MODELAGEM DA CONDUTIVIDADE TÉRMICA DA MISTURA BINÁRIA ÁGUA-ETILENO GLICOL A PARTIR DE REDES NEURAIS ARTIFICIAIS

Bruno Facci, Tiago Dias Martins

[1]*Universidade Federal de São Paulo (UNIFESP), Departamento do Engenharia Química, Diadema, Brasil (bfacci@unifesp.br)*

Resumo: Este trabalho teve como objetivo a modelagem da condutividade térmica da mistura água-etileno glicol via de redes neurais artificiais (RNA) utilizando dados disponíveis na literatura. A melhor rede foi determinada avaliando o erro médio, atingindo um resultado de aproximadamente 0,055 %. Posteriormente, foi realizado a validação externa com dados que não foram utilizados para a obtenção da RNA, apresentando um erro médio de 1,4 % e erro máximo de 5 %, evidenciando a precisão do modelo.

Palavras-chave: Redes neurais artificiais; Condutividade térmica; Mistura binária; Fluido refrigerante.

INTRODUÇÃO

O conhecimento de termodinâmica é extremamente importante para a determinação da condutividade térmica de uma mistura, visto que, essa propriedade depende das interações intermoleculares das substâncias que a compõe. Logo, o entendimento dessa relação auxilia na otimização da escolha da mistura a ser utilizada como fluido refrigerante, e do controle do processo, garantindo um maior desempenho do sistema. (Smith et al., 2019)

A escolha do fluido refrigerante é importante devido, principalmente, ao seu papel no sistema de refrigeração, mas, além disso, devido a crescente preocupação com os poluentes atmosféricos nos dias atuais. Os fluidos que apresentam maior desempenho tendem a apresentar um alto GWP (global warming potencial), que se trata da capacidade desse fluido reter calor na atmosfera (McLinden et al*.,* 2014). Com o aumento da preocupação com a causa ambiental, a busca por componentes ambientalmente favoráveis que mantenham alto desempenho de troca térmica é crucial. Uma das alternativas é a seleção de uma mistura a fim de misturar propriedades de diferentes substâncias, atingindo o limiar entre desempenho e mitigação do impacto ambiental (Tejani et al*.,* 2022).

Assim, a mistura binária água-etileno glicol surge como alternativa para suprir a necessidade de um fluido refrigerante de alto desempenho com baixo impacto ecológico (Jiang et al., 2023).

Além disso, a modelagem da condutividade térmica é essencial para a aplicabilidade real dessa mistura, visto que a energia gasta em um processo está diretamente ligada a capacidade de transferência de calor do fluido refrigerante.

A modelagem termodinâmica da condutividade térmica é bastante complexa (Li et al., 2024) e, se torna ainda mais complicada quando se trata de misturas, visto que as interações moleculares precisam ser levadas em consideração, o que nem sempre é possível.

Como alternativa aos modelos tradicionais, as Redes Neurais Artificiais (RNAs) têm ganhado destaque na modelagem de propriedades termofísicas devido à sua capacidade de aprender diretamente a partir de dados experimentais. Essa característica permite mapear comportamentos complexos, como a condutividade térmica em misturas binárias. O processamento da informação nessa estrutura ocorre por meio da interconexão de neurônios. A operação fundamental de cada nó é descrita pela Equação 1, que detalha como as variáveis de entrada são ponderadas por pesos sinápticos e somadas a um termo de viés (*bias*), viabilizando o ajuste e a determinação precisa da propriedade estudada.

$$y_k = \varphi\,(w_{ki} * x_i + b_k) \qquad (1)$$

sendo, y_k saída numérica do neurônio k; φ = função de ativação do neurônio; w_{ki} = pesos sinápticos de cada entrada i do neurônio k; x_i = entrada numérica i; b_k = bias do neurônio k.

Nesse sentido, o objetivo deste trabalho é obter uma RNA para modelar a condutividade térmica da mistura água-etileno glicol, visando a otimização de processos de refrigeração

Este trabalho busca contribuir para aumentar a eficiência, que depende diretamente da precisão na qual é determinada essa propriedade de transporte. Além de, proporcionar uma alternativa menos custosa, abrangente e rápida, tornando a aplicabilidade ainda mais atrativa (Wang et al., 2013;

Livro: The properties of gases and liquids - Poling et al).

MATERIAL E MÉTODOS

Esse projeto teve como objetivo a predição da condutividade térmica da mistura água-etileno glicol via redes neurais artificiais, a partir de dados experimentais disponíveis na literatura, visando a melhora do desempenho em relação à modelagem (correlação) empírica proposta originalmente.

Os dados experimentais foram adquiridos do artigo "Investigation on liquid termal conductivity of ethylene glicol (EG)/water mixtures: a comparative experimental and molecular dynamics simulation study" (Jiang et al., 2023), no qual foi realizada a determinação da condutividade térmica em diferentes valores de fração molar, pressão e temperatura, conforme apresentado na Tabela 1.

Tabela 1. Intervalos considerados para medição dos valores de condutividade térmica da mistura água-etileno glicol. (Jiang et al., 2023)

Fração molar / x1	Temperatura / K	Pressão / MPa
1	283-353	0,1 / 1 / 4 / 8
0,75	266-353	0,1 / 1 / 4 / 8
0,5	255-353	0,1 / 1 / 4 / 8
0,25	254-353	0,1 / 1 / 4 / 8
0	264-353	0,1 / 1 / 4 / 8

Este trabalho foi desenvolvido utilizando os 200 pontos coletados experimentalmente pelos autores. As variáveis de entrada selecionadas foram temperatura (T), pressão (P) e fração molar da água (x_1). A variável de saída foi a condutividade térmica (κ) correspondente. A estrutura geral das RNAs consideradas nesse trabalho é exemplificada pela Figura 1.

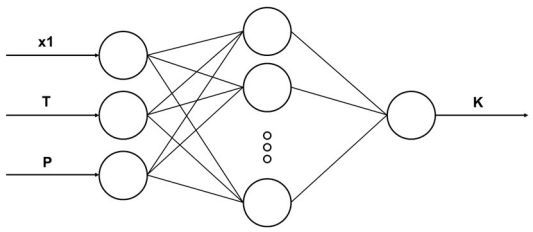


Figura 1. Esquema da RNA.

De antemão, não é possível prever a melhor estrutura de rede neural para o problema, por isso o ajuste da quantidade de neurônios na camada oculta, da melhor função de ativação, bem como a escolha do algoritmo de otimização, precisa ser realizado via tentativa e erro. Com isso, foram realizados treinamentos de diferentes estruturas a fim de se estabelecer as melhores redes. Para isso variou-se parâmetros, tais como: a função de ativação da camada intermediária e da camada de saída, quantidade de neurônios na camada intermediária, e também, o algoritmo de treinamento, especificados na Tabela 2.

Tabela 2. Parâmetros utilizados no treinamento da RNA.

Função de ativação	Número de neurônios	Algoritmo de treinamento
Sigmoidal (logsig) Tangente Hiperbólica (tansig) Linear (purelin) Linear positiva (poslin) Base radial (radbas) Saturação linear simétrica (satlins) Softmax	2-15	Levenberg-Marquardt (trainlm) Levenberg-Marquardt com regularização bayesiana (trainbr) Gradiente conjugado escalonado(trainscg) Gradiente conjugado com reinícios de powell/beale (traincgb) Retropropagação resiliente (trainrp) Retropropagação por gradiente descendente com momento e taxa de aprendizado adaptativa (traingdx)

O processo de obtenção de uma rede neural se dividiu em 3 etapas, sendo elas o treinamento, o teste, e a validação. Para isso, os dados foram separados proporcionalmente em 70%, 15%, 15% para as respectivas etapas (Livro: Redes Neurais – Simon Haykin). A função objetivo a ser minimizada utilizada foi o erro quadrático médio, que calcula a média dos quadrados da diferença entre os valores previstos pelo modelo e os valores reais, conforme indicado pela Equação 2.

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(Y_i - \hat{Y}_i)^2 \qquad (2)$$

sendo, MSE = erro quadrático médio; n = número total de observações; Y_i = valor real; $\hat{Y}_i$ = valor previsto.

Para se determinar a rede com o melhor desempenho, foi calculada a média do erro médio das 3 etapas da obtenção (treino, teste e validação), conforme as Equações 3 e 4.

$$E = \frac{1}{n}\sum_{i=1}^{m}\epsilon_i \quad (3)$$

$$\epsilon_i = \frac{100}{m}\sum_{j=1}^{n}\frac{(Y_j - \hat{Y}_j)}{Y_j} \quad (4)$$

sendo, E = média dos erros médio; m = quantidade de etapas; ϵ_i = erro percentual da etapa i; j = número de dados experimentais da etapa i.

Além disso, foi realizada uma análise estatística em relação a todos os treinamentos realizados, a fim de se avaliar a influência das configurações no resultado e analisar a capacidade de aprendizado da rede (a partir do valor de E) em função do algoritmo de treinamento, número de neurônios e função de ativação na camada intermediária e na camada de saída. Para isso, foram confeccionadas tabelas dinâmicas para contabilizar a incidência de RNAs em diferentes faixas de erro.

Após a determinação da melhor RNA, foi realizada uma simulação a fim de se verificar a capacidade de interpolação do modelo em função da temperatura. Para isso, foram consideradas as condições de fração molar e pressão apresentadas na Tabela 1, interpolando-se os valores de temperatura considerando-se um intervalo de 0,5 K.

Além disso, foi realizada uma validação externa que consistiu na aplicação da rede neural a dados externos. Com esse propósito, dados experimentais foram retirados da literatura, especificamente dos artigos de Vanderkooi et al. (1967) e Deng & Zhang (2021). Essa etapa consistiu em analisar o desempenho da rede neural a partir da avaliação de dados que não foram utilizados nas etapas anteriores (de treino, teste e validação), e coletados em outras condições experimentais. Para isso, para a melhor RNA, foi calculado o valor de ϵ_i e posteriormente obtidas as métricas: valor médio, valor máximo, valor mínimo, e mediana. Como comparativo, foi utilizado a correlação empírica proposta por Jiang et al. (2023) (Equação 5) a fim de se avaliar se houve ganhos com a aplicação da rede neural frente aquilo já estabelecido anteriormente pelos autores.

$$\kappa = a_0 + a_1 T^{0,5} + a_2 P \quad (5)$$

em que: a_0, a_1 e a_2 são parâmetros ajustáveis do modelo, específicos para cada composição.

RESULTADOS E DISCUSSÃO

Neste trabalho, foram treinadas 3528 estruturas de redes neurais artificiais para correlacionar T, P e x_1 com a condutividade térmica da mistura água-etileno glicol, utilizando dados disponíveis na literatura. Para a obtenção da melhor configuração, cada estrutura foi treinada 5 vezes para garantir um desempenho concreto, totalizando um total de 17640 treinamentos.

A partir disso, foi possível analisar quais parâmetros mais contribuíram para que a rede apresentasse um desempenho satisfatório. As Tabelas 3-6 apresentam a contagem de RNAs em função dos parâmetros de algoritmo de treinamento, função de ativação na camada intermediária e função de ativação na camada de saída, número de neurônios, respectivamente, para diferentes faixas de erro médio apresentado pela RNA.

Tabela 3. Contagem de RNAs em função do algoritmo de treinamento em diferentes intervalos de erro.

E (%)	trainbr	trainlm
0,05-0,06	1	4
0,06-0,07		15
0,07-0,08	5	14
0,08-0,09	9	24
0,09-0,1	32	13

Tabela 4. Contagem de RNAs em função da função de ativação na camada intermediária em diferentes intervalos de erro.

E (%)	logsig	poslin	radbas	softmax	tansig
0,05-0,06				5	
0,06-0,07			1	11	3
0,07-0,08				16	3
0,08-0,09	4	2	1	17	9
0,09-0,1	10	1	11	17	6

Tabela 5. Contagem de RNAs em função da função de ativação na camada saída em diferentes intervalos de erro.

E (%)	purelin	satlins	tansig
0,05-0,06	1	3	1
0,06-0,07	9	4	2
0,07-0,08	8	4	7
0,08-0,09	4	5	24
0,09-0,1	3	2	40

Tabela 6. Contagem de RNAs em função do número de neurônios em diferentes intervalos de erro.

E (%)	6	7	8	9	10	11	12	13	14	15
0,05-0,06							1	2	1	1
0,06-0,07			1	1	2	4		4	2	1
0,07-0,08	1		2	2	1	2	3	1	6	1
0,08-0,09		4	4		1	6	5	6	3	4
0,09-0,1		3	5	5	9	4	4	6	4	5

Na Tabela 3 foi omitida a contagem para os algoritmos de treinamento traincgb, traingdx, trainrp, trainscg, pois não apresentaram redes com erros no intervalo entre 0,05-0,1. Essa omissão se repete na Tabela 4 e 5, em relação as funções purelin e satlins, e as funções logsig, poslin e radbas, respectivamente. E também, na Tabela 6, para número de neurônios menor que 6.

A partir da Tabela 3, pode-se notar que as RNAs treinadas apresentaram erros bastante baixos, atingindo menos de 0,1 %, o que comprova a eficiência das RNAs para a predição da condutividade térmica. A eficiência na predição de propriedades termodinâmica já foi observada em outros trabalhos (Heck e Martins, 2023; Farias, 2023; Braga et al., 2021).

Com relação a distribuição dos erros, é possível confirmar que os algoritmos trainbr e trainlm apresentaram desempenho acima da média dentre todos os analisados. Já que ambos apresentaram redes com erro médio inferior a 0,1 %. Apesar de os dois algoritmos apresentarem redes com erro no intervalo de 0,05 % a 0,06 %, o algoritmo de treinamento trainlm apresentou melhor consistência no intervalo entre 0,05 % e 0,1 %, com 70 RNAs. Em contraste, os algoritmos traincgb, traingdx e trainscg não apresentaram RNAs nessa faixa de erros. Esse comportamento já foi citado na literatura, como no trabalho de Faúndez et al. (2020), que sugere que os algoritmos trainlm e trainbr são os mais eficientes para tratar de problemas em termodinâmica.

Baseado na Tabela 4, é notório o destaque para o desempenho da função de ativação softmax na camada intermediária, apresentando o maior número de redes com erro abaixo de 0,1 % (66 estruturas). Em segundo, a função de ativação tansig apresentou um bom desempenho, apresentando 21 redes com erros abaixo de 0,1 %. Finalmente, a função de radbas apresentou 13 RNAs. Enquanto isso, as demais funções de ativação só apresentaram erros acima de 0,1 %. Esse comportamento também foi reportado em (Hidalgo, 2025; Farias, 2023).

A Tabela 5 evidencia que, a função de ativação tansig teve a maior incidência de erros abaixo de 0,1 %, ademais, as funções lineares e satlins também apresentaram redes com erros nessa faixa. Além disso, as demais funções não apresentaram contribuição equivalente, sendo assim, omitidas das tabelas por não corroborarem para a precisão do modelo.

A partir dos resultados apresentados na Tabela 6, é possível visualizar a tendência do aumento da precisão da rede conforme o aumento do número de neurônios da rede neural (em outras palavras, do número de parâmetros). Erros menores que 0,1 % são evidenciados apenas a partir de redes com 6 neurônios, enquanto para erros menores que 0,06 % são necessários, no mínimo, 12 neurônios. Portanto, em geral, a relação entre desempenho e número de neurônios é diretamente proporcional para o problema analisado. Esse comportamento também foi evidenciado nos estudos de (Hidalgo, 2025).

Os resultados apresentados nas Tabelas 3-6 salientam a importância de se realizar uma busca bastante ampla em termos das combinações de estruturas de RNAs. O trabalho de Faundéz et al. (2020) relata que a estrutura ideal é determinada por meio de diversas tentativas variando, entretanto, destaca o desempenho do algoritmo de trainlm na tarefa de modelagem de propriedades de fluidos, a proporcionalidade entre quantidade de neurônios e desempenho, e também, a capacidade de corroborar para o aumento da precisão das funções de ativação tansig e purelin. Apesar disso, os resultados encontrados nesse trabalho divergem do que é tido como “padrão” na modelagem via RNAs, apresentando por exemplo a função softmax como aquela que melhor desempenha.

A função softmax também foi a função de ativação na camada oculta no estudo de Valera et al. (2024) e Gardezani et al. (2026). Esses resultados são bastante interessantes e corroboram que uma busca ampla em termos das mais diversas configurações de RNAs é necessária para que o melhor resultado seja, de fato, encontrado. Isso se deve principalmente pelo fato de que cada problema é um problema diferente.

A partir do cálculo do *E* (equação 3), foram estabelecidas as 10 melhores RNAs, ademais, também foram consideradas duas redes neurais que se destacaram devido sua precisão mesmo com menor número de neurônios, conforme é apresentado na Tabela 7.

Tabela 7. 12 melhores estruturas de redes neurais.

	Algoritmo de treino	Função de ativação		Número de neurônios	E (%)
		Camada intermediária	saída		
1	trainbr	softmax	tansig	12	0,055
2	trainlm	softmax	satlins	15	0,058
3	trainlm	softmax	purelin	14	0,059
4	trainlm	softmax	satlins	13	0,060
5	trainlm	softmax	satlins	13	0,060
6	trainlm	softmax	purelin	13	0,060
7	trainlm	softmax	tansig	13	0,063
8	trainlm	softmax	satlins	13	0,063
9	trainlm	radbas	tansig	11	0,063
10	trainlm	tansig	purelin	14	0,063
11	trainlm	tansig	purelin	8	0,067
12	trainbr	tansig	purelin	6	0,078

Os resultados apresentados pela Tabela 7 comprovam a tendência determinada pelas tabelas 3-6, a partir da presença majoritária do algoritmo de treinamento trainlm, função de ativação softmax e número de neurônios acima de 10. Portanto, a maior incidência nas menores faixas de erro, de fato, corresponde com o melhor desempenho da RNA. Ademais, ao se observar a Tabela 7, a estrutura da RNA com a melhor precisão foi treinada com trainbr, utilizou função de ativação softmax e tansig (camada intermediária e camada de saída, respectivamente) e com 12 neurônios, obtendo um valor de média dos erros igual a 0,05%.

Com isso, a etapa de simulação considerando a interpolação na temperatura e validação externa foram realizadas com a RNA 1. Como resultado, foram obtidas as Figuras 2 e 3.

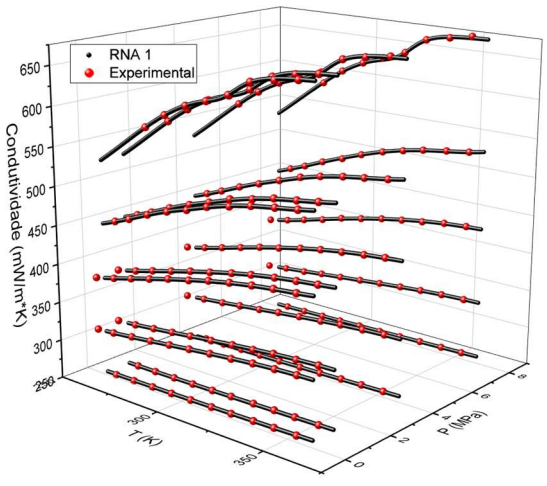


Figura 2. Condutividade térmica calculada pela RNA1 considerando a interpolação na temperatura para as condições experimentais da Tabela 1.

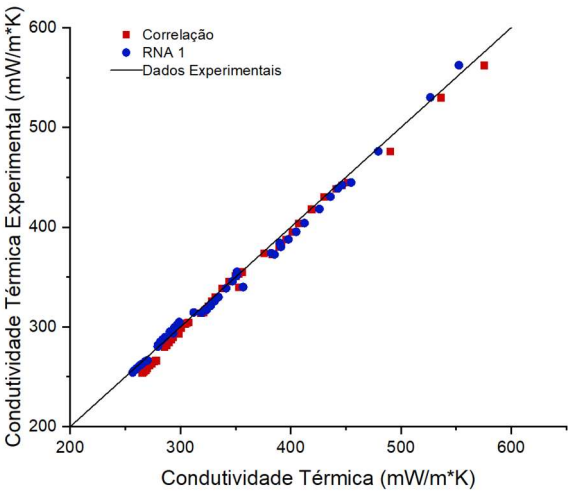


Figura 3. Comparação entre o valor experimental e calculado considerando os dados da validação externa.

Ao se observar o comportamento da curva gerada pelo cálculo da RNA na Figura 2, confirma-se a capacidade da RNA 1 de modelar a condutividade térmica em função da fração molar, temperatura e pressão com precisão. O mesmo pode ser observado na Figura 3, ao considerar dados experimentais de outra fonte.

Visando-se comparar o desempenho da RNA obtida com a correlação proposta por Jiang et al. (2023), os valores de condutividade térmica para os dados da validação externa também foram calculados usando a Equação (5). Além disso, visando-se comparar o desempenho da RNA 1, com RNAs que apresentaram número de parâmetros semelhantes ao da correlação,

Desse modo, foram aplicados a correlação desenvolvida pelo artigo base e três estruturas de rede neural, estrutura 1 que apresentou o maior desempenho nas etapas anteriores, e as estruturas 11 e 12, que apresentam 8 e 6 neurônios respectivamente, no intuito de determinar a influência da quantidade de neurônios (e consequentemente, a quantidade de parâmetros) na validação externa.

Assim, foram extraídos os dados experimentais dos estudos de Vanderkooi (1967) e Deng (2021), e foram calculadas as seguintes métricas considerando o erro percentual: média, máximo, mínimo e mediana, conforme apresentado pela Tabela 8.

Tabela 8. Métricas de desempenho na validação externa.

	Eq (5)	RNA 1	RNA 11	RNA 12
Média	1,8402	1,4096	1,8928	1,9711
Mediana	1,5172	1,2752	1,7211	1,4892
Máximo	4,3936	4,9775	6,4269	7,5461
Mínimo	0,1197	0,0769	0,0238	0,0065

A partir da Tabela 8, é notório o desempenho satisfatório de todos os modelos, entretanto, a RNA 1 destaca-se pelos valores de média, mediana e máximo em relação as RNAs 11 e 12, sendo assim, é importante salientar que para se obter uma alta precisão foram necessários mais neurônios (parâmetros).

Ainda, nota-se que a correlação empírica apresentou desempenho semelhante. Assim, para determinar qual o melhor modelo de fato, foram obtidos os histogramas dos erros percentuais, Figuras 4 e 5, para analisar a distribuição em cada modelo.

A partir dos histogramas, pode-se observar bem a diferença da dispersão dos erros entre os modelos: o erro da correlação é distribuído durante todo o intervalo, enquanto isso, o erro da RNA 1 se concentra na primeira metade do intervalo, o que reflete o valor da mediana apresentado na Tabela 8. Esse comportamento indica uma maior precisão da RNA em determinar a condutividade térmica frente a correlação empírica. Desse modo, a rede neural estabelece desempenho ótimo, tornando-se alternativa confiável e precisa para a modelagem da condutividade térmica da mistura binária água-etileno glicol.

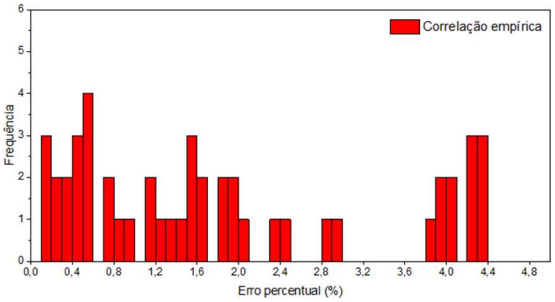


Figura 4. Histograma de erro da correlação empírica.

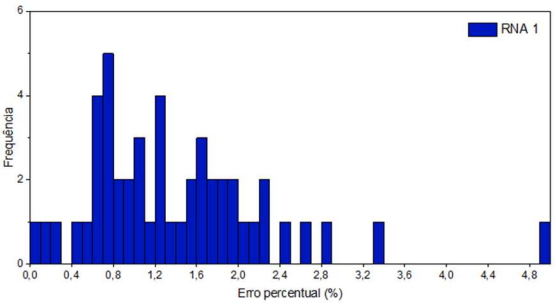


Figura 5. Histograma de erro da RNA 1.

CONCLUSÃO

A capacidade de determinação da condutividade térmica da mistura água-etileno glicol da RNA foi obtida em função da fração molar, temperatura e pressão. O melhor modelo apresentou um resultado de média dos erros médios das etapas de treino, teste e validação de aproximadamente 0,055 %. Dessa forma, a RNA demonstrou capacidade de determinação mais precisa que a correlação estabelecida pela literatura base. Além disso, o desempenho máximo seguiu a tendência entre os parâmetros de estrutura da rede neural que mais colaboraram para a precisão da rede, sendo eles, trainlm e trainbr para algoritmos de treinamento, softmax, satlins, tansig para funções de ativação, e número de neurônios maior que 10.

Ainda assim, a partir da validação externa, foi demonstrado a ampla capacidade de aplicação da RNA, obtendo-se um erro médio de 1,4 % e erro máximo de 5 %, garantindo que, mesmo para conjunto de dados externos, a rede neural mantém a sua precisão. Ademais, a RNA supera novamente a correlação empírica.

De modo geral, a aplicação dessa tecnologia garante maior precisão e confiabilidade na obtenção dessa propriedade termofísica, garantindo o dimensionamento de equipamentos e processos de forma otimizada e menos custosa.

REFERÊNCIAS

Braga, M. B.; Martins, T. D.; Louzi, V. C. A.; Giannella, R. L.; Fujita, V. K.; Rocha, S. C. S. Spouted bed drying of milk-blackberry mixture: material thermal properties and process energy aspects.

Deng, C.; Zhang, K. Thermal conductivity of 1,2-ethanediol and 1,2-propanediol binary aqueous solutions at temperature from 253K to 373K. International Journal of Thermophysics, 42:81. 2021.

Farias, R. J. O. Predição da entalpia de excesso da mistura dióxido de carbono-acetona utilizando redes neurais artificiais. Trabalho de conclusão de curso (bacharel em engenharia química) – Instituto de Ciências Ambientais, Química e Farmacêuticas, Universidade Federal de São Paulo, Diadema. 2023.

Faúndez, C. A.; Campusano, R. A.; Valderrama, J. O. Misleading results on the use of artificial neural networks for correlating and predicting properties of fluids. A case on the solubility of refrigerant R-32 in ionic liquids. Journal of Molecular Liquids, 298. 2020.

Gardezani, O. P.; Martins T. D.; Andrade R. R. Sensor virtual para monitoramento da fermentação de mel com adição de extrato de casca de jabuticaba aplicando redes neurais artificiais. Engenharia e Tecnologia, v. 18, n. 1. 2026.

Haykin, S. Redes neurais: Princípios e prática. (Bookman). 2000.

Heck, J. R. P.; Martins, T. D. Correlação baseada em redes neurais artificiais para a predição da condutividade térmica e da viscosidade do fluido refrigerante R32. Revista de Engenharia e Tecnologia, V.15. 2023

Hidalgo, V. R.; Modelagem de propriedades termodinâmicas de fluidos refrigerantes à base de hidrofluorocarbono via redes neurais artificiais. *Biblioteca Virtual da FAPESP*. 2025. Disponível em: https://bv.fapesp.br/pt/bolsas/219839/modelagem-de-propriedades-termodinamicas-de-fluidos-refrigerantes-a-base-de-hidrofluorocarbono-via-r/. Acesso em: 29 maio 2026.

Jiang, G.; Liu, Y.; Liu, C. Investigation on liquid thermal conductivity of ethylene glycol (EG)/water mixtures: A comparative experimental and molecular dynamics simulation study. Journal of Molecular Liquids, 384. 2023.

Li Z.; Duan, Y.; Yang, X. Linking thermal conductivity to equations of state using the residual entropy scaling theory. Industrial & Engineering Chemistry Research, V. 63, 42. 2024.

McLinden, M. O.; Kazakov, A. F.; Brown, J. S.; Domanski. P. A. A thermodynamic analysis of refrigerants: possibilities and tradeoffs for low-GWP refrigerants. International Journal of Refrigeration, 38, 80-92. 2014.

Poling, B. E.; Prausnitz, J. M.; O'Connell, J. P. The properties of gases and liquids. (McGraw Hill). 2001.

Smith, J. M.; Van Ness, H. C.; Abbott, M. M.; Swihart, M. T. Introdução à termodinâmica da engenharia química. (LTC). 2019.

Tejani, A.; Gajjar, H.; Toshniwal, V.; Kandelwal, R. The impact of low-GWP refrigerants on environmental sustainability: an examination of recent advances in refrigeration systems. ESP Journal of Engineering & Technology Advancements, 2, 62-77. 2022.

Valera V. Y.; Martins T. D.; Codolo M. C. Experimental evaluation and neural networks modeling of removal efficiency and volumetric mass transfer coefficient for gas desulfurization in spray tower. Chemical Engineering Science, 285. 2024.

Vanderkooi, W. N.; Hildenbrand, D. L.; Stull, D. R. The apparatus, values for several glycols and their aqueous solutions, and five high molecular weight hydrocarbons. Liquid Thermal Conductivities. 1967.

Wang, P.; Kosinski, J. J.; Anderko, A.; Springer, R. D.; Lencka, M. M.; Liu, J. Ethylene glycol and its mixtures with water and electrolytes: thermodynamic and transport properties. Industrial & Engineering Chemistry Research, 52, 15968-15987. 2013.