



XXX Congresso Nacional de Estudantes de Engenharia Mecânica
19 a 23 de agosto de 2024, Uberaba, Minas Gerais, Brasil

DESENVOLVIMENTO DE UMA FERRAMENTA DE DIAGNÓSTICO PARA SISTEMAS DE REFRIGERAÇÃO COMERCIAIS E INDUSTRIAIS UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Amanda Aparecida Alves Silva, silva.amanda@ufvjm.edu.br¹

Dimas José Rua Orozoco, dimas.rua@ufla.br²

Oswaldo José Venturini, osvaldo@unifei.edu.br³

José Ricardo Ferreira Oliveira, jose.ricardo@ufvjm.edu.br¹

Euler Guimarães Horta, euler.horta@ufvjm.edu.br¹

Tiago Mendes, tiago.mendes@ufvjm.edu.br¹

¹ Universidade Federal dos Vales do Jequitinhonha e Mucuri, Instituto de Ciência e Tecnologia. Rodovia MGT 367 – Km 583, 5000, Alto da Jacuba, Diamantina/MG, CEP 39100-000.

² Universidade Federal de Lavras, Departamento de Engenharia. Trevo Rotatório Professor Edmir Sá Santos, s/n, Lavras/MG, CEP 37203-202.

³ Universidade Federal de Itajubá, Instituto de Engenharia Mecânica. Av. BPS, 1303, Bairro Pinheirinho, Itajubá/ MG, CEP 37500 903.

Resumo. A utilização da Inteligência Artificial (IA) no diagnóstico de sistemas de refrigeração comerciais e industriais é uma ferramenta poderosa para melhorar seu desempenho e confiabilidade. Ao integrar dados operacionais em tempo real com técnicas de IA, é possível detectar degradações e falhas, contribuindo para o desempenho energético desses sistemas. Modelos matemáticos e computacionais são empregados para prever o comportamento dos sistemas em diferentes condições operacionais, permitindo o treinamento de algoritmos de IA para monitorá-los e identificar problemas. Isso não apenas auxilia na redução do consumo energético e na sustentabilidade, mas também na previsão de falhas e na integração com tecnologias como a Internet das Coisas (IoT) e automação. O trabalho proposto visa fornecer uma metodologia para monitorar e diagnosticar o desempenho dos sistemas de refrigeração.

Palavras-chave: Sistemas Térmicos. Refrigeração Industrial. Detecção de Falhas. Diagnóstico.

Abstract. The use of Artificial Intelligence (AI) in the diagnosis of commercial and industrial refrigeration systems is a powerful tool to improve their performance and reliability. By integrating real-time operational data with AI techniques, it is possible to detect degradations and failures, contributing to the energy performance of these systems. Mathematical and computational models are used to predict the behavior of systems under different operating conditions, allowing the training of AI algorithms to monitor them and identify problems. This not only helps reduce energy consumption and sustainability, but also predicts failures and integrates with technologies such as the Internet of Things (IoT) and automation. The proposed work aims to provide a methodology to monitor and diagnose the performance of refrigeration system.

Keywords: Thermal Systems. Industrial Refrigeration. Fault Detection. Diagnose.

1. INTRODUÇÃO

O diagnóstico para sistemas de refrigeração comerciais e industriais utilizando Inteligência Artificial (IA) é uma ferramenta poderosa para melhorar o desempenho e a confiabilidade desses sistemas. Ao combinar dados operacionais em tempo real com técnicas de IA, degradações e/ou falhas podem ser detectadas, contribuindo com o desempenho energético desses sistemas de refrigeração. Modelos matemáticos e computacionais têm sido utilizados para prever o comportamento e melhorar o desempenho de sistemas em geral. Os objetivos dessa modelagem, entre outros, é o de reproduzir corretamente o comportamento dos sistemas modelados em diferentes condições operacionais. Em posse desse comportamento, algoritmos baseados em IA podem ser treinados e utilizados para monitorar sistemas de refrigeração, com o objetivo de identificar a presença de degradações e/ou falhas em seus componentes. Em um contexto de transição energética, o diagnóstico para esses sistemas auxiliaria no seu monitoramento, reduzindo e otimizando o seu consumo

energético, tornando assim os mesmos mais sustentáveis. Como a generalização de uma IA treinada com os dados simulados de degradações e falhas, o sistema de diagnóstico desenvolvido será extremamente útil para os sistemas de refrigeração mencionados.

O desempenho para a previsão de várias estruturas de IA tem sido desenvolvido e explorado no meio acadêmico, comercial e industrial. Além do monitoramento em tempo real dos parâmetros operacionais de máquinas, equipamentos etc. têm sido atualmente explorado por diversos pesquisadores e investidores. Com modelos matemáticos e computacionais é possível representar inúmeras condições operacionais para os sistemas de refrigeração com e sem degradações e/ou falhas. Por fim, em posse dessas informações e por meio da IA é possível treinar um algoritmo que possa promover o diagnóstico desses sistemas identificando as eventuais degradações e/ou falhas.

Sensores conectados aos equipamentos de refrigeração podem coletar dados em tempo real e transmiti-los para os algoritmos de IA, que podem, por sua vez, ajustar automaticamente os parâmetros de acordo com as condições operacionais ideais. Essa abordagem traz benefícios significativos para a transição energética dos sistemas de refrigeração. Além de reduzir o impacto ambiental, ela aumenta a eficiência operacional, melhora a confiabilidade e prolonga a vida útil dos equipamentos. Os desempenhos de previsão de várias estruturas de IA, como redes neurais *feedforward*, redes neurais de função de base radial, inferência *neurofuzzy* adaptativa e redes neurais recorrentes, além do monitoramento em tempo real dos parâmetros operacionais dos ciclos de refrigeração, como temperatura, pressão, vazão de refrigerante e consumo de energia, estão incentivando o interesse de diversos pesquisadores (ADELEKAN et al, 2022, WIJAYA et al, 2022; CHEN et al, 2022; ZHUANG et al, 2023; WAHBA et al, 2023; GAO e WANG, 2023; LI et al, 2023).

Diante do exposto, o objetivo deste trabalho é o desenvolvido um sistema de diagnóstico para sistemas de refrigeração comerciais e industriais com base em modelos computacionais dos componentes desses sistemas e em IA. De modo específico, este projeto visa qualificar e quantificar os impactos das falhas no desempenho dos componentes e no sistema de refrigeração como um todo.

2. METODOLOGIA

O compressor modelado será do tipo alternativo aberto modelo 6F.2-K da Bitzer operando com HCFC-22, cuja a modelagem será baseada em Jankovi *et al.* (2016). Esse modelo de compressor possui um volume deslocado (V_{desl}) de $0,0508 \text{ m}^3/\text{s}$ a uma rotação (N) de 1750 RPM . Além de um rendimento mecânico (η_{mec}) de $0,81$ (Bitzer, 2018). Na Fig. 1 mostra-se uma representação esquemática do compressor em conjunto com seu motor elétrico de acionamento.

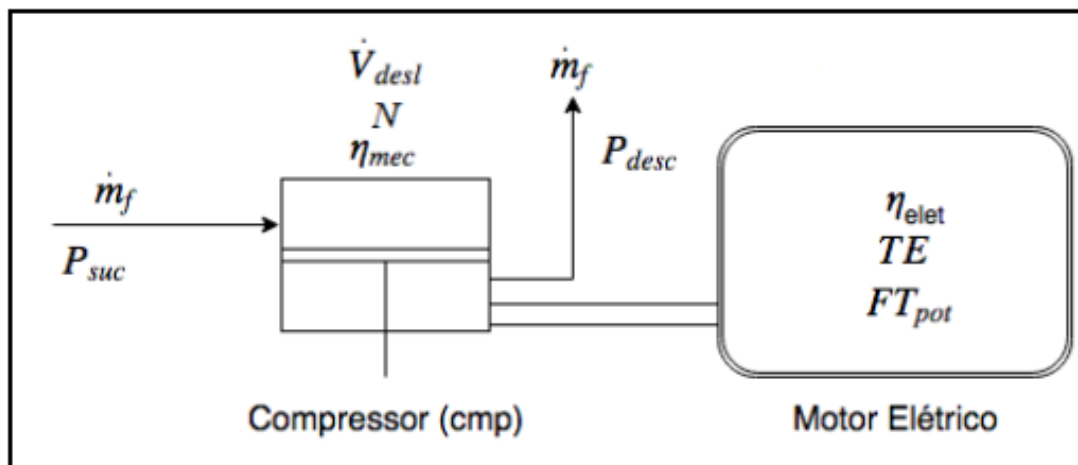


Figura 1. Representação esquemática do modelo matemático para o compressor.

Onde na Fig. 1, P_{desc} e P_{suc} são as pressões de descarga e sucção do compressor, respectivamente. O motor elétrico possui uma tensão elétrica (TE) nominal e fator de potência (FT_{pot}) de 380 Volts e $0,86$, respectivamente. Além de um rendimento elétrico (η_{elet}) de $0,97$. A vazão mássica de fluido refrigerante pode ser calculada pela Eq. (1), onde η_{vol} é o rendimento volumétrico e v_{fe} é o volume específico do fluido refrigerante na sucção do compressor. Esse rendimento é obtido em função da relação de pressão (Fig. 2). A relação de pressão (RP) é a razão entre a pressão de descarga e sucção do compressor, respectivamente.

$$\dot{m}_f = \frac{\eta_{vol} \cdot \dot{V}_{desl}}{v_{suc}} \quad (1)$$




Figura 2. Rendimento volumétrico x relação de pressão.

Os coeficientes da curva da Fig. 2 são obtidos através de um processo de regressão utilizando os dados de catálogo do compressor obtidos em Bitzer (2018). Para essa curva o coeficiente de determinação de regressão (R^2) foi de 0,99.

Utilizando o rendimento global (η_{global}), Eq. (2), composto pelo rendimento mecânico e isentrópico (η_{iso}) é possível determinar a potência de compressão real ($W_{cmp\ real}$) através da Eq. (3). Onde $W_{cmp\ iso}$ é a potência de compressão isentrópica.

$$\eta_{global} = \eta_{mec} \cdot \eta_{iso} \quad (2)$$

$$\dot{W}_{cmp\ real} = \frac{\dot{W}_{cmp\ iso}}{\eta_{global}} \quad (3)$$

O rendimento isentrópico é obtido também em função da relação de pressão (Fig. 3). Os coeficientes da curva da Fig. 3 são obtidos através de um processo de regressão utilizando os dados de catálogo do compressor obtidos em Bitzer (2018). Para essa curva o coeficiente de determinação de regressão (R^2) foi de 0,99.




Figura 3. Rendimento isentrópico x relação de pressão.

A potência elétrica consumida pelo compressor ($W_{comp\ elet}$) pode ser obtida pela Eq. (4) utilizando o rendimento elétrico (η_{elet}). A corrente elétrica consumida pelo motor de acionamento do compressor ($I_{comp\ elet}$) pode ser obtida pela Eq. (5).

Para o desenvolvimento de uma rede neural, são necessários diversos componentes e fatores, dentre eles podemos destacar os parâmetros de entrada e saída da rede, os quais devem ser fornecidos para o treinamento supervisionado, onde a rede receberá os dados de entrada e irá comparar a resposta obtida com os dados de saída, ou resposta desejada. Além disto, é necessário definir uma função de perda, que será responsável por comparar a resposta emitida com a desejada e mensurar o erro entre tais parâmetros, o qual será utilizado no algoritmo de *backpropagation* para cálculo de gradiente e ajuste dos pesos internos da rede. Outro parâmetro a ser definido é a arquitetura da rede, existem diversas arquiteturas propostas na literatura, cada uma recomendada, mas não exclusiva, para certas aplicações e finalidades. A arquitetura mais comum e inicialmente proposta é a *feedforward*, ou alimentação para frente (Silva *et al.*, 2019).

$$\dot{W}_{elet\ comp} = \frac{\dot{W}_{iso\ comp}}{\eta_{elet}\eta_{global}} \quad (4)$$

$$I_{comp\ elet} = \frac{\dot{W}_{comp\ elet}}{\sqrt{3} \cdot TE \cdot FT_{pot}} \quad (5)$$

O objetivo da rede aqui proposta, é prever parâmetros que não são normalmente medidos em compressores reais, desta forma, os parâmetros a serem estimados são: rendimento isentrópico, rendimento volumétrico, vazão de fluido refrigerante e temperatura de descarga do compressor. Dada a característica das respostas desejadas pela rede, trata-se então de um problema de regressão, uma vez que serão inseridos dados provenientes do modelo matemático os quais serão utilizados para estimar outros dados desejados. Sendo assim, para realizar tal previsão de parâmetros, a rede utilizará como atributos previsores as seguintes informações: pressão de descarga do compressor, pressão de sucção e corrente elétrica consumida. Tal escolha de parâmetros se dá pela facilidade de medição em um equipamento real, onde para se adquirir as pressões basta instalação de manômetros nos respectivos pontos, e para corrente basta um amperímetro ligado ao compressor. Em nível industrial, tais parâmetros são comumente monitorados, logo a rede proposta possui fácil implementação dada a natureza dos dados de entrada necessários.

Após a definição dos dados de entrada e saída da rede, foi escolhido a função de perda a ser utilizada, trata-se do percentual de erro médio absoluto (*Mean Absolute Percentage Error - MAPE*), o qual calcula um erro médio absoluto entre as respostas com base no percentual da diferença entre a resposta obtida e a desejada. Tal função é dada pela seguinte equação:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|d_i - y_i|}{d_i} \quad (6)$$

Onde n é o número de amostras, d_i é a resposta desejada da amostra i e y_i é a resposta emitida.




Figura 4. Arquitetura e organização da rede neural artificial.

Por fim, definiu-se a arquitetura da rede a ser desenvolvida, consistindo na arquitetura feedforward, organizada em 3 camadas, possuindo 3 neurônios na camada de entrada, 5 neurônios na camada oculta da rede, e por fim, 4 neurônios na camada de saída, sendo cada neurônio correspondente a um parâmetro de saída. Em uma rede neural, cada camada possui uma função de ativação em seus neurônios, a qual é responsável por transformar a informação recebida. Como se trata de uma rede para regressão, utilizou-se como função de ativação dos neurônios da camada de saída, a função linear a qual não aplica modificações além da multiplicação entre os pesos internos da rede e os valores de entrada das amostras. Para a camada escondida, foi utilizado a função tangente hiperbólica, a qual emite valores dentro do intervalo de -1 a 1. Desta forma, a Fig. 4 ilustra a arquitetura definida para a rede a ser desenvolvida.

Como base de dados foram utilizados os dados obtidos pelo modelo matemático e computacional do compressor. Posteriormente, os dados foram divididos entre amostras para treinamento da rede, e amostras para teste e validação das respostas. Tal prática é comum em RNAs para validar a capacidade de generalização obtida após o treinamento, uma vez que a rede não possui acesso aos dados de teste, logo não há ajuste prévio às respostas desejadas para este conjunto de dados (Kubat, 2017). A divisão foi realizada na proporção de 70% dos dados para treinamento da rede, 15% para validação do treinamento, e 15% para teste da precisão obtida na rede.

A alimentação dos dados na rede ocorreu após a normalização destes, isto é feito a fim de evitar problemas com variações muito grandes e instabilidades no ajuste de pesos da rede, uma vez que os parâmetros de entrada são muito grandes, ou muito pequenos, os pesos devem se ajustar proporcionalmente. Desta forma, é comum a normalização dos parâmetros de entrada para valores entre 0 e 1, ou -1 e 1, para evitar tais problemas. Com esta normalização aplicada, é necessário aplicar a desnormalização nas respostas emitidas para visualizar corretamente os dados de saída. A implementação da RNA foi feita utilizando o pacote de recursos NNET do Octave.

3. RESULTADOS E DISCUSSÃO

Foi possível criar um modelo matemático que represente de forma precisa o comportamento do compressor em sistemas de refrigeração, considerando as variáveis críticas. Verificando também a eficácia do modelo ao comparar os resultados obtidos com os dados fornecidos pelos catálogos de fabricantes, assegurando uma diferença média inferior a 1%, assim é possível através das análises dos resultados da modelagem, oferecer insights valiosos a engenheiros e projetistas de sistemas de refrigeração, visando a otimização do desempenho do compressor.

Com o objetivo de fundamentar o modelo, os seus resultados para o fluxo de calor removido (Q_{evp}) são comparados com o compressor 6F.2-K da Bitzer (Bitzer, 2018). O fluxo de calor removido é atingido no evaporador de um sistema de refrigeração operando com o compressor analisado. Essa operação é estabelecida para diferentes temperaturas de condensação (T_{cnd}) e evaporação (T_{evp}). O fluxo de calor removido diminui para o aumento e redução da temperatura de condensação e evaporação, respectivamente (Tab. 1). O modelo do compressor foi resolvido por meio de um script desenvolvido em MatLab® (Mathworks, 2013).

Tabela 1. Comparação entre os resultados para os fluxos de calor removido obtidos pelo modelo e do compressor 6F.2-K da Bitzer.

T_{evp}/T_{cnd} [°C]	Modelo [kW]	Bitzer [kW]	Diferença [%]	T_{evp}/T_{cnd} [°C]	Modelo [kW]	Bitzer [kW]	Diferença [%]
+10/30	198,528	198,518	-0,005	-25/40	42,110	41,573	-1,291
+5/30	167,026	166,638	-0,233	+10/50	162,551	164,218	1,015
0/30	139,398	138,763	-0,458	+5/50	135,543	137,035	1,088
-5/30	115,290	114,490	-0,699	0/50	111,986	113,351	1,205
-10/30	94,379	93,479	-0,963	-5/50	91,580	92,810	1,325
-15/30	76,375	75,425	-1,260	-10/50	74,063	75,119	1,406
-20/30	61,017	60,044	-1,621	-15/50	59,201	60,015	1,356
-25/30	48,074	47,058	-2,159	-20/50	46,799	47,246	0,947
+10/40	180,743	180,968	0,125	-25/50	36,697	36,562	-0,371
+5/40	151,427	151,485	0,038	Diferença Média [%]		-0,075	
0/40	125,774	125,738	-0,028				
-5/40	103,455	103,352	-0,100				
-10/40	84,177	84,018	-0,189				
-15/40	67,675	67,454	-0,328				
-20/40	53,719	53,393	-0,610				

Quanto a rede neural, foram treinadas 10 redes e calculado o MAPE de cada uma utilizando as saídas das redes calculadas para o conjunto de teste. Na Tab. 2 é apresentado o MAPE médio para cada saída da rede calculado a partir da média das 10 redes treinadas. Após o treinamento da rede, obteve-se um MAPE inferior a 1 nas amostras de teste, isto significa que nas amostras nunca vistas antes pela rede, obteve-se um erro máximo inferior a 1% nas previsões realizadas

pela mesma. Com isso pode-se admitir que a rede obteve boa capacidade de generalização dada a função de perda utilizada, se tornando assim um bom modelo para previsão dos parâmetros de interesse.

Tabela 2. Média do erro emitido pelas 10 redes treinadas.

PARÂMETRO DE SAÍDA	MAPE MÉDIO
Rendimento Volumétrico (%)	0,236
Rendimento Isentrópico (%)	0,107
Vazão Mássica de Fluido Refrigerante (%)	0,652
Temperatura de Descarga (%)	0,243

4. CONCLUSÃO

A integração da modelagem matemática de um compressor aberto a pistão com o poder da inteligência artificial oferece uma abordagem inovadora e promissora para aprimorar a eficiência dos sistemas de refrigeração. A modelagem matemática computacional do compressor é uma ferramenta essencial para a eficiência e a confiabilidade dos sistemas de refrigeração. Além de promover a transição energética, a abordagem baseada em dados de catálogos de fabricantes possibilita a análise detalhada do desempenho em diversas condições operacionais, fornecendo informações cruciais para decisões informadas no projeto e operação do sistema. Esta técnica não apenas reduz o consumo de energia e os custos operacionais, mas também fomenta uma abordagem sustentável e econômica para o resfriamento e condicionamento, impactando positivamente no cenário atual de transição energética no Brasil e no mundo.

Neste estudo, demonstramos como é possível utilizar dados facilmente mensuráveis, como corrente e pressão, para prever parâmetros críticos não diretamente observáveis, como o rendimento volumétrico e isentrópico, vazão mássica de fluido refrigerante e temperatura de descarga. Os resultados obtidos revelam a eficácia da rede neural artificial em realizar essas previsões com precisão satisfatória, e também evidenciam a importância da modelagem matemática como base sólida para o treinamento de algoritmos de aprendizado de máquina. Essa abordagem oferece uma compreensão mais profunda do comportamento do compressor, e permite a otimização contínua de seu desempenho. Além disso, ao considerar o contexto mais amplo da sustentabilidade e transição energética, essa metodologia adquire uma relevância ainda maior. A capacidade de prever e controlar eficientemente os parâmetros operacionais do compressor contribui para a redução do consumo de energia e dos impactos ambientais associados, promove também a integração de tecnologias mais limpas e eficientes nos sistemas de refrigeração. Portanto, esta pesquisa não apenas avança nosso entendimento sobre o funcionamento dos compressores e sua otimização, mas também destaca o potencial da inteligência artificial como uma ferramenta poderosa para impulsionar a sustentabilidade e facilitar a transição para uma economia de baixo carbono.

5. AGRADECIMENTOS

Os autores gostariam de agradecer ao Programa Institucional de Bolsas de Iniciação Científica da Universidade Federal dos Vales do Jequitinhonha e Mucuri (PIBIC/ UFVJM), pela concessão de bolsa de Iniciação Científica à autora Amanda Aparecida Alves Silva. Os autores também gostariam de agradecer à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), pelo apoio financeiro concedido através da CHAMADA 13/2023 - PARTICIPAÇÃO COLETIVA EM EVENTOS DE CARÁTER TÉCNICO-CIENTÍFICO NO PAÍS.

6. REFERÊNCIAS

- Adelekan, D.S., Ohunakin, O. S., Paul, B.S. Artificial intelligence models for refrigeration, air conditioning and heat pump systems, *Energy Reports*, Volume 8, 2022, Pages 8451-8466, ISSN 2352-4847, <https://doi.org/10.1016/j.egyr.2022.06.062>.
- Bitzer, 2018. Bitzer. Retrieved from Bitzer.
- Chen, Y., Wen, J. O. Pradhan, L. James Lo, T. Wu, Using discrete Bayesian networks for diagnosing and isolating cross-level faults in HVAC systems, *Applied Energy*, Volume 327, 2022, 120050, ISSN 0306-2619, <https://doi.org/10.1016/j.apenergy.2022.120050>.
- Gao, C., Wang, D. Comparative study of model-based and model-free reinforcement learning control performance in HVAC systems, *Journal of Building Engineering*, Volume 74, 2023, 106852, ISSN 2352-7102, <https://doi.org/10.1016/j.jobee.2023.106852>.
- Kubat, M., 2017. "An Introduction to Machine Learning". 2ed. Ed. Springer, Coral Gables, FL, USA.
- Li, S., Zhang, J., Hou, J., Zhang, B., Yang, L., Zheng, M. Multi-objective optimization of pressure regulators in buildings' HVAC systems, *Journal of Building Engineering*, Volume 76, 2023, 107260, ISSN 2352-7102, <https://doi.org/10.1016/j.jobee.2023.107260>.
- Mathworks, 2013. Mathworks. Retrieved from Mathworks.

- Silva, I.N., Spatti, D.H. e Flauzino, R.A., 2019. “Redes Neurais Artificiais para Engenharia e Ciências Aplicadas”. 2 ed. Ed. Artliber, São Paulo, Brasil.
- Wahba, N. Rismanchi, B., Pu, Y., Aye, L. Efficient HVAC system identification using Koopman operator and machine learning for thermal comfort optimisation, *Building and Environment*, Volume 242, 2023, 110567, ISSN 0360-1323, <https://doi.org/10.1016/j.buildenv.2023.110567>.
- Wijaya, T.K., Sholahudin, Alhamid, M.I., Saito, K., Nasruddin, N. Dynamic optimization of chilled water pump operation to reduce HVAC energy consumption, *Thermal Science and Engineering Progress*, Volume 36, 2022, 101512, ISSN 2451-9049, <https://doi.org/10.1016/j.tsep.2022.101512>.
- Zhuang, D., Gan, V.J.L., Tekler, Z.D., Chong, A., Tian, S., Shi, X. Data-driven predictive control for smart HVAC system in IoT-integrated buildings with time-series forecasting and reinforcement learning, *Applied Energy*, Volume 338, 2023, 120936, ISSN 0306-2619, <https://doi.org/10.1016/j.apenergy.2023.120936>.

7. RESPONSABILIDADE PELAS INFORMAÇÕES

Os autores são os únicos responsáveis pelas informações incluídas neste trabalho.