

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA

JOÃO VICTOR SARAIVA

OTIMIZAÇÃO DO COEFICIENTE DE PERFORMANCE EM SISTEMAS DE
REFRIGERAÇÃO UTILIZANDO O ALGORITMO SIMULATED ANNEALING
ASSISTIDO POR REDES NEURAIS ARTIFICIAIS

Uberlândia

2026

JOÃO VICTOR SARAIVA

OTIMIZAÇÃO DO COEFICIENTE DE PERFORMANCE EM SISTEMAS DE
REFRIGERAÇÃO UTILIZANDO O ALGORITMO SIMULATED ANNEALING
ASSISTIDO POR REDES NEURAIS ARTIFICIAIS

Trabalho de Conclusão de Curso ou
Dissertação ou Tese apresentado à Faculdade
de Engenharia Mecânica da Universidade
Federal de Uberlândia como requisito parcial
para obtenção do título de bacharel em
Engenharia Mecânica.

Orientador: Gleyzer Martins

Uberlândia

2026

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

S243
2026

Saraiva, João Victor, 2001-
Otimização do coeficiente de performance em sistemas de
refrigeração utilizando o algoritmo simulated annealing assistido
por redes neurais artificiais [recurso eletrônico] / João Victor
Saraiva. - 2026.

Orientador: Gleyzer Martins.

Trabalho de Conclusão de Curso (graduação) - Universidade
Federal de Uberlândia, Graduação em Engenharia Mecânica.

Modo de acesso: Internet.

Inclui bibliografia.

1. Engenharia mecânica. I. Martins, Gleyzer, 1978-, (Orient.). II.
Universidade Federal de Uberlândia. Graduação em Engenharia
Mecânica. III. Título.

CDU: 621

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091

Nelson Marcos Ferreira - CRB6/3074

JOÃO VICTOR SARAIVA

OTIMIZAÇÃO DO COEFICIENTE DE PERFORMANCE EM SISTEMAS DE
REFRIGERAÇÃO UTILIZANDO O ALGORITMO SIMULATED ANNEALING
ASSISTIDO POR REDES NEURAIS ARTIFICIAIS

Trabalho de Conclusão de Curso ou
Dissertação ou Tese apresentado à Faculdade
de Engenharia Mecânica da Universidade
Federal de Uberlândia como requisito parcial
para obtenção do título de bacharel em
Engenharia Mecânica.

Uberlândia, 2026

Banca Examinadora:

Prof. Dr. João Rodrigo Andrade (FEMEC-UFU)

Prof. Dr. Arthur Heleno Pontes Antunes (FEMEC-UFU)

AGRADECIMENTOS

Agradeço a Deus, pela saúde e força para concluir esta etapa.

Aos meus pais e familiares, pelo apoio incondicional e pela paciência ao longo de toda a graduação.

À minha companheira, pelo incentivo constante e pela compreensão nos momentos de maior dedicação a este trabalho.

Ao meu orientador, pela disponibilidade, pelos direcionamentos e pelo conhecimento compartilhado durante o desenvolvimento deste trabalho.

Aos professores e colegas do curso, pela troca de experiências e pelo aprendizado construído ao longo desses anos.

À Universidade Federal de Uberlândia, pela estrutura, pelo ensino público e de qualidade e pelas oportunidades que tornaram possível esta formação.

A todos que, de alguma forma, contribuíram para a realização deste trabalho, meu sincero agradecimento.

“A imaginação é mais importante que o conhecimento, porque o conhecimento é limitado, ao passo que a imaginação abrange o mundo inteiro.”

(EINSTEIN, 1929, p. 117)

RESUMO

A crescente demanda por eficiência energética em sistemas de refrigeração, aliada à necessidade urgente de substituição de fluidos refrigerantes sintéticos por alternativas naturais de menor impacto ambiental, incentiva a necessidade do desenvolvimento de novos métodos de otimização. O propano (R290), hidrocarboneto com potencial de aquecimento global unitário e excelentes propriedades termodinâmicas, representa uma alternativa promissora aos refrigerantes convencionais, porém sua operação em condições de máxima eficiência exige ferramentas capazes de capturar e interpretar de algum modo, mesmo que aproximado, a complexidade e a não linearidade existente nos ciclos de refrigeração reais. Nesse contexto, o presente trabalho propõe e valida uma metodologia híbrida original baseada no algoritmo metaheurístico Simulated Annealing assistido por Redes Neurais Artificiais para a maximização do Coeficiente de Performance em uma bancada experimental de refrigeração operando com R290. Os dados experimentais, compostos por mais de 12.000 registros obtidos sob múltiplas condições de operação da bancada instrumentada, considerando variações na temperatura de evaporação, condensação e porcentagem de abertura da válvula de expansão eletrônica. O Coeficiente de Performance de cada ponto operacional foi calculado rigorosamente a partir de balanços de entalpia nos processos de compressão, condensação e expansão isentálpica, utilizando propriedades termodinâmicas precisas do R290 obtidas pela biblioteca Coolprop. Esses dados alimentaram o treinamento de uma rede neural de arquitetura MLP (Multilayer Perceptron), capaz de mapear simultaneamente as variáveis de entrada para quatro saídas — Coeficiente de Performance, temperatura de condensação, temperatura de evaporação e abertura de válvula — atingindo erro quadrático médio inferior a 0,003 no conjunto de teste, o que evidencia a elevada capacidade preditiva do modelo. O algoritmo Simulated Annealing foi então aplicado sobre o espaço de busca delimitado pelos limites reais dos dados experimentais, utilizando a rede neural treinada como substituto computacional do sistema físico, eliminando a necessidade de modelos analíticos durante a otimização, reduzindo drasticamente o custo computacional sem comprometer a fidelidade do comportamento não linear, visto que o modelo de aprendizado de máquina procura incorporar implicitamente as irreversibilidades e não linearidades do sistema real. Os resultados demonstraram que a abordagem híbrida proposta é capaz de identificar condições operacionais ótimas locais de forma eficiente, robusta e reprodutível, consolidando-se como contribuição relevante para o campo da otimização energética de sistemas de refrigeração.

Palavras-chave: Refrigeração, Otimização, Metaheurística, R290, COP.

ABSTRACT

The growing demand for energy efficiency in refrigeration systems, combined with the urgent need to replace synthetic refrigerants with lower-environmental-impact natural alternatives, drives the need to develop new optimization methods. Propane (R290), a hydrocarbon with a unitary global warming potential and excellent thermodynamic properties, represents a promising alternative to conventional refrigerants. However, its operation under maximum-efficiency conditions requires tools capable of capturing and interpreting, even if approximately, the complexity and nonlinearity present in real refrigeration cycles. In this context, the present work proposes and validates an original hybrid methodology based on the Simulated Annealing metaheuristic algorithm assisted by Artificial Neural Networks to maximize the Coefficient of Performance in an experimental refrigeration bench operating with R290. The experimental data, comprising more than 12,000 records obtained under multiple operating conditions of the instrumented bench, cover suction and discharge pressures, temperatures at the four thermodynamic points of the cycle, and the opening percentage of the electronic expansion valve. The Coefficient of Performance for each operating point was rigorously calculated from enthalpy balances across the compression, condensation, and isenthalpic expansion processes, using precise thermodynamic properties of R290 obtained through the CoolProp library. These data were used to train a Multilayer Perceptron (MLP) neural network architecture capable of simultaneously mapping the input variables to four outputs — Coefficient of Performance, condensation temperature, evaporation temperature, and valve opening — achieving a mean squared error below 0.003 on the test set, which demonstrates the model's high predictive capability. The Simulated Annealing algorithm was then applied over the search space delimited by the real boundaries of the experimental data, using the trained neural network as a computational surrogate for the physical system. This eliminated the need for analytical models during optimization, drastically reducing computational cost without compromising fidelity to the nonlinear behavior, since the machine learning model implicitly incorporates the irreversibilities and nonlinearities of the real system. The results demonstrated that the proposed hybrid approach is capable of efficiently, robustly, and reproducibly identifying locally optimal operating conditions, establishing itself as a relevant contribution to the field of energy optimization in refrigeration systems.

Keywords: Refrigeration, Optimization, Metaheuristics, R290, COP.

LISTA DE ILUSTRAÇÕES

Imagem 1 - Diagrama P-h do ciclo de refrigeração por compressão a vapor.....	14
Imagem 2 - Fluxograma do algoritmo Simulated Annealing.....	17
Imagem 3 - Bancada experimental de refrigeração operando com R290.....	19
Imagem 4 - Arquitetura da rede neural utilizada.....	22

LISTA DE TABELAS

Tabela 1 -	Estrutura do conjunto de dados experimentais.....	19
Tabela 2 -	Evolução do Erro Quadrático Médio durante o treinamento.....	24

LISTA DE ABREVIATURAS E SIGLAS

ASHRAE	American Society of Heating, Refrigerating and Air-Conditioning Engineers
COP	Coefficiente de Performance
MSE	Mean Squared Error (Erro Quadrático Médio)
P-h	Pressão-Entalpia
ReLU	Rectified Linear Unit
VEE	Válvula de Expansão Eletrônica
MLP	Multilayer Perceptron

SUMÁRIO

1	INTRODUÇÃO.....	12
2	REVISÃO BIBLIOGRÁFICA.....	13
2.1	Ciclo de Refrigeração por Compressão de Vapor.....	13
2.2	O Refrigerante R290 e Suas Propriedades	14
2.3	Redes Neurais Artificiais.....	15
2.4	Algoritmo Simulated Annealing.....	16
3	METODOLOGIA.....	18
3.1	Descrição da Bancada Experimental.....	18
3.2	Aquisição e tratamento de dados.....	20
3.3	Cálculo do COP via Propriedades Termodinâmicas.....	21
4	RESULTADOS E DISCUSSÃO	25
4.1	Desempenho do Modelo Preditivo.....	25
4.2	Convergência do Simulated Annealing.....	25
4.3	Condições Ótimas de Operação Encontradas	26
5	CONCLUSÃO.....	27

1 INTRODUÇÃO

O aumento da eficiência energética em sistemas de refrigeração representa um dos desafios centrais da engenharia atualmente, impulsionado tanto pelo crescimento contínuo da demanda por condicionamento térmico em escala global quanto pelas metas internacionais de redução de emissões de gases de efeito estufa (RTOC, 2023). Nesse cenário, a escolha do fluido refrigerante assume papel estratégico: os refrigerantes sintéticos amplamente utilizados, como o R410A e o R22, apresentam elevado Potencial de Aquecimento Global, tornando sua substituição progressiva uma necessidade regulatória e ambiental inadiável (United Nations, 1987; RTOC, 2023). O propano (R290), hidrocarboneto natural com Potencial de Aquecimento Global unitário e excelentes propriedades de transferência de calor, desponta como alternativa tecnicamente viável e ambientalmente responsável, sendo objeto crescente de investigação científica (Ibrahim et al., 2024; Bani Issa, 2025).

A maximização do Coeficiente de Performance (COP) é o principal indicador de eficiência em sistemas de refrigeração por compressão de vapor, expressando a relação entre o efeito frigorífico produzido e o trabalho consumido pelo compressor. A obtenção do COP máximo depende do ajuste simultâneo de múltiplas variáveis operacionais interdependentes — pressões e temperaturas em diferentes pontos dos ciclo, variando com o tempo, equipamentos e dentre outros fatores — cuja otimização por métodos analíticos tradicionais é dificultada pela não linearidade e pelas irreversibilidades inerentes aos sistemas reais (Stoecker, 1998). Abordagens baseadas em modelos físicos, embora precisas em condições ideais, exigem parametrizações extensas e frequentemente falham em representar fielmente o comportamento dinâmico de bancadas experimentais sujeitas a perturbações e variações de carga (Bejan, 2016).

O advento das técnicas de aprendizado de máquina abriu novas perspectivas para a modelagem de sistemas termodinâmicos complexos (Goodfellow et al., 2016). Redes Neurais Artificiais têm demonstrado capacidade superior na aproximação de funções não lineares a partir de dados experimentais, dispensando hipóteses simplificadoras e incorporando implicitamente os efeitos de irreversibilidade do sistema real. Quando combinadas a algoritmos de otimização metaheurística, como o Simulated Annealing - inspirado no processo físico de recozimento de metais e reconhecido por sua robustez na exploração de espaços de busca não convexos (Kirkpatrick et al., 1983; Bertsimas and Tsitsiklis, 1993; Delahaye et al., 2019) -, essas abordagens permitem identificar condições ótimas de operação de forma eficiente e sem dependência de modelos analíticos explícitos.

O presente trabalho propõe e valida experimentalmente uma metodologia híbrida baseada em Simulated Annealing assistido por Redes Neurais Artificiais para a otimização do COP em uma bancada experimental de refrigeração operando com R290. A rede neural, treinada sobre mais de 12.000 registros experimentais, atua como substituto computacional do sistema físico, representando o comportamento da bancada em diferentes configurações, sem a necessidade de reajuste manual e a espera de convergência do comportamento para a coleta de dados, enquanto o Simulated Annealing explora o espaço de operação em busca das condições de máxima eficiência simulando ajustes na bancada com o uso da rede neural. A abordagem resultou em um COP ótimo de 3,4, obtido de forma eficiente e reprodutível dentro dos limites reais de operação da bancada. Os resultados evidenciam o potencial da metodologia proposta como ferramenta de suporte à operação e ao projeto de sistemas de refrigeração de próxima geração, contribuindo para o avanço do estado da arte na interseção entre aprendizado de máquina, algoritmos metaheurísticos e engenharia térmica

2 REVISÃO BIBLIOGRÁFICA

2.1 Ciclo de Refrigeração por Compressão de Vapor


O ciclo de refrigeração por compressão de vapor é o princípio termodinâmico mais amplamente empregado em sistemas de condicionamento térmico, respondendo por mais de 90% das aplicações industriais e comerciais de refrigeração no mundo (Dossat, 2002). Seu funcionamento baseia-se na exploração das mudanças de fase de um fluido refrigerante ao longo de quatro processos termodinâmicos sequenciais: compressão, condensação, expansão e evaporação. A repetição cíclica desses processos permite a transferência contínua de energia térmica de uma fonte fria para uma fonte quente, contrariando o fluxo espontâneo de calor mediante o fornecimento de trabalho mecânico ao compressor (Çengel et al., 2023).

No processo de compressão, o fluido refrigerante no estado de vapor superaquecido é submetido a um aumento de pressão e temperatura pelo compressor, passando do nível de pressão baixa para o nível de pressão alta do ciclo. Em seguida, no condensador, o vapor de alta pressão rejeita calor para o meio externo, condensando-se progressivamente até atingir o estado líquido sub-resfriado. A expansão ocorre na válvula de expansão eletrônica, processo de natureza isentálpica no qual a pressão e a temperatura do fluido são reduzidas abruptamente, gerando uma mistura bifásica de baixa entalpia. Por fim, no evaporador, essa mistura absorve

calor do ambiente a ser refrigerado, evaporando-se completamente e retornando ao compressor como vapor superaquecido, encerrando o ciclo (Dossat, 2002).

O Coeficiente de Performance do ciclo é definido pela razão entre o efeito frigorífico produzido no evaporador e a potência líquida consumido pelo compressor, sendo calculado a partir das entalpias específicas nos pontos termodinâmicos do ciclo. Em sistemas reais, o COP é significativamente inferior ao limite teórico de Carnot em virtude das irreversibilidades associadas à transferência de calor com gradiente de temperatura finito, às perdas por atrito no compressor e às quedas de pressão nas linhas de refrigeração (Çengel et al., 2023). A representação gráfica do ciclo no diagrama Pressão-Entalpia (P-h), ilustrada na Imagem 1, é a ferramenta analítica padrão para a visualização e quantificação dos processos termodinâmicos envolvidos, permitindo a identificação imediata dos pontos de operação e o cálculo direto das grandezas de interesse a partir das propriedades do fluido (Çengel et al., 2023; Stoecker, 1998).

Imagem 1 – Diagrama P-h do ciclo de refrigeração por compressão a vapor



Fonte: Autor, 2026.

2.2 O Refrigerante R290 e Suas Propriedades

O propano, designado comercialmente como R290, é um hidrocarboneto pertencente ao grupo dos refrigerantes naturais, caracterizado por Potencial de Aquecimento Global unitário e Potencial de Destruição da Camada de Ozônio nulo (Ibrahim et al., 2024). Essas características ambientais, combinadas com disponibilidade natural abundante e baixo custo de produção, posicionam o R290 como um dos principais candidatos à substituição dos

refrigerantes sintéticos halogenados no contexto das regulamentações internacionais estabelecidas pelo Protocolo de Montreal e pelo Acordo de Kigali (United Nations, 1987).

Do ponto de vista termodinâmico, o R290 apresenta propriedades altamente favoráveis para aplicações de refrigeração. Seu calor latente de vaporização é significativamente superior ao do R410A em condições equivalentes de operação, resultando em menor vazão mássica necessária para a mesma capacidade frigorífica e, conseqüentemente, em menor consumo energético do compressor (Bolaji, 2010). Estudos recentes demonstram que sistemas com R290 podem atingir eficiências entre 10% e 20% superiores às de sistemas equivalentes operando com R410A sob as mesmas condições de carga térmica (Khai et al., 2025; Liang et al., 2025; Ibrahim et al., 2024).

A principal limitação do R290 reside em sua inflamabilidade, classificada como A3 pela norma ASHRAE 34 (ASHRAE, 2022), o que impõe restrições regulatórias quanto à carga máxima permitida em ambientes ocupados e demanda cuidados específicos no projeto e na manutenção dos sistemas. No contexto de bancadas experimentais laboratoriais, essas restrições são gerenciáveis mediante a adoção de medidas de segurança adequadas, incluindo ventilação forçada, detectores de gás e limitação da carga de refrigerante. A tendência regulatória global aponta para a ampliação progressiva dos limites de carga permitidos para hidrocarbonetos, à medida que as tecnologias de segurança se consolidam e os benefícios ambientais tornam-se cada vez mais determinantes nas decisões de projeto (RTOC, 2023).

2.3 Redes Neurais Artificiais

As Redes Neurais Artificiais são modelos computacionais inspirados na arquitetura do sistema nervoso biológico, compostos por unidades de processamento simples — os neurônios artificiais — organizados em camadas interconectadas por parâmetros ajustáveis denominados pesos sinápticos (Haykin, 1999). A capacidade dessas estruturas de aproximar funções arbitrariamente complexas a partir de dados, sem a necessidade de formulação analítica, as torna ferramentas particularmente adequadas para a modelagem de sistemas físicos com comportamento não linear e multivariado, ao custo da alta abstração imposta pelos cálculos, impossibilitando análise comportamental da rede neural (Hornik et al., 1989). No campo da engenharia térmica, aplicações de Redes Neurais Artificiais para predição de desempenho de sistemas de refrigeração têm demonstrado resultados consistentemente superiores aos de modelos de regressão polinomial e comparáveis aos de modelos físicos detalhados, com a

vantagem de não exigirem parametrizações extensas nem hipóteses simplificadoras (Zhang et al., 2018).

A arquitetura de rede neural empregada no presente trabalho é do tipo feedforward totalmente conectada, também denominada Multilayer Perceptron, na qual os sinais de entrada propagam-se sequencialmente da camada de entrada para as camadas ocultas e, por fim, para a camada de saída, sem conexões recorrentes. Cada neurônio de uma camada oculta computa uma combinação linear ponderada de suas entradas, à qual é aplicada uma função de ativação não linear — no presente caso, a função Rectified Linear Unit (ReLU) — que introduz a capacidade de representação de relações não lineares entre as variáveis (Goodfellow et al., 2016). O processo de treinamento consiste no ajuste iterativo dos pesos sinápticos por meio do algoritmo de retropropagação do erro combinado ao otimizador Adam, minimizando uma função de custo definida como o Erro Quadrático Médio entre as saídas previstas pela rede e os valores reais observados no conjunto de treinamento (Kingma and Ba, 2014).

A generalização do modelo é garantida pela divisão do conjunto de dados em partições de treinamento, validação e teste, pelo monitoramento da perda de validação ao longo das épocas e pela interrupção antecipada do processo quando sinais de sobreajuste são detectados (Goodfellow et al., 2016). A técnica de Dropout, que desativa aleatoriamente uma fração dos neurônios em cada iteração de treinamento, é adicionalmente empregada como mecanismo de regularização, promovendo a robustez do modelo frente a variações nos dados de entrada e reduzindo a sensibilidade a ruídos experimentais presentes na bancada (Srivastava et al., 2014).

2.4 Algoritmo Simulated Annealing


O Simulated Annealing é um algoritmo de otimização metaheurística inspirado no processo físico de recozimento de materiais, no qual um sólido aquecido é resfriado lentamente até atingir um estado de mínima energia livre (Bertsimas and Tsitsiklis, 1993; Delahaye et al., 2019). Proposto originalmente por Kirkpatrick et al. (1983), o algoritmo é amplamente reconhecido por sua robustez na exploração de espaços de busca não convexos, multimodais e de alta dimensionalidade, características comuns em problemas de otimização de sistemas termodinâmicos reais. O funcionamento do algoritmo é governado por um parâmetro denominado temperatura, que controla a probabilidade de aceitação de soluções piores que a atual. No início da busca, a temperatura elevada permite ampla exploração do espaço de soluções. À medida que o algoritmo progride, a temperatura é reduzida gradualmente segundo uma função de resfriamento geométrica, concentrando a busca nas regiões mais promissoras.

A probabilidade de aceitação de uma solução pior segue a distribuição de Boltzmann (Bertsimas and Tsitsiklis, 1993; Delahaye et al., 2019), expressa por:

$$P = \exp\left(\frac{\Delta COP}{T}\right)$$

Onde: P é a probabilidade de aceitação de uma solução pior; ΔCOP é a variação do COP entre a solução candidata e a solução atual, e T é a temperatura do sistema no instante da avaliação. O fluxograma do algoritmo é apresentado na Imagem 2.

Imagem 2 – Fluxograma do algoritmo Simulated Annealing



3 METODOLOGIA


3.1 Descrição da Bancada Experimental

A bancada experimental utilizada neste trabalho consiste em um sistema de refrigeração por compressão de vapor em circuito fechado, operando com o refrigerante natural R290 (Propano). Trata-se de um ciclo simples projetado para simular o comportamento de sistemas de refrigeração para resfriamento (não para congelamento). O sistema é composto por compressor hermético alternativo de velocidade fixa (Tecumseh, AE4435U-AA1A), com deslocamento volumétrico de 9,33 cm³ /rev e óleo lubrificante do tipo polioléster (POE), trocadores de calor de placas brasadas (Brahex) com 20 placas no evaporador e 40 placas no condensador, e Válvula de Expansão Eletrônica (VEE) da CAREL, modelo E2V05BS, com controle de superaquecimento via algoritmo PID.

A bancada encontra-se instalada em ambiente climatizado com temperatura média de aproximadamente 24°C, mantida por sistema de ar condicionado. A unidade evaporadora foi isolada termicamente durante os experimentos, de forma a minimizar a influência da temperatura ambiente e garantir que o efeito frigorífico fosse medido de forma controlada. Essa condição de isolamento térmico foi considerada na análise dos dados experimentais e na modelagem computacional.

A instrumentação da bancada inclui sensores de pressão absoluta instalados nas linhas de sucção e descarga do compressor, bem como sensores de temperatura posicionados nos pontos termodinâmicos fundamentais do ciclo - sucção e descarga do compressor, saída do condensador e saída do evaporador - bem como sensores adicionais de pressão, vazão e temperatura nas linhas de água do evaporador e do condensador, tensão, corrente e potência do compressor, conforme ilustrado na Imagem 3 abaixo.

Imagem 3 – Bancada experimental de refrigeração operando com R290.



Fonte: Autor, 2026.

A faixa da temperatura de evaporação considerada nos testes variou de $-2,5^{\circ}\text{C}$ a $2,5^{\circ}\text{C}$, para a temperatura de condensação variou de $25,5^{\circ}\text{C}$ a $30,4^{\circ}\text{C}$ e a abertura da válvulo variou de 50% a 57,5%. A aquisição das variáveis operacionais é realizada por sistema supervisório com frequência de amostragem de 1 Hz, garantindo resolução temporal suficiente para capturar as dinâmicas transitórias do sistema.

Para garantir a repetibilidade dos experimentos, a bancada foi operada em regime estacionário, sendo considerados válidos apenas os dados coletados após estabilização térmica e de pressão, definida por variações inferiores a 1% nas grandezas monitoradas ao longo de uma janela de 60 segundos.

Os dados foram adquiridos seguindo a busca por otimização pelo método simplex, procurando diminuir o tempo de aquisição de dados no amplo espaço de busca possível, garantindo assim a amplitude e a faixa de variável dos dados fornecidos anteriormente.

3.2 Aquisição e tratamento de dados

O conjunto de dados utilizado neste estudo é composto por 12.487 registros experimentais obtidos sob diferentes condições de operação da bancada, abrangendo ampla faixa de pressões, temperaturas e aberturas da válvula de expansão. A estrutura do conjunto de dados é apresentada na Tabela 1, onde são exibidas as variáveis registradas e algumas amostras representativas.

Tabela 1 – Estrutura do conjunto de dados experimentais

Pb (bar)	Pa (bar)	Tsc (°C)	Tdc (°C)	Toc (°C)	Toe (°C)	Tc (°C)	Te (°C)	AV (-)
1,750	10,521	3,444	70,902	21,631	0,344	30,0	1,3	0,5
1,751	10,522	3,446	70,926	21,634	0,340	30,0	1,3	0,5
1,752	10,522	3,446	70,926	21,634	0,340	30,0	1,3	0,5
1,750	10,518	3,450	70,954	21,636	0,337	30,0	1,3	0,5
...	...	...	...	...	...	...	...	...

Fonte: Autor, 2026.

Sendo: Pb: pressão baixa na sucção do compressor; Pa: pressão alta na entrada da válvula de expansão; Tsc: temperatura de sucção do compressor; Tdc: temperatura de descarga do compressor; Toc: temperatura de saída do condensador; Toe: temperatura de saída do evaporador; Tc: temperatura de condensação; Te: temperatura de evaporação; AV : percentual de abertura da válvula.

Inicialmente, os dados brutos foram submetidos a um processo de pré-processamento com a normalização das variáveis de entrada para o intervalo [0,1], visando melhorar a estabilidade do treinamento da rede neural.

Adicionalmente, foram descartados registros correspondentes a regimes transientes, garantindo que apenas estados próximos ao regime permanente fossem considerados. Esse procedimento é fundamental para assegurar a consistência termodinâmica dos cálculos de entalpia e, conseqüentemente, do Coeficiente de Performance, evitando também a não-convergência do algoritmo utilizado.

3.3 Cálculo do COP via Propriedades Termodinâmicas

O Coeficiente de Performance (COP) foi calculado com base no balanço energético do ciclo de refrigeração, utilizando as entalpias específicas do fluido nos pontos característicos:

$$COP = \frac{Q_{evap}}{W_{comp}} = \frac{h_1 - h_4}{h_2 - h_1}$$

Onde: h_1 é a entalpia na saída do evaporador (entrada do compressor); h_2 é a entalpia na saída do compressor e h_4 é a entalpia na saída da válvula de expansão.

As propriedades termodinâmicas do R290 foram obtidas por meio de biblioteca computacional (Coolprop) baseada em equações de estado multiparamétricas, garantindo elevada precisão na determinação das entalpias a partir das medições experimentais de pressão e temperatura.

O processo de expansão foi considerado isentálpico, conforme hipótese clássica para válvulas de estrangulamento, enquanto o processo de compressão incorporou implicitamente as irreversibilidades presentes no compressor real, uma vez que as entalpias foram calculadas diretamente a partir dos dados experimentais.

3.4 Treinamento da Rede Neural

A modelagem do sistema foi conduzida por meio de uma Rede Neural Artificial do tipo Multilayer Perceptron totalmente conectada, projetada para capturar as relações não lineares entre as variáveis operacionais do ciclo e as grandezas termodinâmicas de interesse. A estrutura da rede foi definida de forma a equilibrar capacidade de representação e estabilidade numérica, sendo composta por múltiplas camadas ocultas densas, nas quais funções de ativação do tipo Rectified Linear Unit – ReLU - foram empregadas para introduzir não linearidade ao modelo e permitir a aproximação eficiente do comportamento do sistema físico.


O treinamento foi realizado por meio do algoritmo de retropropagação do erro, utilizando o otimizador Adam, amplamente reconhecido por sua eficiência em problemas de aprendizado profundo envolvendo dados ruidosos e não linearmente correlacionados. A função objetivo adotada foi o Erro Quadrático Médio entre os valores previstos pela rede e os valores experimentais, o que permitiu penalizar de forma consistente desvios de maior magnitude. Para

garantir a capacidade de generalização do modelo, o conjunto de dados foi particionado em subconjuntos independentes de treinamento, validação e teste, sendo o desempenho monitorado continuamente ao longo do processo de aprendizagem.

Medidas de regularização foram incorporadas com o objetivo de evitar sobreajuste, incluindo a aplicação de Dropout nas camadas ocultas e a utilização de estratégia de interrupção antecipada baseada na evolução da perda de validação. Essas técnicas contribuíram para estabilizar o treinamento e reduzir a sensibilidade do modelo a flutuações nos dados experimentais. Ao final do processo, o modelo apresentou Erro Quadrático Médio inferior a 0,003 no conjunto de teste, indicando elevada precisão preditiva e forte capacidade de generalização, mesmo diante da variabilidade inerente às condições operacionais da bancada.

A arquitetura da rede é composta por 6 dados de entrada, sendo as temperaturas em pontos específicos do ciclo como também pela maior e menor pressão no ciclo; 3 camadas ocultas, sendo 2 camadas densas de 64 neurônios e 1 camada densa com 32 neurônios, todas as 3 camadas usando função de ativação ReLU; e uma camada de saída com os dados de temperatura de condensação, evaporação, COP do ciclo e o grau de abertura da válvulo. Toda a arquitetura está expressa na Imagem 4 abaixo.

Imagem 4 – Arquitetura da rede neural utilizada.



Fonte: Autor, 2026.

3.5 Implementação do Simulated Annealing

A etapa de otimização foi realizada por meio do algoritmo Simulated Annealing, aplicado ao espaço de variáveis operacionais delimitado pelos limites observados experimentalmente. A função objetivo foi definida como a maximização do Coeficiente de Performance previsto pela rede neural, que passou a atuar como um modelo substituto do sistema físico, permitindo avaliações rápidas e sucessivas sem a necessidade de execução experimental ou resolução de modelos termodinâmicos detalhados.

O processo de busca foi iniciado a partir de condições operacionais aleatórias dentro do domínio admissível, sendo geradas novas soluções candidatas por meio de perturbações estocásticas aplicadas ao vetor de variáveis de entrada. A aceitação dessas soluções seguiu o critério probabilístico clássico baseado na distribuição de Boltzmann, o que permitiu, especialmente nas fases iniciais do algoritmo, a exploração ampla do espaço de busca e a superação de ótimos locais. À medida que a temperatura do sistema era reduzida segundo uma lei de resfriamento geométrica, observou-se uma transição gradual para um regime de busca mais exploratório local, concentrado nas regiões mais promissoras do espaço de soluções.

A utilização da rede neural como função avaliadora foi determinante para a viabilidade computacional da abordagem, uma vez que permitiu a execução de um número elevado de iterações em tempo reduzido, mantendo simultaneamente a fidelidade física das avaliações, dado que o modelo havia sido treinado diretamente sobre dados experimentais. Para garantir a robustez dos resultados, o algoritmo foi executado múltiplas vezes a partir de diferentes condições iniciais, possibilitando a análise da consistência das soluções encontradas e da estabilidade do processo de convergência.

4 RESULTADOS E DISCUSSÃO

4.1 Desempenho do Modelo Preditivo

O modelo de rede neural desenvolvido demonstrou elevado desempenho na predição das variáveis de interesse, evidenciado pela forte concordância entre os valores estimados e os dados experimentais. A evolução do Erro Quadrático Médio ao longo do treinamento é apresentada na Tabela 2, em que se observa redução consistente tanto na perda de treinamento quanto na de validação, sem sinais de sobreajuste.

Tabela 2 – Evolução do Erro Quadrático Médio durante o treinamento.

Época	MSE Treinamento	MSE Validação
1	0,2985	0,0111
10	0,0141	0,0029
30	0,0043	0,0021
60	0,0014	0,0005
100	0,0007	0,0007
140	0,0006	0,0013

Fonte: Autor, 2026.

A análise comparativa revelou comportamento praticamente linear entre previsões e medições, com coeficientes de determinação superiores a 0,98 para todas as saídas consideradas, o que indica excelente capacidade do modelo em capturar as relações subjacentes entre as variáveis do sistema. A distribuição dos resíduos apresentou características próximas à normalidade, centrada em torno de zero e sem tendências sistemáticas aparentes, sugerindo ausência de viés relevante no processo de modelagem.

4.2 Convergência do Simulated Annealing

A análise do comportamento do algoritmo Simulated Annealing ao longo das execuções revelou um padrão consistente de convergência em direção a regiões de maior desempenho. Nas etapas iniciais do processo, caracterizadas por temperaturas mais elevadas, observou-se grande variabilidade nas soluções avaliadas, refletindo a capacidade do algoritmo de explorar amplamente o espaço de busca. Esse comportamento foi progressivamente substituído por uma

dinâmica mais estável à medida que a temperatura era reduzida, resultando em refinamento contínuo das soluções e convergência para valores elevados de Coeficiente de Performance.

A repetição do algoritmo sob diferentes condições iniciais evidenciou baixa dispersão nos resultados finais, indicando robustez da metodologia e reduzida dependência da escolha do ponto inicial. A aceitação controlada de soluções subótimas mostrou-se essencial para evitar aprisionamento em ótimos locais, confirmando a eficácia do Simulated Annealing em problemas caracterizados por superfícies de resposta multimodais e altamente não lineares.

4.3 Condições Ótimas de Operação Encontradas

A aplicação da metodologia proposta permitiu identificar um conjunto de condições operacionais que maximizam o Coeficiente de Performance dentro dos limites da bancada experimental. O valor ótimo encontrado pela abordagem híbrida foi de aproximadamente 3,40. Este ponto ótimo encontrado, caracteriza-se pela temperatura de condensação de aproximadamente 30 °C e temperatura de evaporação de aproximadamente 1,3 °C, associadas a um ajuste preciso da válvula de expansão eletrônica (abertura em torno de 49% a 50%). Essa combinação favorece a maximização da entalpia útil no evaporador ao mesmo tempo em que limita o incremento do trabalho de compressão, resultando em aumento global da eficiência do ciclo.

Os resultados obtidos não apenas corroboram tendências observadas na literatura recente, como também demonstram o potencial da abordagem híbrida proposta. Estudos experimentais com R290 têm reportado valores de COP na faixa de 2,8 a 3,5 em sistemas de refrigeração/resfriamento com temperatura de evaporação próxima a 0°C (Ibrahim et al., 2024; Liang et al., 2025; Khai et al., 2025). O valor ótimo de 3,40 encontrado neste trabalho se posiciona na faixa superior desses resultados, confirmando que a combinação de Redes Neurais com Simulated Annealing é capaz de explorar efetivamente o espaço de operação e identificar condições superiores às normalmente obtidas por ajuste manual ou otimização univariada. Para contextualização, o COP experimental máximo observado no conjunto de dados (12.487 registros) foi de 3,37, enquanto a média dos pontos experimentais foi de aproximadamente 2,91. O valor ótimo de 3,40 obtido pela otimização representa, portanto, uma melhoria em relação ao melhor ponto experimental registrado.

A fim de validar a coerência física da solução encontrada e caracterizar de forma mais completa o comportamento do ciclo, buscou-se, no conjunto de dados experimentais, o registro cujas condições operacionais mais se aproximam do ponto ótimo indicado pela abordagem

híbrida. Constatou-se que esse ponto corresponde justamente ao registro de maior COP experimental observado na bancada (3,37), evidenciando que a solução encontrada está ancorada em uma região do espaço operacional efetivamente amostrada durante os ensaios. Para esse ponto, calculou-se ainda o grau de superaquecimento na sucção do compressor de aproximadamente 20,0 °C, o grau de sub-resfriamento na saída do condensador de aproximadamente 11,1 °C e a eficiência isentrópica do compressor de aproximadamente 74,8%, grandezas consistentes com o comportamento esperado de um compressor hermético alternativo operando em regime real, com irreversibilidades associadas à compressão não isentrópica.

5 CONCLUSÃO

Este trabalho apresentou uma metodologia híbrida para otimização do desempenho de sistemas de refrigeração baseada na integração entre Redes Neurais Artificiais e o algoritmo Simulated Annealing, aplicada a uma bancada experimental real operando com o refrigerante R290. Diferentemente de abordagens convencionais baseadas em modelos analíticos ou dados simulados, a estratégia proposta fundamenta-se exclusivamente em dados experimentais, permitindo incorporar de forma implícita as irreversibilidades e não linearidades inerentes ao sistema físico. Os resultados demonstraram que o modelo de aprendizado de máquina é capaz de representar com elevada fidelidade o comportamento do sistema, viabilizando sua utilização como substituto computacional em processos de otimização. A aplicação do Simulated Annealing sobre esse modelo permitiu identificar condições operacionais que maximizam o Coeficiente de Performance de forma robusta e reprodutível, atingindo o valor de 3,40. Este resultado é superior ao COP máximo experimental observado (3,37) e significativamente superior ao COP médio dos regimes típicos de operação da bancada (aproximadamente 2,91), representando uma melhoria de cerca de 17% em relação à média experimental, entretanto, ainda assim não sendo possível afirmar o valor como um ótimo global, uma vez que o algoritmo metaheurístico usado não garante tal possibilidade. A principal contribuição deste trabalho reside na demonstração de que a combinação entre modelagem orientada a dados e otimização metaheurística constitui uma ferramenta eficaz para exploração de espaços operacionais complexos, especialmente em sistemas térmicos reais onde modelos físicos detalhados são de difícil implementação. Nesse sentido, a metodologia proposta apresenta potencial direto de aplicação em sistemas industriais, podendo ser integrada a estratégias de controle avançado

para operação autônoma e adaptativa. Como perspectivas futuras, destacam-se a validação da abordagem em sistemas de maior escala, a incorporação de restrições operacionais e de segurança mais rigorosas e a implementação em tempo real para controle preditivo de sistemas de refrigeração.

REFERÊNCIAS

- ASHRAE. **ANSI/ASHRAE Standard 34-2022**: designation and safety classification of refrigerants. Atlanta: ASHRAE, 2022.
- BANI ISSA, A. **Enabling propane (R290) refrigerant in next-generation residential air-source heat pumps**. 2025. Tese (Doutorado) – Purdue University, West Lafayette, 2025.
- BEJAN, A. **Advanced engineering thermodynamics**. 4. ed. Hoboken: John Wiley & Sons, 2016.
- BERTSIMAS, D.; TSITSIKLIS, J. Simulated annealing. **Statistical Science**, v. 8, n. 1, p. 10-15, 1993.
- BOLAJI, B. O. Performance investigation of R290. **International Journal of Refrigeration**, 2010.
- ÇENGEL, Y. A.; BOLES, M. A.; KANOGLU, M. **Thermodynamics**: an engineering approach. 10. ed. New York: McGraw-Hill Education, 2023.
- DELAHAYE, D. et al. Simulated annealing: from basics to applications. In: **Handbook of metaheuristics**. [S.l.]: Springer, 2019.
- DOSSAT, R. J. **Principles of refrigeration**. 5. ed. [S.l.]: Pearson Education, 2002.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge: MIT Press, 2016.
- HAYKIN, S. **Neural networks**: a comprehensive foundation. 2. ed. Upper Saddle River: Prentice Hall, 1999.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural Networks**, v. 2, n. 5, p. 359-366, 1989.
- IBRAHIM, O. A. A. et al. Review of hydrocarbon refrigerants as drop-in alternatives. **International Journal of Thermofluids**, 2024.
- KHAI, et al. Performance of R290 systems. **Energy**, 2025.
- KINGMA, D. P.; BA, J. Adam: a method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014.
- KIRKPATRICK, S.; GELATT, C. D.; VECCHI, M. P. Optimization by simulated annealing. **Science**, v. 220, n. 4598, p. 671-680, 1983.
- LIANG, et al. Experimental analysis of R290. **Applied Thermal Engineering**, 2025.
- RTOC, U. **2022 assessment report of the Refrigeration, Air Conditioning and Heat Pumps Technical Options Committee**. Nairóbi: United Nations Environment Programme, 2023.

SRIVASTAVA, N. et al. Dropout: a simple way to prevent neural networks from overfitting. **Journal of Machine Learning Research**, v. 15, p. 1929-1958, 2014.

STOECKER, W. F. **Industrial refrigeration handbook**. New York: McGraw-Hill, 1998.

UNITED NATIONS. **Montreal Protocol on Substances that Deplete the Ozone Layer**. 1987.

ZHANG, Z. et al. Artificial neural network for performance prediction of refrigeration systems. **Applied Thermal Engineering**, 2018.

APÊNDICE A – CÓDIGO DO PRÉ-PROCESSAMENTO DOS DADOS

```

1 import pandas as pd
2 import glob
3 from CoolProp.CoolProp import PropsSI
4
5 REFRIGERANTE = "R290"
6
7 arquivos = glob.glob("drive/MyDrive/Colab
8 Notebooks/PSODATA/*.xlsx")
9
10 df_final = pd.concat(
11     (pd.read_excel(arq) for arq in arquivos),
12     ignore_index=True
13 )
14 indices_manter = [1, 2, 6, 8, 16, 17, 30, 31, 39]
15 df_final = df_final.iloc[:, indices_manter]
16
17 novos_nomes = [
18     "Temp_Descarga_Comp",
19     "Temp_Saida_Cond",
20     "Temp_Suc_Comp",
21     "Temp_Saida_Evap",
22     "Press_Baixa",
23     "Press_Alta",
24     "Temp_Condensacao",
25     "Temp_Evaporacao",
26     "Abertura_Valvula"
27 ]
28 df_final.columns = novos_nomes
29
30 ordem_colunas = [
31     "Press_Baixa",
32     "Press_Alta",
33     "Temp_Suc_Comp",
34     "Temp_Descarga_Comp",
35     "Temp_Saida_Cond",
36     "Temp_Saida_Evap",
37     "Temp_Condensacao",
38     "Temp_Evaporacao",
39     "Abertura_Valvula"
40 ]
41 df_final = df_final[ordem_colunas]
42
43 def calcular_cop_linha(row):

```

```

44     try:
45         P_low  = (row["Press_Baixa"] + 1.0163) * 1e5
46         P_high = (row["Press_Alta"]  + 1.0163) * 1e5
47         T_suc  = row["Temp_Suc_Comp"]      + 273.15
48         T_desc = row["Temp_Descarga_Comp"]  + 273.15
49         T_cond = row["Temp_Saida_Cond"]     + 273.15
50
51         # Validações físicas
52         T_sat_low = PropsSI('T', 'P', P_low, 'Q', 1.0,
53 REFRIGERANTE)
54         T_sat_high = PropsSI('T', 'P', P_high, 'Q', 1.0,
55 REFRIGERANTE)
56         if abs(T_sat_low - T_suc) < 5.0: return None
57         if abs(T_sat_high - T_desc) < 5.0: return None
58         if abs(T_sat_high - T_cond) < 5.0: return None
59         if P_low >= P_high: return None
60         if T_suc >= T_desc: return None
61
62         h1 = PropsSI('H', 'P', P_low, 'T',
63 T_suc, REFRIGERANTE)
64         h2 = PropsSI('H', 'P', P_high, 'T', T_cond,
65 REFRIGERANTE)
66         h3 = PropsSI('H', 'P', P_high, 'T', T_desc,
67 REFRIGERANTE)
68
69         Q_evap = abs(h1 - h2)
70         W_comp = abs(h1 - h3)
71
72         return round(Q_evap / W_comp, 6)
73
74     except Exception as e:
75         print("\nERRO AO CALCULAR COP")
76         print(f"Arquivo : {row['Arquivo_Origem']}")
77         print(f"Erro      : {e}")
78         return None
79
80 df_final["COP"] = df_final.apply(calcular_cop_linha,
81 axis=1)
82
83 total      = len(df_final)
84 validos    = df_final["COP"].notna().sum()
85 invalidos  = total - validos
86
87 print(f"Total de linhas : {total}")
88 print(f"COPs calculados : {validos}")
89 print(f"Linhas inválidas : {invalidos} (removidas)")
90 print(f"\nEstatísticas do COP:")

```

```
86 print(df_final["COP"].describe())
87
88 df_final =
89 df_final.dropna(subset=["COP"]).reset_index(drop=True)
90 df_final.to_csv("Dados50.csv", index=False)
91 print(f"\nCSV salvo com {len(df_final)} linhas e coluna
92 COP!")
```

APÊNDICE B – CÓDIGO DA REDE NEURAL

```

1 import pandas as pd
2 import numpy as np
3 import tensorflow as tf
4 from tensorflow import keras
5 from sklearn.model_selection import train_test_split
6 from sklearn.preprocessing import StandardScaler
7 import joblib
8
9 data = pd.read_csv("Dados50.csv")
10
11 COLUNAS_X = [
12     "Press_Baixa", "Press_Alta", "Temp_Suc_Comp",
13     "Temp_Descarga_Comp", "Temp_Saida_Cond",
14     "Temp_Saida_Evap"
15 ]
16 COLUNAS_Y = [
17     "Abertura_Valvula", "COP",
18     "Temp_Condensacao", "Temp_Evaporacao"
19 ]
20
21 X = data[COLUNAS_X]
22 y = data[COLUNAS_Y]
23
24 print(f"Total de amostras : {len(data)}")
25 print(f"Entradas          : {len(COLUNAS_X)} → {COLUNAS_X}")
26 print(f"Saídas            : {len(COLUNAS_Y)} → {COLUNAS_Y}")
27 print(f"\nEstatísticas das saídas:")
28 print(y.describe())
29
30 bounds_reais = [(float(X[col].min()), float(X[col].max()))
31 for col in COLUNAS_X]
32 joblib.dump(bounds_reais, "bounds_reais.pkl")
33 joblib.dump(COLUNAS_X, "colunas_x.pkl")
34 joblib.dump(COLUNAS_Y, "colunas_y.pkl")
35 print("\nLimites reais das entradas:")
36 for col, (lo, hi) in zip(COLUNAS_X, bounds_reais):
37     print(f" {col:<24}: [{lo:.3f}, {hi:.3f}]")
38
39 scaler_X = StandardScaler()
40 scaler_y = StandardScaler()
41 X_scaled = scaler_X.fit_transform(X)
42 y_scaled = scaler_y.fit_transform(y)

```

```

43
44 X_train, X_test, y_train, y_test = train_test_split(
45     X_scaled, y_scaled, test_size=0.2, random_state=42
46 )
47
48 model = keras.Sequential([
49     keras.layers.Input(shape=(6,)),
50     keras.layers.Dense(64, activation='relu'),
51     keras.layers.Dropout(0.1),
52     keras.layers.Dense(64, activation='relu'),
53     keras.layers.Dropout(0.1),
54     keras.layers.Dense(32, activation='relu'),
55     keras.layers.Dense(4)
56 ])
57
58 model.summary()
59
60 model.compile(optimizer='adam', loss='mse', metrics=['mae'])
61
62 early_stop = keras.callbacks.EarlyStopping(
63     monitor='val_loss',
64     patience=50,
65     restore_best_weights=True,
66     verbose=1
67 )
68
69 history = model.fit(
70     X_train, y_train,
71     epochs=1000,
72     batch_size=32,
73     validation_split=0.2,
74     callbacks=[early_stop],
75     verbose=1
76 )
77
78 loss, mae = model.evaluate(X_test, y_test, verbose=0)
79 print(f"\nÉpocas treinadas : {len(history.history['loss'])}")
80 print(f"Erro final (MSE) : {loss:.6f}")
81 print(f"MAE : {mae:.6f}")
82
83 amostra = X_test[:5]
84 pred_scaled = model.predict(amostra, verbose=0)
85 pred = scaler_y.inverse_transform(pred_scaled)
86 real = scaler_y.inverse_transform(y_test[:5])
87
88 print("\nComparação previsão vs real (5 amostras):")

```

```

    print(f"    {'':4} {'Abertura':>10} {'COP':>8} {'T_Cond':>8}
89 {'T_Evap':>8}")
90 for i in range(5):
    print(f"    Real    : {real[i][0]:10.4f} {real[i][1]:8.4f}
91 {real[i][2]:8.4f} {real[i][3]:8.4f}")
    print(f"    Prev    : {pred[i][0]:10.4f} {pred[i][1]:8.4f}
92 {pred[i][2]:8.4f} {pred[i][3]:8.4f}")
93     print()
94
95 model.save("modelo_refrigeracao.keras")
96 joblib.dump(scaler_X, "scaler_X.pkl")
97 joblib.dump(scaler_y, "scaler_y.pkl")
98 print("Modelo e scalers salvos!")

```

APÊNDICE C – CÓDIGO DA INFERÊNCIA DO SIMULATED ANNEALING NA REDE NEURAL

```

1 import numpy as np
2 import tensorflow as tf
3 from tensorflow import keras
4 import joblib
5 import math
6 import pandas as pd
7 from IPython.display import clear_output
8
9 model =
10 keras.models.load_model("modelo_refrigeracao.keras")
11 scaler_X = joblib.load("scaler_X.pkl")
12 scaler_y = joblib.load("scaler_y.pkl")
13
14 data = pd.read_csv("Dados50.csv")
15 COLUNAS_X = ["Press_Baixa", "Press_Alta", "Temp_Suc_Comp",
16              "Temp_Descarga_Comp", "Temp_Saida_Cond",
17              "Temp_Saida_Evap"]
18
19 BOUNDS = [(float(data[c].min()), float(data[c].max())) for c
20 in COLUNAS_X]
21
22 print("Limites reais das entradas:")
23 for col, (lo, hi) in zip(COLUNAS_X, BOUNDS):
24     print(f" {col:<24}: [{lo:.3f}, {hi:.3f}]")
25
26 def predict(x):
27     entrada = pd.DataFrame([x], columns=COLUNAS_X)
28     entrada_scaled = scaler_X.transform(entrada)
29     entrada_tensor = tf.constant(entrada_scaled,
30 dtype=tf.float32)
31     saida_scaled = model(entrada_tensor,
32 training=False).numpy()
33     saida = scaler_y.inverse_transform(saida_scaled)
34     abertura = saida[0][0]
35     cop = saida[0][1]
36     t_cond = saida[0][2]
37     t_evap = saida[0][3]
38     return abertura, cop, t_cond, t_evap
39
40 def calcular_cop(x):
41     try:
42         _, cop, _, _ = predict(x)
43         if cop <= 0:
44             return -1e9

```

```

40         return cop
41     except Exception:
42         return -1e9
43
44 def vizinho(x, T, bounds):
45     x_novo = x.copy()
46     n_vars = np.random.choice([1, 2, 3], p=[0.6, 0.3, 0.1])
47     indices = np.random.choice(len(x), size=n_vars,
48 replace=False)
49     for idx in indices:
50         lo, hi = bounds[idx]
51         passo = (hi - lo) * 0.15 * T
52         x_novo[idx] += np.random.uniform(-passo, passo)
53         x_novo[idx] = np.clip(x_novo[idx], lo, hi)
54     return x_novo
55
56 def exibir_progresso(reinicio, n_reinicios, iteracao,
57 iteracoes,
58                       T, cop_atual, melhor_cop,
59 melhor_global_cop,
60                       historico, melhor_global_x):
61     clear_output(wait=True)
62     prog = int((iteracao / iteracoes) * 30)
63     barra = "█" * prog + "░" * (30 - prog)
64
65     abertura, cop_ia, t_cond, t_evap =
66     predict(melhor_global_x)
67
68     print("=" * 55)
69     print("          SIMULATED ANNEALING – MAXIMIZANDO COP")
70     print("=" * 55)
71     print(f"  Reinício           : {reinicio}/{n_reinicios}")
72     print(f"  Iteração            : {iteracao:>6} /")
73 {iteracoes} [{barra}] {iteracao/iteracoes*100:.1f}%")
74     print(f"  Temperatura SA      : {T:.6f}")
75     print(f"  COP atual           : {cop_atual:.5f}")
76     print(f"  Melhor reinício     : {melhor_cop:.5f}")
77     print(f"  🏆 Melhor global      : {melhor_global_cop:.5f}")
78     print("-" * 55)
79     print("  📤 Saídas do melhor global:")
80     print(f"      Abertura_Valvula : {abertura:.4f}")
81     print(f"      Temp_Condensacao  : {t_cond:.4f} °C")
82     print(f"      Temp_Evaporacao   : {t_evap:.4f} °C")
83     print("-" * 55)
84     if historico:
85         print("  Evolução do melhor COP:")
86         for it, c in historico[-8:]:
87             print(f"      it {it:>5}: {c:.5f}")

```

```

83     print("=" * 55)
84
85 def simulated_annealing(bounds, T_inicial=1.0, T_final=1e-5,
86                          alpha=0.9995, iteracoes=8_000,
87                          n_reinicios=6,
88                          intervalo_display=200):
89     melhor_global_x = None
90     melhor_global_cop = -np.inf
91     historico = []
92
93     for reinicio in range(1, n_reinicios + 1):
94         x_atual = np.array([np.random.uniform(lo, hi) for
95 lo, hi in bounds])
96         cop_atual = calcular_cop(x_atual)
97         melhor_x = x_atual.copy()
98         melhor_cop = cop_atual
99         T = T_inicial
100
101         for i in range(1, iteracoes + 1):
102             x_novo = vizinho(x_atual, T, bounds)
103             cop_novo = calcular_cop(x_novo)
104             delta = cop_novo - cop_atual
105
106             if delta > 0 or np.random.random() <
107 math.exp(delta / T):
108                 x_atual = x_novo
109                 cop_atual = cop_novo
110
111                 if cop_atual > melhor_cop:
112                     melhor_cop = cop_atual
113                     melhor_x = x_atual.copy()
114                     historico.append((i, melhor_cop))
115
116                 if cop_atual > melhor_global_cop:
117                     melhor_global_cop = cop_atual
118                     melhor_global_x = x_atual.copy()
119
120                 T = max(T * alpha, T_final)
121
122                 if i % intervalo_display == 0:
123                     exibir_progresso(reinicio, n_reinicios, i,
124 iteracoes,
125                                     T, cop_atual, melhor_cop,
126                                     melhor_global_cop,
127                                     historico, melhor_global_x)
128
129     return melhor_global_x, melhor_global_cop

```

```
126 melhor_x, melhor_cop = simulated_annealing(BOUNDS)
127
128 abertura, cop_ia, t_cond, t_evap = predict(melhor_x)
129
130 clear_output(wait=True)
131 print(f"\n COP previsto pela IA : {cop_ia:.5f}")
132 print("\n Entradas ótimas:")
133 for nome, val in zip(COLUNAS_X, melhor_x):
134     print(f"      {nome:<24}: {val:.4f}")
135 print("\n Saídas previstas pela IA:")
136 print(f"      Abertura_Valvula      : {abertura:.4f}")
137 print(f"      COP                      : {cop_ia:.4f}")
138 print(f"      Temp_Condensacao         : {t_cond:.4f} °C")
139 print(f"      Temp_Evaporacao         : {t_evap:.4f} °C")
```