utilizada, mas para comparação neste artigo são utilizados três modelos, sendo um linear e outros dois não lineares. O modelo linear é o de Regressão Linear Multivariável (RL) e os não lineares são duas arquiteturas de Redes Neurais Artificiais (RNAs), uma com única camada escondida (RNA rasa, ou RNAR) e outra com duas camadas escondidas (RNA profunda, ou RNAP).

A inovação deste artigo consiste na utilização um sensor virtual não invasivo para estimar a temperatura de evaporação em sistemas de refrigeração baseado nos dados de vibração, que pode ser utilizado tanto para monitoramento de condições de operação quanto para detecção de falhas. Com a técnica proposta, a avaliação pode ser realizada sem a necessidade de instrumentação invasiva, permitindo avaliação mais rápida e fácil. O sensor virtual proposto foi treinado e testado com um conjunto de dados adquiridos no escopo deste trabalho e que representam condições reais observadas em sistemas de refrigeração. Esse conjunto contém dados de velocidade vibratória na superfície do compressor operando em diferentes frequências rotacionais e diferentes pressões de sucção.

O restante do artigo está organizado como segue. A seção 2 apresenta os materiais e métodos, detalhando o processo utilizado para gerar o conjunto de dados utilizado para treinamento e testes, assim como a estrutura do sensor virtual baseado em dados proposto. A seção 3 apresenta o procedimento usado para treinamento e seleção de hi-

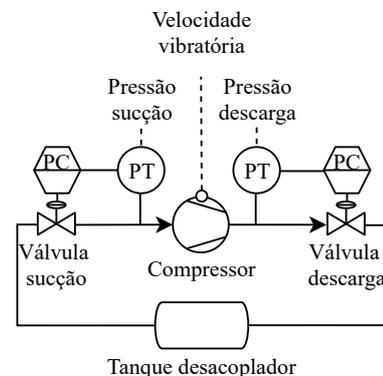
perparâmetros dos modelos de ML. A seção 4 detalha os resultados e análises do método proposto com diferentes modelos de ML. A seção 5 apresenta a conclusão.

2. MATERIAIS E MÉTODOS

Esta seção apresenta os materiais e métodos utilizados neste estudo. A seção 2.1 apresenta o procedimento para aquisição dos dados de vibração no compressor de refrigeração usados para o desenvolvimento do sensor virtual. A seção 2.2 apresenta o detalhamento dos modelos de ML utilizados neste estudo, incluindo a etapa de pré-processamento dos dados.

2.1 Aquisição dos dados de vibração no compressor

Neste trabalho, uma bancada de ensaios foi utilizada para obter o conjunto de dados de vibração de diferentes unidades de compressores, testados em diferentes condições de operação. A bancada foi desenvolvida para emular a operação dos compressores em um sistema de refrigeração, como mostra o diagrama da Figura 1a. O compressor em ensaio tem o espectro de velocidade vibratória na sua superfície medido por um acelerômetro e pode ser avaliado em diferentes frequências rotacionais e em diferentes pressões de sucção e de descarga. As pressões de sucção e de descarga do compressor são controladas em malha fechada, para que as referências possam ser escolhidas de forma desejada dentro do mapa de aplicação característico do modelo de compressor ensaiado.



(a) P&ID da bancada



(b) Compressor instrumentado

Figura 1. Configuração experimental para aquisição de dados.

Todos os compressores utilizados neste estudo são do tipo hermético, possuem a frequência rotacional variável e operam com o fluido refrigerante R600a. Foram utilizados dois

transdutores GE TERPS DPS 8000 para medir as pressões de sucção e de descarga, com uma incerteza instrumental de $\pm 0,01\%$. Para a aquisição da velocidade vibratória, um acelerômetro PCB M352C65 com base magnética foi acoplado na superfície superior do compressor, como pode ser visto na Figura 1b. A taxa de aquisição das pressões é de 10 Hz e a taxa de aquisição da velocidade vibratória é de 51,2 kHz. Neste estudo, cinco unidades de compressores foram testadas em três frequências rotacionais cada (2100 RPM, 2850 RPM e 3600 RPM). Para cada frequência rotacional, foram obtidos dados de vibração em 11 pares de pressão de sucção e de descarga, sendo que a pressão de sucção foi variada entre 0,47 bar e 1,08 bar, correspondendo às temperaturas de evaporação de $-30\text{ }^\circ\text{C}$ até $-10\text{ }^\circ\text{C}$, e a pressão de descarga foi fixada em 5,89 bar, correspondendo à temperatura de condensação de $44\text{ }^\circ\text{C}$. Esses valores foram selecionados a fim de testar o compressor nas temperaturas de evaporação típicas de sistemas de refrigeração em aplicações domésticas. A temperatura de condensação de $44\text{ }^\circ\text{C}$ foi selecionada por ser uma condição intermediária dentro da faixa de aplicação de ensaios de desempenho para sistemas de refrigeração (AHRI, 2015). Para cada unidade de compressor, foram medidas 30 vezes cada condição de operação (frequência rotacional, pressões de sucção e de descarga). As condições de operação foram definidas de forma aleatória para cada rodada de repetição e uma nova rodada de repetição se iniciava logo que uma dada repetição de todas as condições havia sido finalizada. O conjunto de dados resultante possui 4.940 amostras, cada uma consistindo da medição da velocidade vibratória por 1 s e das medições das pressões de sucção e descarga. Um conjunto de dados adicional contendo frequências rotacionais intermediárias, 2475 RPM e 3225 RPM, e 9 pares de temperaturas de evaporação e de condensação foi adquirido para auxiliar os modelos de ML a apresentarem uma melhor capacidade de generalização para essas condições intermediárias. Esse conjunto possui 630 amostras.

2.2 Características dos modelos de aprendizado de máquina

Os modelos de ML propostos e suas configurações são detalhados nesta seção. O primeiro passo consiste em processar os dados brutos de vibração, que são utilizados como entrada para os modelos depois de processados. Esse passo é detalhado na sequência.

Processamento dos dados de vibração O processamento dos dados de vibração possui dois passos: o cálculo das amplitudes do espectro de frequência e a filtragem do espectro obtido. Um exemplo do processo pode ser visto na Figura 2. Os dados brutos de velocidade vibratória, presentes na Figura 2a, foram adquiridos em 1 s com uma taxa de 51,2 kHz. A transformada rápida de Fourier (FFT) foi utilizada para obter a amplitude do espectro de frequência, resultando em 25 600 pontos de frequências não negativas (Rao et al., 2011). O limite superior para a avaliação do espectro de frequência de vibração em estudos de compressores de refrigeração normalmente é de 10 kHz, pois a maior parte dos fenômenos de interesse tem efeito nessa faixa (McKee et al., 2015). Portanto, a amostragem obtida, que permite a análise até 25,6 kHz, fornece um bom nível de confiança de que o efeito da vibração na temperatura de evaporação será considerado.

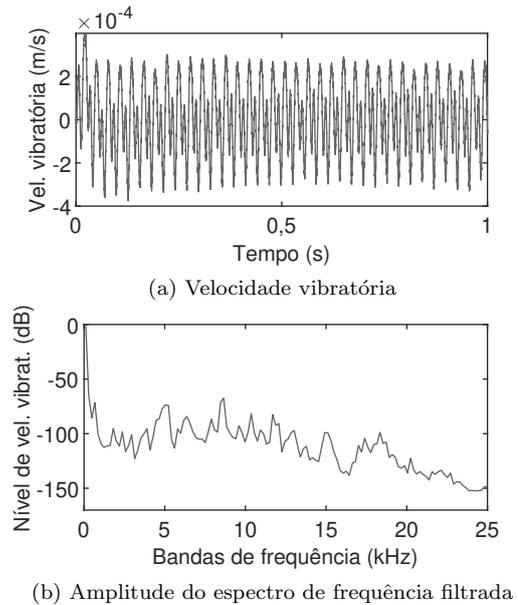


Figura 2. Processamento dos dados de vibração. A transformada rápida de Fourier é obtida, seguida por um filtro de bandas da amplitude do espectro de frequência.

O espectro resultante possui 25 600 pontos e foi filtrado por um filtro de bandas a fim de determinar a energia em bandas de frequência, processo que condensa a informação do espectro em um número menor de pontos e reduz o efeito do ruído branco. Uma alternativa seria utilizar filtros de bandas de oitava, que inicialmente foram propostos para análises acústicas e então adaptados para a avaliação do espectro de vibração de máquinas rotacionais para obter informações a respeito da frequência rotacional (McKee et al., 2015). Como este trabalho propõe extrair informações a respeito da temperatura de evaporação, foi decidido utilizar um filtro de banda com tamanho fixo, que preserva mais informações a respeito de frequências altas e médias. O tamanho de banda foi fixado em 200 Hz, com 10% de sobreposição entre as bandas. O filtro avalia a energia para as bandas centrais de 100 Hz até 24,99 kHz, resultando em 132 bandas. O resultado do processo de filtragem é apresentado na Figura 2b.

Detalhamento dos modelos de ML Esta seção detalha os três modelos de ML testados para o sensor virtual. Para a RL, um fator de regularização foi usado para evitar os efeitos da alta correlação entre as variáveis de entrada (Hoerl e Kennard, 1970). O método adiciona um fator k no cálculo da matriz de coeficientes $\hat{\beta}$:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X} + k\mathbf{I})^{-1} \mathbf{X}^T \mathbf{y},$$

onde \mathbf{X} é a matriz de entradas, \mathbf{y} é o vetor de saídas e \mathbf{I} é uma matriz identidade de dimensão apropriada. Para as RNAs, duas arquiteturas foram utilizadas: RNAR, que consiste em uma RNA com apenas uma camada escondida, e RNAP, com duas camadas escondidas.

Para os três modelos, as entradas consistem em 132 bandas obtidas pelo filtro de bandas e a frequência rotacional da amostra. Todas as entradas foram normalizadas de forma a possuírem média zero e desvio padrão unitário. Como

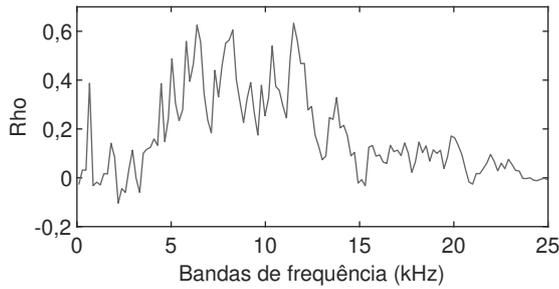


Figura 3. Avaliação do coeficiente de correlação de Spearman entre bandas de frequência e temperatura de evaporação.

saída, a rede retorna a temperatura de evaporação da amostra.

3. SELEÇÃO DE HIPERPARÂMETROS E TREINAMENTO DOS MODELOS DE APRENDIZADO DE MÁQUINA

Esta seção apresenta como o conjunto de dados foi dividido para o treinamento dos modelos de ML, assim como o procedimento adotado para a seleção de hiperparâmetros dos modelos.

Como foram adquiridos dados de cinco unidades de compressores do mesmo modelo, os dados da quinta unidade foram reservados para o conjunto de teste dos modelos de ML. Os dados das quatro unidades restantes foram utilizados como conjunto de treinamento. Para o ajuste dos hiperparâmetros dos modelos, 10% dos dados do conjunto de treinamento foram separados e utilizados como conjunto de desenvolvimento.

Um hiperparâmetro utilizado nos três modelos é o número de bandas de frequência usadas como entradas do modelo. Nem todas as bandas necessariamente apresentam informações relevantes para estimar a temperatura de evaporação. Dessa forma, a fim de determinar quais bandas apresentam mais informações a respeito do parâmetro desejado, o coeficiente de correlação de Spearman (Puth et al., 2015) foi calculado entre cada uma das bandas e a temperatura de evaporação para conjunto de treinamento. Tal coeficiente foi escolhido pois permite avaliar a relação monotônica entre as bandas e a temperatura de evaporação, sendo capaz de avaliar relações não lineares, contanto que sejam monotônicas. O resultado, apresentado na Figura 3, permite que as bandas sejam ordenadas pelo grau de correlação e, dessa forma, permite garantir que as bandas com maior valor absoluto da correlação com a temperatura de evaporação estejam sempre presentes no conjunto mesmo quando for selecionado um número reduzido de entradas.

Para a RL, os hiperparâmetros a serem ajustados são o fator de regularização k e a quantidade de bandas de frequência. Uma busca em grade foi realizada variando o fator k de 0 a 1000, com um passo de 20 e a quantidade de bandas de 10 até 130, com um passo de 10. Para a avaliação do desempenho foi utilizada a raiz do erro quadrático médio (RMSE, do inglês *root-mean-square error*) do conjunto de desenvolvimento. A Figura 4 apresenta os resultados da busca. A quantidade de bandas de entrada teve influência

considerável, atingindo-se o melhor resultado de RMSE para a utilização de 130 bandas como entrada. O fator de regularização k teve um impacto menor no resultado do RMSE, com melhor resultado obtido com o valor de 280.

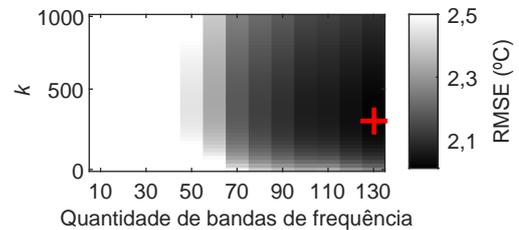


Figura 4. Busca em grade pelos melhores hiperparâmetros para o modelo RL.

Para a RNAR, uma busca em grade também foi realizada a fim de selecionar o melhor conjunto de parâmetros. Foram testados os efeitos da quantidade de neurônios na camada escondida e da quantidade de bandas utilizadas como entrada no desempenho da RNAR. O número de neurônios foi variado de 10 até 600. O número de bandas usadas como entrada foi variado de 10 até 130. A função de ativação utilizada foi a Função Linear Retificada (relu) e o algoritmo de treinamento utilizado foi o Gradiente Descendente Estocástico com Momento (Murphy, 2012). Novamente, o RMSE do conjunto de desenvolvimento foi utilizado como parâmetro de avaliação do modelo. Para evitar superajuste do modelo ao conjunto de treinamento, 10% do mesmo foi utilizado para realizar a validação cruzada durante o processo de treinamento. Os resultados são apresentados na Figura 5. Cada resultado observado é, na verdade, a média aritmética de 10 treinamentos da RNAR realizados com cada configuração. A partir dos resultados, definiu-se como a melhor configuração a utilização de 90 bandas de frequência como entrada e 400 neurônios na camada escondida.

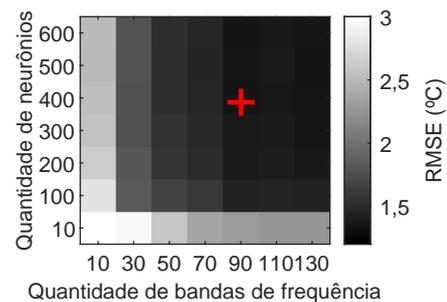


Figura 5. Busca em grade pelos melhores hiperparâmetros para o modelo RNAR.

Para a RNAP, o mesmo procedimento da RNAR foi realizado, porém com uma camada escondida adicional, após a camada de entrada, contendo 600 neurônios. Os resultados são apresentados na Figura 6. Novamente, os resultados observados representam a média aritmética de 10 treinamentos da RNAP realizados com cada configuração. A partir dos resultados, definiu-se como a melhor configuração a utilização de 130 bandas de frequência como entrada e 100 neurônios na segunda camada escondida.

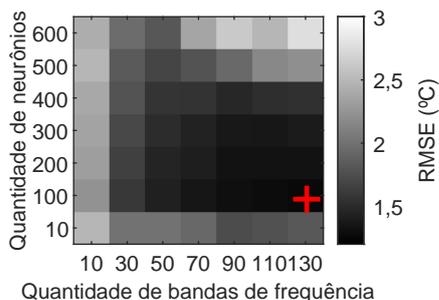


Figura 6. Busca em grade pelos melhores hiperparâmetros para o modelo RNAP.

4. RESULTADOS E DISCUSSÃO

Com os hiperparâmetros selecionados, os três modelos foram treinados com o conjunto de treinamento e testados no conjunto de teste. Como indicado na seção 3, o conjunto de teste consiste dos dados da quinta unidade de compressor, que não teve nenhum de seus dados considerados no conjunto de treinamento. Dessa forma, é apropriado assumir que o resultado para este conjunto representa como os modelos se comportariam quando aplicados a um conjunto de dados não visto antes, indicando sua capacidade de generalização para unidades do mesmo modelo. A Tabela 1 apresenta o RMSE e o coeficiente de determinação R^2 para os três modelos treinados nos conjuntos de treinamento, desenvolvimento e teste. As métricas de desempenho indicam que o modelo de RNAR apresentou o melhor resultado para o conjunto de teste, mas o modelo de RL apresentou um resultado muito próximo ao melhor, indicando que a relação entre as entradas utilizadas e a temperatura de evaporação tem um comportamento próximo de linear. O modelo RNAP apresentou o pior resultado para o conjunto de teste, indicando que não há ganho no aumento da complexidade para esta situação, em especial para o conjunto de dados atual. O número de pesos para serem ajustados nesse modelo é muito alto em comparação com o tamanho do conjunto de dados disponível, o que acaba prejudicando o treinamento e, conseqüentemente, o desempenho do mesmo.

As Figuras 7 a 9 apresentam os gráficos dos resíduos entre os valores estimados e os medidos para o conjunto de teste para cada um dos modelos treinados. Os resíduos foram divididos entre as frequências rotacionais presentes no conjunto. Por meio dos gráficos de resíduos, é possível avaliar como cada modelo se comporta ao longo da faixa de aplicação do mesmo, que para este conjunto de dados ficou entre $-30\text{ }^{\circ}\text{C}$ e $-10\text{ }^{\circ}\text{C}$. Tais gráficos permitem avaliar se determinado modelo possui tendência a errar para mais ou para menos dependendo da região da faixa de aplicação. Por meio dos gráficos de resíduos, é possível constatar que os dois melhores modelos, RL e RNAR, apresentaram comportamento similar de resíduos, com o modelo RNAP apresentando um comportamento mais tendencioso nos extremos da faixa de aplicação.

5. CONCLUSÃO

Um conjunto de dados de vibração de compressores de refrigeração foi adquirido em diversas condições típicas

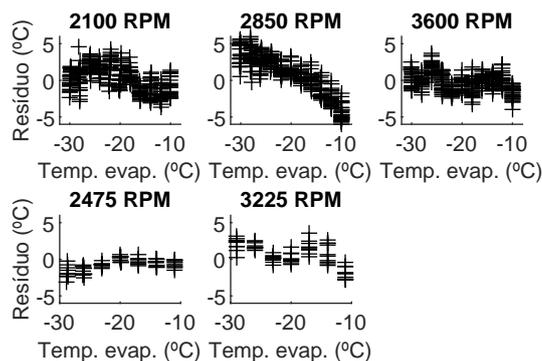


Figura 7. Resíduos para o conjunto de teste divididos por frequência rotacional para o modelo RL.

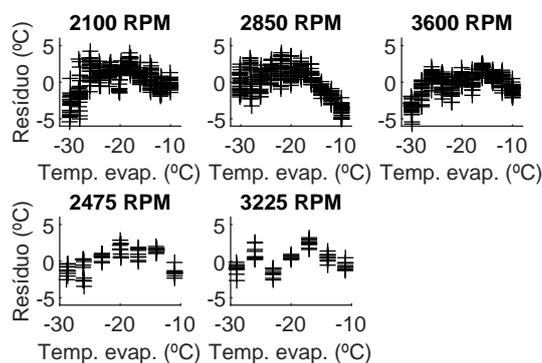


Figura 8. Resíduos para o conjunto de teste divididos por frequência rotacional para o modelo RNAR.

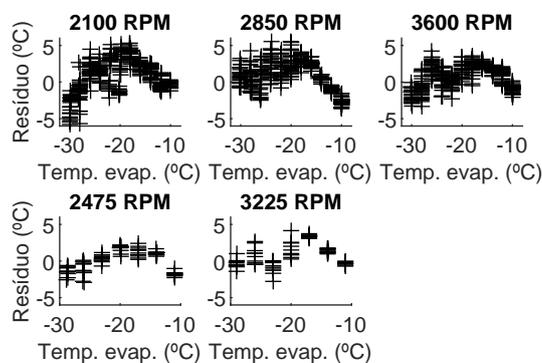


Figura 9. Resíduos para o conjunto de teste divididos por frequência rotacional para o modelo RNAP.

de um envelope de aplicação em um refrigerador, possibilitando o treinamento de modelos de aprendizado de máquina para estimar a temperatura de evaporação de sistemas de refrigeração de forma não invasiva. O conjunto de dados foi dividido em conjuntos de treinamento, desenvolvimento e teste, com os dois primeiros sendo utilizados para treinamento dos modelos e ajuste de seus hiperparâmetros e o último sendo utilizado para avaliar o comportamento dos mesmos para dados não antes vistos.

Um modelo de regressão linear e dois modelos de redes neurais artificiais foram treinados, sendo que o modelo com uma camada escondida apresentou os melhores resultados, sendo capaz de estimar a temperatura de evaporação com

Tabela 1. Métricas de desempenho para os modelos treinados

Conjunto	RL		RNAR		RNAP	
	R^2	RMSE (°C)	R^2	RMSE (°C)	R^2	RMSE (°C)
Treinamento	0,92	1,80	0,99	0,43	0,99	0,43
Desenvolvimento	0,90	2,02	0,96	1,34	0,96	1,24
Teste	0,90	1,99	0,92	1,77	0,89	2,13

um RMSE de 1,77 °C. A diferença para o modelo de regressão linear não foi tão grande, indicando que a relação entre as entradas e a saída do modelo é próxima de linear para o conjunto de dados obtido neste trabalho. É esperando que tal relação fique mais complexa com a variação de outras grandezas, como a temperatura de condensação, que ficou fixa neste estudo.

Tendo em vista os resultados obtidos, a ideia da utilização de dados de vibração no corpo do compressor de refrigeração e modelos de ML para o desenvolvimento de sensores virtuais não invasivos almejando a estimativa da temperatura de evaporação se mostrou viável a partir das estratégias avaliadas. A qualidade da estimativa obtida permite a avaliação futura da utilização da mesma para ferramentas de detecção e prevenção de falhas em sistemas de refrigeração relacionadas com mudanças na temperatura de evaporação. Ademais, o conjunto de dados pode ser expandido para avaliar o comportamento da relação da vibração com a temperatura de evaporação frente a variações da temperatura de condensação, fenômeno esperado durante o funcionamento do sistema de refrigeração.

REFERÊNCIAS

AHRI (2015). AHRI 540 – Performance rating of positive displacement refrigerant compressors and compressor units.

ASHRAE (2019). ANSI/ASHRAE 23.1 – Methods for performance testing positive displacement refrigerant compressors and condensing units that operate at sub-critical pressures of the refrigerant.

ASHRAE (2021). ANSI/ASHRAE 41.9 – Standard methods for refrigerant mass flow measurements using calorimeters.

Azamfar, M., Singh, J., Bravo-Imaz, I., e Lee, J. (2020). Multisensor data fusion for gearbox fault diagnosis using 2-d convolutional neural network and motor current signature analysis. *Mechanical Systems and Signal Processing*, 144, 106861. doi:10.1016/j.ymssp.2020.106861.

Cabrera, D., Guamán, A., Zhang, S., Cerrada, M., Sánchez, R.V., Cevallos, J., Long, J., e Li, C. (2020). Bayesian approach and time series dimensionality reduction to LSTM-based model-building for fault diagnosis of a reciprocating compressor. *Neurocomputing*, 380, 51–66. doi:10.1016/j.neucom.2019.11.006.

Ge, Z. (2017). Review on data-driven modeling and monitoring for plant-wide industrial processes. *Chemometrics and Intelligent Laboratory Systems*, 171, 16–25. doi:10.1016/j.chemolab.2017.09.021.

Hoerl, A.E. e Kennard, R.W. (1970). Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, 12(1), 55–67.

Ma, Y. e Huang, B. (2017). Bayesian learning for dynamic feature extraction with application in soft sensing. *IEEE*

Transactions on Industrial Electronics, 64(9), 7171–7180. doi:10.1109/tie.2017.2688970.

McKee, K.K., Forbes, G.L., Mazhar, I., Entwistle, R., Hodkiewicz, M., e Howard, I. (2015). A vibration cavitation sensitivity parameter based on spectral and statistical methods. *Expert Systems with Applications*, 42(1), 67–78. doi:10.1016/j.eswa.2014.07.029.

Murphy, K.P. (2012). *Machine learning: a probabilistic perspective*. MIT press.

Nascimento, A.S.B.d.S., Flesch, R.C.C., e Flesch, C.A. (2020). Data-driven soft sensor for the estimation of sound power levels of refrigeration compressors through vibration measurements. *IEEE Transactions on Industrial Electronics*, 67(8), 7065–7072. doi:10.1109/tie.2019.2941124.

Potočník, P. e Govekar, E. (2017). Semi-supervised vibration-based classification and condition monitoring of compressors. *Mechanical Systems and Signal Processing*, 93, 51–65. doi:10.1016/j.ymssp.2017.01.048.

Puth, M.T., Neuhäuser, M., e Ruxton, G.D. (2015). Effective use of spearman’s and kendall’s correlation coefficients for association between two measured traits. *Animal Behaviour*, 102, 77–84.

Rao, K.R., Kim, D.N., e Hwang, J.J. (2011). *Fast Fourier transform-algorithms and applications*. Springer Science & Business Media.

Samad, T. (2017). A survey on industry impact and challenges thereof [technical activities]. *IEEE Control Systems Magazine*, 37(1), 17–18. doi:10.1109/mcs.2016.2621438.

Sarkar, C., Rao, V.S., Prasad, R.V., Das, S.N., Misra, S., e Vasilakos, A. (2016). VSF: An energy-efficient sensing framework using virtual sensors. *IEEE Sensors Journal*, 16(12), 5046–5059. doi:10.1109/jсен.2016.2546839.

Tang, J., Qiao, J., Wu, Z., Chai, T., Zhang, J., e Yu, W. (2018). Vibration and acoustic frequency spectra for industrial process modeling using selective fusion multi-condition samples and multi-source features. *Mechanical Systems and Signal Processing*, 99, 142–168. doi:10.1016/j.ymssp.2017.06.008.

Yang, H.b., Zhang, J.a., Chen, L.l., Zhang, H.l., e Liu, S.l. (2019). Fault diagnosis of reciprocating compressor based on convolutional neural networks with multisource raw vibration signals. *Mathematical Problems in Engineering*, 2019, 1–7. doi:10.1155/2019/6921975.

Yin, S., Li, X., Gao, H., e Kaynak, O. (2015). Data-based techniques focused on modern industry: An overview. *IEEE Transactions on Industrial Electronics*, 62(1), 657–667. doi:10.1109/TIE.2014.2308133.

Zeng, X., Li, Z., Gao, W., Ren, M., Zhang, J., Li, Z., e Zhang, B. (2018). A novel virtual sensing with artificial neural network and k-means clustering for IGBT current measuring. *IEEE Transactions on Industrial Electronics*, 65(9), 7343–7352. doi:10.1109/tie.2018.2793196.