

12º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

REVISÃO DA LITERATURA SOBRE A PREVISÃO DAS PROPRIEDADES FÍSICO-QUÍMICAS DO GÁS NATURAL UTILIZANDO REDES NEURAIS ARTIFICIAIS

AUTORES:

Carolina Lima da Silva, Luiz Carlos Lobato dos Santos, George Simonelli

INSTITUIÇÃO:

Programa de Pós-Graduação em Engenharia Química, Escola Politécnica, Universidade Federal da Bahia

REVISÃO DA LITERATURA SOBRE A PREVISÃO DAS PROPRIEDADES FÍSICO-QUÍMICAS DO GÁS NATURAL UTILIZANDO REDES NEURAIS ARTIFICIAIS

Resumo

O gás natural (GN) é uma mistura formada basicamente por hidrocarbonetos gasosos. Possui componentes de baixa massa molecular e é composto principalmente por metano e etano. As propriedades físico-químicas do gás natural são úteis em diversas aplicações, tais como projetar dutos, válvulas, medidores e outros equipamentos de processos industriais. Em engenharia, a previsão das características físico-químicas do gás natural, como viscosidade, densidade, fator de compressibilidade, entre outras, é geralmente realizada em laboratório ou usando correlações, uma por uma separadamente. Contudo, determinar as propriedades físico-químicas do gás natural em laboratório pode ser custoso e demorado, pois requer o uso de técnicas analíticas avançadas, equipamentos especializados e cuidados rigorosos na amostragem e na preparação de amostras para garantir resultados precisos e confiáveis. Neste contexto, as redes neurais artificiais (RNAs) têm se destacado como uma alternativa eficaz e precisa. Elas aprendem diretamente com os dados experimentais, sejam reais ou simulados. Além disso, as RNAs conseguem integrar múltiplas variáveis de entrada e saída, simplificando o processo de previsão. Esta revisão de literatura busca sintetizar os trabalhos anteriores na aplicação de RNAs para a previsão dessas propriedades, identificando lacunas e tendências. Discute os tipos de redes utilizadas, variáveis de entrada e saída, e fontes de dados para treinamento, teste e validação dos modelos. Foi possível concluir que a aplicação das redes neurais para previsão das propriedades do gás natural é satisfatória e promissora, no entanto, ainda há desafios que precisam ser superados.

Palavras-chave: gás natural, redes neurais artificiais, propriedades físico-químicas.

Abstract

Natural gas (NG) is a mixture composed mainly of gaseous hydrocarbons. It contains low molecular weight components and consists primarily of methane and ethane. The physicochemical properties of natural gas are useful in various applications, such as designing pipelines, valves, meters, and other industrial process equipment. In engineering, the prediction of the physicochemical characteristics of natural gas, such as viscosity, density, compressibility factor, among others, is generally carried out in the laboratory or using correlations, one by one separately. However, determining the physicochemical properties of natural gas in the laboratory can be costly and time-consuming, as it requires the use of advanced analytical techniques, specialized equipment, and rigorous care in sampling and sample preparation to ensure accurate and reliable results. In this context, artificial neural networks (ANNs) have emerged as an effective and precise alternative. They learn directly from experimental data, whether real or simulated. Additionally, ANNs can integrate multiple input and output variables, simplifying the prediction process. This literature review aims to synthesize previous work on the application of ANNs to predict these properties, identifying gaps and trends. It discusses the types of networks used, input and output variables, and data sources for training, testing, and

validating the models. It was possible to conclude that the application of neural networks for predicting the properties of natural gas is satisfactory and promising; however, there are still challenges that need to be overcome.

Keywords: natural gas, artificial neural networks, physicochemical properties.

Introdução

O estudo da previsão das propriedades físico-químicas do gás natural (GN) é um tópico de pesquisa relacionado à indústria de petróleo e gás, com implicações para a engenharia, segurança e sustentabilidade ambiental. Tradicionalmente, métodos empíricos e equações de estado têm sido empregados para estimar essas propriedades com base em dados experimentais (Sanjari e Lay, 2012). No entanto, essas abordagens muitas vezes apresentam limitações em termos de precisão, tempo de execução e complexidade do sistema, pois requerem o uso de técnicas analíticas avançadas, equipamentos especializados e cuidados rigorosos na amostragem e na preparação de amostras para garantir resultados precisos e confiáveis.

As redes neurais artificiais têm se destacado como uma alternativa eficaz, sendo muito usadas para prever as propriedades físico-químicas do gás natural. Algumas dessas propriedades, como fator de compressibilidade, velocidade do som e viscosidade, são necessárias para o estudo de estratégias para o transporte, armazenamento do gás natural e otimização do processo de combustão (Chu et al., 2021). Ao longo dos anos, diversos estudos foram desenvolvidos para aprimorar as técnicas de predição dessas propriedades. Dentre as técnicas, destaca-se o uso de redes neurais artificiais (RNAs).

Esta revisão da literatura tem a finalidade em conhecer e sintetizar os trabalhos desenvolvidos anteriormente, a fim de apresentar um panorama do que já foi pesquisado na área e o estado atual das pesquisas que estão sendo realizadas, com o intuito de identificar as lacunas e as tendências da aplicação de redes neurais na previsão de propriedades físico-químicas do gás natural. Além disso, busca indicar e discutir os tipos de redes usadas, as variáveis de entrada e de saída, e como determinar as fontes de dados para treinar, testar e validar os modelos de redes.

Metodologia

Neste trabalho, a revisão foi realizada de forma assistemática, com o objetivo de analisar artigos que utilizaram RNAs para prever as propriedades do gás natural. A pesquisa da literatura foi conduzida nas bases de dados ScienceDirect, SciELO, Google Acadêmico e CAPES Periódicos. Foram utilizados termos de busca como “*natural gas*”, “*artificial neural network*”, “*physicochemical properties*”, e variações relacionadas ao tema proposto. Foram incluídos estudos que investigaram a utilização de redes neurais artificiais para predição das propriedades físico-químicas do gás natural.

Resultados e Discussão

A Tabela 1 apresenta um resumo dos principais pontos obtidos pela revisão dos artigos utilizados para esta pesquisa. Nela, são encontrados os tipos de redes neurais artificiais (RNA) empregados nos artigos, a origem dos dados utilizados para treinar, testar e validar as redes, as variáveis de saída e a avaliação dos modelos escolhidos que apresentaram melhor desempenho e precisão.

Tabela 1: Apresentação comparativa entre trabalhos utilizados na revisão literária e os principais resultados.

Autor (es)	Ano	Tipo de Rede Neural	Variáveis Independentes (Entrada)	Variáveis Dependentes (Saída)	Fonte dos Dados	Avaliação dos modelos
Kamyab et al.	2010	RNA FeedForward (LMA)	Ppr ⁽¹⁾ , Tpr ⁽²⁾	Z ⁽³⁾	Diagrama de Katz	EMA ⁽¹²⁾ = 0,106%
Lay, Peymani e Sanjari	2012	RNA Retropropagação (LMA)	PM ⁽⁴⁾ , Ppr, Tpr	μ ⁽⁵⁾	Dados experimentais (literatura)	DMRA ⁽¹³⁾ = 0,221%
Alquraishi e Shokir	2011	RNA GRN	PM, Ppr, Tpr ρ , Ppr, Tpr	ρ ⁽⁶⁾ μ	Medições experimentais (literatura)	EMA = 4,93% EMA = 3,65%
Sanjari e Lay	2012	RNA BPNN	Ppr, Tpr	Z	Dados experimentais	DMRA = 0,593%
Khosravi, Machado e Nunes	2018	(N1) GMDH	P ⁽⁷⁾ , T ⁽⁸⁾ , η ⁽⁹⁾	ρ	Dados coletados em campo	REMQ ⁽¹⁴⁾ = 0,2042 kg/m3
		(N2) ANFIS-GA	Ppr, Tpr	ρ		REMQ = 2,2735 kg/m3
		(N2) GMDH		Z		REMQ = 0,0054
Farzaneh-Gord et al.	2021	RNA MLP	P, T, η	Z	EOS combinadas com dados experimentais	DPMA ⁽¹⁵⁾ = 0,7%
Chu et al.	2021	AKC (RNA-KNN)	P, T, yi ⁽¹⁰⁾	Z', c ⁽¹¹⁾ , μ	Dados simulados	DMRA = 2,5%

⁽¹⁾ pressão pseudo-reduzida

⁽²⁾ temperatura pseudo-reduzida

⁽³⁾ fator de compressibilidade

⁽⁴⁾ peso molecular

⁽⁵⁾ viscosidade

⁽⁶⁾ densidade

⁽⁷⁾ pressão

⁽⁸⁾ temperatura

⁽⁹⁾ coeficiente Joule-Thomson

⁽¹⁰⁾ fração molar do GN

⁽¹¹⁾ velocidade do som

⁽¹²⁾ Erro Médio Absoluto

⁽¹³⁾ Desvio médio relativo absoluto

⁽¹⁴⁾ Raiz do erro médio quadrático

⁽¹⁵⁾ Desvio percentual médio absoluto

Neste estudo são apresentadas as observações feitas sobre os diferentes tipos de algoritmos de aprendizagem de máquina que tem sido aplicado nas pesquisas avaliadas, englobando desde os algoritmos mais utilizados até o mais complexo. Segundo Sanjari e Lay (2012), o algoritmo mais utilizado para prever as propriedades do gás natural é o algoritmo de aprendizagem por retropropagação.

As pesquisas analisadas utilizam algoritmos de aprendizagem de máquina em seus trabalhos, destacando o uso dos algoritmos de retropropagação, perceptron multicamadas (MLP), rede de regressão generalizada (GRN), K-Nearest Neighbor (KNN), Fuzzy Inference System (FIS), Adaptive Neuro Fuzzy Inference System (ANFIS), ANFIS otimizado com Algoritmo Genético (ANFIS-GA) e Multilayer FeedForward Neural Network (MLFFNN). Alguns deles combinam algoritmos, como mostrado nos trabalhos de Chu et al. (2021), que propuseram um novo método de combinação denominado AKC (Combinação RNA-KNN), e Khosravi, Machado e Nunes (2018) com o modelo ANFIS-GA.

Determinados modelos foram elaborados para prever o fator de compressibilidade, uma variável termodinâmica muito importante e utilizada na engenharia devido à sua aplicação industrial e científica. Alguns autores criaram modelos de redes mais simples para prever o fator de compressibilidade utilizando algoritmo de RNA *FeedForward*. Entretanto, esses modelos apresentaram características diferentes, seja nas variáveis de entrada ou na obtenção da fonte de dados.

Kamyab et al. (2010) propuseram um modelo de RNA *Feedforward* que utiliza o algoritmo Levenberg-Marguardt (LMA) e o diagrama de Standing-Katz para obter os dados e treinar as RNAs. Nesse estudo, os pesquisadores projetaram duas redes: a rede 2-5-5-1 e a rede 2-10-10-1. Ambas possuem a mesma estrutura (2 entradas e 1 saída), entretanto, com números diferentes de neurônios nas camadas ocultas. Segundo Kamyab et al. (2010), a rede 2-5-5-1 mostrou ser mais rápida; contudo, a rede 2-10-10-1 é mais precisa. Elas apresentaram um erro médio absoluto (EMA) de 0,2705% e 0,1060%, respectivamente, em comparação com a equação empírica de DAK (Dranchuk e Abou-Kassem).

Sanjari e Lay (2012) fizeram uma comparação entre os resultados do fator de compressibilidade obtidos com o modelo de RNA usando algoritmo de retropropagação e os modelos empíricos e equações de estado (EOS) Peng-Robinson (PR). Sanjari e Lay (2012) usaram um banco de dados experimentais para prever o fator de compressibilidade, utilizando pressão reduzida e temperatura reduzida como variáveis de entrada, e obtiveram um desvio médio relativo absoluto (DMRA) de 0,593% em relação à EOS de Peng-Robinson.

Lay, Peymani e Sanjari (2012) desenvolveram um modelo de RNA baseado no algoritmo de retropropagação (LMA) utilizando um banco de dados de diferentes misturas de gás natural obtidas na

literatura. Essas misturas incluíam pressão pseudo-reduzida, temperatura pseudo-reduzida e peso molecular, com o objetivo de estimar a viscosidade do GN. O modelo de RNA apresentou um desvio relativo médio absoluto de 0,2208% quando comparado aos dados experimentais de viscosidade. Além disso, a RNA projetada foi comparada a cinco modelos empíricos* e demonstrou prever a viscosidade do GN com precisão. Contudo, à medida que a complexibilidade dos sistemas que envolvem gás natural foi mais bem compreendida, os pesquisadores elaboraram técnicas mais avançadas.

Alquraishi e Shokir (2011) projetaram um modelo RNA GRN para construir duas redes neurais a fim de estimar a densidade e a viscosidade de gases de hidrocarbonetos. Um banco de dados foi montado com base na literatura para atender a uma grande faixa de pressão e temperatura. A pressão pseudo-reduzida, a temperatura pseudo-reduzida e o peso molecular foram os dados de entrada usados para estimar a densidade do gás, que, nesse modelo, é independente do fator de compressibilidade e apresentou um erro médio absoluto (EMA) de 4,93%. Entretanto, para prever a viscosidade, além de utilizar a pressão pseudo-reduzida e a temperatura pseudo-reduzida, foi utilizada a densidade como variável de entrada. O modelo superou as correlações testadas e mostrou um EMA de 3,65%.

Nesse seguimento, Khosravi, Machado e Nunes (2018) foram pioneiros ao desenvolver os métodos MLFFNN, FIS, GMDH, ANFIS e ANFIS-GA para prever a densidade e a compressibilidade do gás natural. Esses pesquisadores propuseram duas redes distintas (N1 e N2): a N1, específica para estimar a densidade em City Gas Stations, e a N2, para prever a densidade e o fator de compressibilidade.

A rede N1 usou dados reais de pressão, temperatura e coeficiente de Joule-Thomson, enquanto a rede N2 tinha como alvos separados a densidade e o fator de compressibilidade, utilizando dados reais de pressão pseudo-reduzida e temperatura pseudo-reduzida. Embora os algoritmos testados por Khosravi, Machado e Nunes (2018), tenham apresentado bons resultados na previsão das propriedades do GN, o GMDH foi o modelo que apresentou a melhor previsão para a rede N1, que tem como alvo a densidade, e para estimar o fator de compressibilidade da rede N2. Todavia, a combinação ANFIS-GA usada para modelar a rede N2 mostrou melhor precisão para prever a densidade. Para os dados de teste, apresentou uma raiz de erro médio quadrático (REMQ) igual a 2,2735.

Farzaneh-Gord et al. (2021), assim como Khosravi, Machado e Nunes (2018), também elaboraram um modelo que utiliza pressão, temperatura e coeficiente de Joule-Thomson como variáveis de entrada para prever uma única variável de saída: o fator de compressibilidade.

O modelo apresentado por Farzaneh-Gord et al. (2021) foi baseado em RNA MPL (Perceptron Multicamadas). Entretanto, utilizou a EOS GERG-2008 somada à combinação de dados experimentais

* Lee-Gonzalez-Eakin Method; Adel Elsharkawy Method; Carr-Kabayashi-Burrow Method; Heydarian-Moghadassi-Salarabadi Method; Sanjari-Nemati Lay-Peymani Method.

para obter as variáveis de entrada e, quando comparado à RNA MPL, alcançou um desvio percentual médio absoluto (DPMA) de 0,7%.

Para desenvolver o modelo AKC, Chu et al. (2021) utilizaram temperatura, pressão e fração do gás natural como variáveis de entrada. Esses dados foram obtidos através de dados experimentais e, diferente dos outros modelos, predizem três propriedades físico-químicas: velocidade do som, viscosidade e fator de compressibilidade como variáveis de saída em uma única rede. A rede combinada AKC apresentou um melhor DMRA de 2,5% comparado às RNA 5,9% e ao KNN 19,2% testados separadamente.

Neste contexto, assim como Chu et al. (2021), desenvolveram uma rede com três variáveis de saída, observou-se que seria interessante prever outras propriedades físico-químicas tão necessárias e importantes para o gás natural. Ainda faltam trabalhos que utilizem modelos de RNA para prever mais propriedades do GN em uma única rede, pois, como mostrado anteriormente, as redes neurais normalmente usam duas ou três variáveis de entrada para gerar uma variável de saída.

Conclusões

A análise crítica dos artigos revela que as redes neurais artificiais são ferramentas adequadas para a previsão de propriedades físico-químicas do gás natural, oferecendo precisão superior em comparação com EOS e os modelos empíricos. Estudos revisados mostraram que diferentes tipos de RNAs, como FeedForward, GRN, MLP, GMDH, e combinações como AKC (RNA-KNN), têm sido eficazes na previsão de propriedades como viscosidade, densidade e fator de compressibilidade.

Os modelos de RNAs apresentam precisão elevada e capacidade de lidar com a complexidade das propriedades do GN. No entanto, ainda há espaço para melhorias, como a criação de modelos que prevejam múltiplas propriedades simultaneamente com baixo custo computacional. Avançar nesta direção pode proporcionar ferramentas mais robustas e eficientes para a indústria de gás natural.

Agradecimentos

Ao Programa de Recursos Humanos da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (PRH/ANP – PRH36/UFBA), suportado com recursos provenientes do investimento de empresas petrolíferas qualificadas na Cláusula de PD&I da Resolução ANP nº 50/2015. Agradecemos, também, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Referências Bibliográficas

ALQURAISHI, A. A.; SHOKIR, E. M. Artificial neural networks modeling for hydrocarbon gas viscosity and density estimation. **Journal of King Saud University-Engineering Sciences**, v. 23, pág. 123-129, 2011. Disponível em: <https://doi.org/10.1016/j.jksues.2011.03.004>. Acesso em: 11 de janeiro de 2024.

CHU, J.; LIU, X.; ZHANG, Z.; ZHANG Y.; HE, M. A novel method overcomeing overfitting of artificial neural network for accurate prediction: Application on thermophysical property of natural gas. **Case Studies in Thermal Engineering**, Volume 28, 2021, Disponível em: <https://doi.org/10.1016/j.csite.2021.101406>. Acesso em: 05 de março de 2024.

FARZANEH-GORD, M.; RAHBARI, H. R.; MOHSENI-GHARESFA, B.; TOIKKA, A.; ZVEREVA, I.; Accurate determination of natural gas compressibility factor by measuring temperature, pressure and Joule-Thomson coeficiente; Artificial neural network approach, **Journal of Petroleum Science and Engineering**, Volume 202, 2021. Disponível em: <https://doi.org/10.1016/j.petrol.2021.108427>. Acesso em: 25 de janeiro de 2024.

KAMYAB, M.; SAMPAIO, J.H.B.; QANBARI F.; EUSTES A.W.; Using artificial neural networks to estimate the z-factor for natural hydrocarbon gases. **Journal of Petroleum Science and Engineering**, v. 73, n. 3-4, p. 248-257, 2010. Disponível em: <https://doi.org/10.1016/j.petrol.2010.07.006>. Acesso em: 10 de dezembro de 2023.

KHOSRAVI, A.; MACHADO, L.; NUNES, R. O. Estimation of density and compressibility factor of natural gas using artificial intelligence approach. **Journal of Petroleum Science and Engineering**, v. 168, p. 201-216, 2018. Disponível em: <https://doi.org/10.1016/j.petrol.2018.05.023>. Acesso em: 23 de fevereiro de 2024.

LAY, E. N.; PEYMANI, M.; SANJARI, E. Prediction of natural gas viscosity using artificial neural network approach. **International Journal of Chemical and Molecular Engineering**, v. 6, n. 7, p. 577-583, 2012. Acesso em: 24 de junho de 2024.

SANJARI, E.; LAY, E. N.; Estimation of natural gas compressibility factors using artificial neural network approach, **Journal of Natural Gas Science and Engineering**, v. 9, p. 220-226, 2012. Disponível em: <https://doi.org/10.1016/j.jngse.2012.07.002>. Acesso em: 20 de dezembro de 2023.