

基于数值仿真与神经网络的 CO₂ 封存效率优化

牛业超, 李霞, 孙一雪, 杨富, 逄昊焜, 李石*

(中国石油大学(华东)化学化工学院, 山东青岛 266580)

摘要:针对枯竭油气藏 CO₂ 注入过程中多机制封存性能缺乏快速评估工具的问题, 构建了基于 CMG-GEM 平台的三维油藏模型, 结合拉丁超立方抽样(LHS)生成 1 520 组参数场景, 模拟溶解俘获、残余俘获与结构圈闭 3 类封存机制的响应过程。通过斯皮尔曼秩相关系数(SRCC)识别关键控制参数, 并建立反向传播神经网络(BPNN)模型, 实现封存效率及机制贡献的快速预测。结果表明, 所建模型在 3 项指标上均具较高精度($R^2 > 0.98$, $RMSE < 0.01$), 可为封存方案优化与风险评估提供有效支持。

关键词: 枯竭油气藏; 二氧化碳封存; 反向传播神经网络; 风险评估

中图分类号: TE319; X701

文献标志码: A

文章编号: 0253-4320(2026)03-0230-06

DOI: 10.16606/j.cnki.issn0253-4320.2026.03.037

Optimization of CO₂ storage efficiency based on numerical simulation and neural network

NIU Ye-chao, LI Xia, SUN Yi-xue, YANG Fu, FENG Hao-kun, LI Shi*

(School of Chemistry and Chemical Engineering, China University of Petroleum (East China), Qingdao 266580, China)

Abstract: To address the lack of rapid evaluation tools for multi-mechanism CO₂ storage performance during CO₂ injection in depleted oil and gas reservoirs, a three-dimensional reservoir model was developed based on the CMG-GEM platform. Latin Hypercube Sampling (LHS) was employed to generate 1520 parameter scenarios, enabling the simulation of the responses of three major trapping mechanisms, namely solubility trapping, residual trapping, and structural trapping. Key controlling parameters were identified using the Spearman rank correlation coefficient (SRCC), and a backpropagation neural network (BPNN) model was established to achieve rapid prediction of storage efficiency and the contributions of individual trapping mechanisms. The results indicate that the proposed model exhibits high predictive accuracy for all three indices ($R^2 > 0.98$, $RMSE < 0.01$), demonstrating its effectiveness in supporting storage scheme optimization and CO₂ storage risk assessment.

Key words: depleted oil and gas reservoir; CO₂ storage; backpropagation neural network; risk assessment

随着全球气候变化问题日益严峻, 碳捕集与封存(carbon capture and storage, CCS)被认为是实现“碳达峰”与“碳中和”目标的重要技术路径之一^[1]。政府间气候变化专门委员会(IPCC)指出, 为将全球升温控制在 1.5°C 以内, 需在本世纪中叶前实现大规模 CO₂ 减排与封存^[2]。通过 CCS 技术将 CO₂ 注入深层地质体以实现长期封存, 是当前主要的负排放手段之一^[3-4]。

目前, 深层咸水层、枯竭油气藏、不可开采煤层及海底储层是 CO₂ 地质封存的主要场所^[5-6]。其中, 枯竭油气藏因具有良好的封闭性、成熟的钻井基础设施和丰富的开发数据^[7-8], 在封存安全性和经济性方面优势明显, 被认为是减少碳排放的切实可行方案之一^[9]。但 CO₂ 在油气藏中的封存过程涉及多机制协同作用^[10], 其效率和稳定性受多因素非线性耦合影响, 评价仍存在较大不确定性^[11]。数值

模拟技术可解析 CO₂ 多相渗流与传质过程, 是封存机制研究的重要工具^[12]。然而, 传统高保真模型在大规模多参数场景评估中计算成本高昂, 场景模拟耗时常达数日甚至数周, 难以满足封存场选址与快速评估需求。

近年来, 机器学习(machine learning, ML)技术被广泛应用于构建数值模拟的代理模型, 以提升 CO₂ 封存过程的预测效率^[13-15]。然而, 现有研究多聚焦于单一封存机制的预测, 缺乏对多机制协同作用的系统建模; 同时, 敏感性分析方法多基于局部样本, 难以有效覆盖高维参数空间, 限制了模型的可解释性和工程推广能力。

针对上述问题, 本文中构建了融合全局敏感性分析与机器学习的预测框架。基于 CMG-GEM 平台建立三维油藏模型, 结合拉丁超立方抽样(latin hypercube sampling, LHS)生成 1 520 组多参数工况,

收稿日期: 2025-06-16; 修回日期: 2026-01-05

作者简介: 牛业超(2001-), 女, 硕士生; 李石(1978-), 男, 博士, 副教授, 研究方向为石化行业节能降碳技术研究, 通讯联系人, lsh@upc.edu.cn。

模拟并定量表征3类封存机制。利用斯皮尔曼秩相关系数(spearman's rank correlation coefficient, SRCC)识别关键控制因素,明确各输入参数对溶解俘获、残余俘获与结构圈闭机制的相对影响。在此基础上,构建反向传播神经网络(backpropagation neural network, BPNN)模型,实现3类封存指数快速预测,并通过独立盲测样本验证泛化能力。研究结果可为CO₂封存机制解析、场址筛选与环境风险评估提供理论依据与技术支持。

1 方法

为系统分析枯竭油气藏中CO₂的封存行为,本文中构建了一套融合数值模拟与机器学习的数据驱动建模框架,如图1所示。包括多场景数值模拟、封存机制敏感性分析以及基于BP神经网络的封存效率预测。在保证物理合理性的前提下,该框架提高了建模效率,为封存风险识别与注入方案优化提供技术支持。

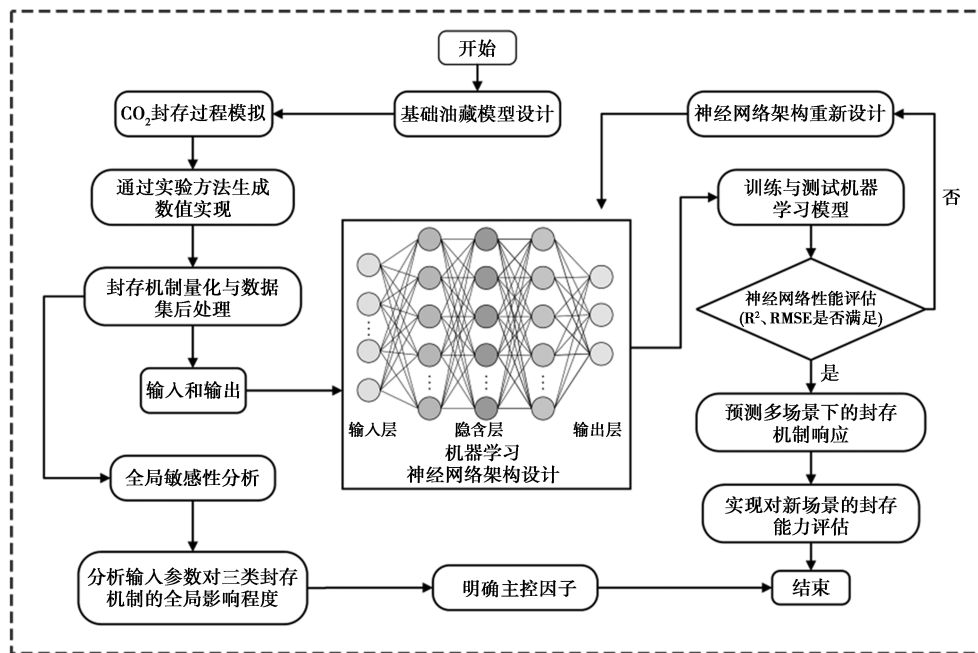


图1 枯竭油气藏CO₂封存行为建模流程

1.1 设计仿真模拟

基于CMG软件中的GEM模块,构建三维枯竭油藏模型,模拟CO₂的注入、迁移与封存过程,识别控制封存行为的关键地质与工程参数。模型初始状态假设油气藏历经长期开发,孔隙压力大幅降低、产能衰减至经济极限,处于典型的枯竭状态,同时具备完好盖层以保障CO₂封存的完整性与安全性。

模型采用结构化三维网格,横向方向分别划分为36×36个单元,垂向分为10层,共计12 960个网格。各向网格尺寸均匀,以兼顾模拟精度与计算效率。为更准确描述垂向流动特征,模型在垂向上设定细分网格,同时简化假设储层孔隙度与渗透率沿垂向均质分布,以突出整体规律性分析。

地质与工程参数参考典型文献与实际工程经验设定^[16],数值模拟的基准参数如表1所示。考虑超临界CO₂的PVT性质,利用CMG-GEM中的组分模型,模拟其在油相与水相中的溶解行为,同时引入残

余气体俘获和溶解俘获等机制,以更真实反映其封存过程。

表1 数值模拟基准参数及敏感性分析参数范围汇总

参数	基准值	下限	上限
有效厚度(h)/m	10	5	15
孔隙度(ϕ)	0.2	0.1	0.3
盐度(S_{sal})/(g·L ⁻¹)	150	50	150
渗透率(k)/mD	100	10	250
垂向与水平渗透率(K_v/K_h)	0.1	0.05	1
残余油饱和度(S_m)	0.28	0.2	0.4
残余气饱和度(S_{rg})	0.2	0.15	0.35
注入井底压力(P_{inj})/MPa	44.5	20	50
二氧化碳注入速率(Q_{CO_2})/(m ³ ·d ⁻¹)	10000	5000	50000

注入方案如图2所示,采用四周对称布井方式,形成环绕注入系统,模拟注入期为10 a,封存监测期为90 a,总模拟时长为100 a。边界条件设定为无流边界,以模拟封闭储层系统,排除外部干扰对CO₂迁移路径的影响。




图 2 三维结构化网格的油藏数值模拟模型布置图

1.2 数据生成与敏感性分析

为系统评估地质与工程参数对 CO_2 封存行为的影响,并为后续风险建模提供数据支撑,本文中基于油藏基础模型开展了敏感性分析与批量模拟工作,涵盖样本生成、封存机制量化、响应指标设定等关键环节。

1.2.1 参数空间构建

采用 LHS 方法,对 9 个主要控制参数进行全局敏感性分析,构建具有代表性的多维参数空间并生成机器学习模型所需的训练与验证数据集,具体参数范围与分布如表 1 所示。该方法通过分层等概率抽样策略,能够在样本量有限的情况下有效表征参数间的非线性耦合效应。

1.2.2 封存机制响应指标定义

基于 LHS 生成的 1 520 组参数组合,在 CMG-GEM 平台上执行批量模拟,每组对应 1 个独立的 CO_2 封存场景。模拟输出包括溶解相 CO_2 封存量、残余气相封存量及超临界气相质量等动态数据。为了评价 CO_2 注入过程的有效性,定量评估封存风险,研究结合 IPCC 提出的封存机制划分方法^[17],模拟过程中考虑了以下 3 类主要封存机制,并根据此定义响应指标^[18]。

(1) 溶解俘获机制

指 CO_2 逐步溶解于孔隙盐水中,形成热力学稳定的溶液,过程受温度、压力和盐度等因素控制。定义溶解俘获指数(solubility gas trapping index, STI)为:

$$\text{STI} = \frac{\text{溶解于盐水中的 } \text{CO}_2 \text{ 总质量(kg)}}{\text{注入 } \text{CO}_2 \text{ 总质量(kg)}} \quad (1)$$

(2) 残余气体俘获机制

在毛细压力作用下, CO_2 被困于孔隙中形成不可移动气相,其过程受岩石润湿性及残余气饱和度的影响。定义残余俘获指数(residual gas trapping index, RTI)为:

$$\text{RTI} = \frac{\text{以残余气相形式俘获的 } \text{CO}_2 \text{ 总质量(kg)}}{\text{注入 } \text{CO}_2 \text{ 总质量(kg)}} \quad (2)$$

$$\text{StTI} = \frac{\text{因浮力作用被结构圈闭的 } \text{CO}_2 \text{ 总质量(kg)}}{\text{注入 } \text{CO}_2 \text{ 总质量(kg)}} \quad (3)$$

CO_2 在非均质储层中上浮至顶部盖层处受阻,形成自由气聚集区,表现为结构圈闭与重力稳定。定义结构俘获指数(structural trapping index, StTI)为:

$$\text{StTI} = \frac{\text{因浮力作用被结构圈闭的 } \text{CO}_2 \text{ 总质量(kg)}}{\text{注入 } \text{CO}_2 \text{ 总质量(kg)}} \quad (3)$$

3 项俘获机制占比之和为 1,反映 CO_2 在不同物理机制下的最终赋存状态,作为后续多输出预测模型的目标变量。

1.2.3 数据集构建与归一化处理

由于 9 个输入变量在量纲与取值范围上差异较大,直接作为神经网络输入易影响模型训练稳定性。为此,采用 Min-Max 归一化方法将所有输入变量线性缩放至 $[0, 1]$ 区间,同时保持其相对分布特征,表达式如下:

$$x_i' = \frac{[x_i - \min(x_i)]}{[\max(x_i) - \min(x_i)]} \quad (4)$$

式中, x_i 为原始输入变量值; x_i' 为归一化后变量值; $\min(x_i)$ 与 $\max(x_i)$ 分别为第 i 个变量的最小值与最大值。

1.2.4 斯皮尔曼秩相关系数

为定量评估输入参数对 CO_2 封存机制响应指标的全局敏感性,并增强模型可解释性,采用 SRCC 进行分析。该方法可表征多参数非线性耦合条件下输入与输出之间的单调相关关系,计算公式如下:

$$\rho = 1 - \left(6 \sum_{i=1}^n d_i^2\right) / [n(n^2 - 1)] \quad (5)$$

式中, ρ 为斯皮尔曼秩相关系数; d_i 为第 i 个样本在 2 个变量秩次中的差值; n 为样本数量。系数取值范围为 $[-1, 1]$,当 ρ 趋近于 1 或 -1 时,表示变量间存在显著的正向或负向单调关系;当 ρ 近似于 0 时,则说明两者间无明显的单调性。

1.3 BP 神经网络模型建立

BP 神经网络是一种基于误差反向传播算法的前馈神经网络,具有较强的非线性拟合能力。该网络由输入层、隐藏层和输出层组成,采用均方误差(mean squared error, MSE)作为损失函数,通过反向传播与梯度下降算法迭代优化权重与偏置参数。

本文中基于 MATLAB 深度学习工具箱,采用 Resilient Backpropagation (Rprop, 训练函数为 trainrp) 构建前馈神经网络模型,输入为表 1 所列参数,输出为 3 类封存机制指标(STI、RTI、StTI)。数据集划分为训练集、验证集和测试集,模型训练以最小化训练集的 MSE 为目标,结合验证集性能判定模型收敛。模型性能通过决定系数(R^2)和均方根误差

(RMSE) 进行评价,以抑制过拟合并提高泛化能力,定义如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{i,true} - y_{i,pred})^2}{\sum_{i=1}^n (y_{i,true} - \bar{y}_{i,true})^2} \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{i,true} - y_{i,pred})^2} \quad (7)$$

式中, $y_{i,true}$ 、 $y_{i,pred}$ 分别为样本的真实值与神经网络预测值; $\bar{y}_{i,true}$ 为真实值均值; n 为样本总数。


2 结果与分析

2.1 全局敏感性分析


为评估输入参数对 3 类封存机制指标的影响,本文中采用 SRCC 表征 9 个地质-注采参数与 STI、RTI 及 StTI 之间的单调相关关系。结果显示,注入速率与 StTI 呈强正相关($\rho=0.64$),与 STI 呈强负相关($\rho=-0.71$),与 RTI 为弱-中等正相关($\rho=0.21$),表明在研究参数范围内注入速率的变化与封存机制分配呈最一致的单调响应趋势^[16]。盐度与 STI 为中等负相关($\rho=-0.50$),与 StTI 为中等正相关($\rho=0.48$),指示高盐度条件下溶解封存相关指标降低、结构型指标升高。渗透率与 RTI 呈较强负相关($\rho=-0.65$),而与 STI 和 StTI 的相关性较弱($\rho=0.13、0.12$),说明渗透率对残余气封存指标的单调响应更为突出。有效厚度与孔隙度与 STI 分别为正相关($\rho=0.32、0.35$),与 StTI 为弱负相关($\rho=-0.29、-0.31$)。 K_v/K_h 与 RTI 为弱负相关($\rho=-0.28$),其单调相关强度有限。其余参数(残余油饱和度、残余气饱和度、注入井底压力等)与 3 类指标的相关性均较弱($|\rho| \leq 0.05$),在本研究样本范围内未呈现明显的单调关联。

2.2 神经网络训练样本


基于 1 520 组油藏数值模拟结果构建 CO₂ 封存机制预测模型,图 3、图 4 分别展示了样本划分方式及 3 类封存机制指标的分布特征。各指标在样本空间中分布均匀,具有良好的离散性与覆盖性,可为神经网络建模提供可靠数据基础。为提升模型泛化能力并抑制过拟合,选取 1 290 组样本用于训练,其余



(a) STI 训练样本与盲样样本划分




(b) RTI 训练样本与盲样样本划分




(c) StTI 训练样本与盲样样本划分


图 3 神经网络训练样本与盲测样本的划分示意图



(a) STI 样本集分布



(b) RTI 样本集分布



(c) StTI 样本集分布

图 4 神经网络样本集在训练、验证与测试阶段的分布图

230 组作为独立盲测样本;训练样本按 70%-15%-15%划分为训练集、验证集和测试集,其中验证集用

于监控模型收敛并触发早停机制,测试集仅用于模型性能评估。

2.3 神经元和隐藏层的最优配置

神经网络中,隐藏层是刻画输入与输出之间非线性关系的关键结构,其层数与神经元数量直接影响模型的表达能力与泛化性能。为评估网络结构对预测精度的影响,本文中对神经元数量和隐藏层层数 2 个网络结构参数进行调优。首先,在单隐藏层结构下改变神经元数量(6~100),分析模型性能变化[图 5(a)];随后固定每层神经元数量为 15,逐步增加隐藏层层数至 14 层,比较模型在训练集与验证集上的表现[图 5(b)]。




图 5 BP 神经网络结构超参数调优结果

实验结果表明,适当提升网络复杂度可提高模型拟合能力与预测精度;但当网络结构过深或单层神经元数量过多时,训练时间显著增加,且验证集性能波动加剧,出现过拟合倾向。综合预测精度与计算效率,最终确定采用包含 3 个隐藏层、每层 15 个神经元的 BP 神经网络为最优配置,结构如图 6 所示。




图 6 BP 神经网络的结构拓扑图

2.4 BP 神经网络模型性能验证

图 7 展示训练过程中 MSE 随迭代变化。STI 模型在第 201 次迭代取得最优验证性能, MSE 为 0.001 584 6;RTI 与 SITI 模型分别在第 245 次和第 96 次迭代收敛,验证 MSE 为 0.006 146 8 和 0.003 297 8。训练与验证曲线趋势一致、无明显偏离,表明训练稳定,未见过拟合,模型收敛性与泛化能力较好。

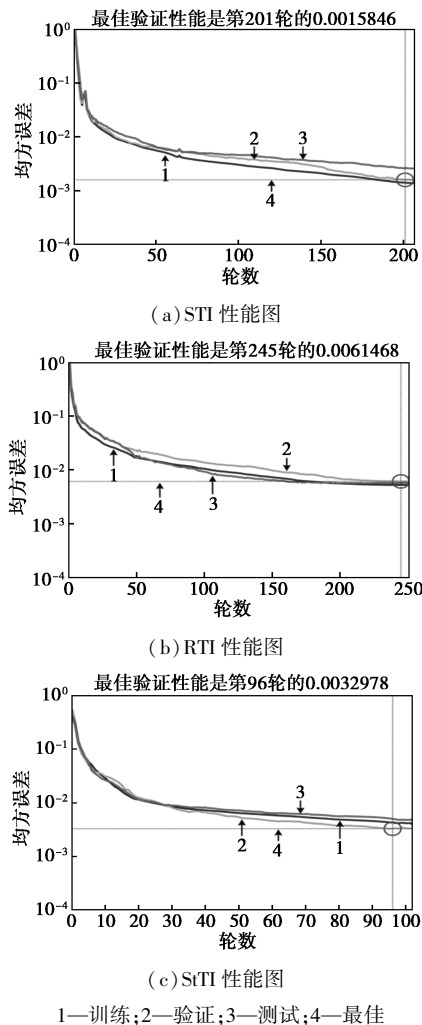




图 7 BP 神经网络在 3 类封存指标预测中的训练性能曲线


图 8 展示了模型在训练集、验证集和测试集上的预测值与数值模拟结果的对比关系。可以看出,



(a) STI 的样本集训练、验证、测试结果



(b) RTI 的样本集训练、验证、测试结果




(c) StTI 的样本集训练、验证、测试结果


图8 预测值与数值模拟值的相关性对比图

3类封存指标在各数据集上的预测结果与模拟值高度一致,散点整体紧贴对角线分布,表明模型具有良好的回归拟合能力。定量评价结果显示,STI、RTI与StTI模型的整体RMSE分别为0.0056、0.0074和0.0069,均处于较低水平,进一步验证了模型的稳定性、鲁棒性与泛化能力。


为检验模型在未见数据上的泛化能力,选取独立的230组数值模拟样本进行盲测。图9给出了3类指标在盲测样本上的预测-真实值对比,结果表明,BP模型对STI、RTI与StTI的预测 R^2 均高于0.98,说明模型具有良好的泛化性能与风险预测能力,可为实际封存情景下的风险评估提供支持。



(a) STI 盲测结果



(b) RTI 盲测结果



(c) StTI 盲测结果

图9 BP神经网络在盲测数据集上的预测结果对比图

2.5 模型计算效率对比分析

在评估数据驱动模型在实际工程应用中的潜力时,对比了BP神经网络与传统数值模拟方法在单场景封存预测任务中的平均计算耗时。传统数值模拟方法在完成一次完整的封存过程(注入+封存监测)时,平均耗时约960 s(16 min);而BP神经网络模型在完成同类预测时仅需约0.05 s,计算效率提升近4个数量级。结果表明,数据驱动方法在多场景、高维输入处理任务中展现出显著优势。

3 结论与展望

(1)基于CMG-GEM构建三维枯竭油气藏模型,采用LHS生成1520组情景,系统模拟CO₂迁移与封存过程,并提取溶解俘获、残余俘获与结构圈闭3类指标以量化机制贡献。

(2)SRCC结果表明,注入速率、渗透率与盐度为关键控制参数:注入速率促进结构圈闭而抑制溶解俘获;渗透率主导残余气相行为;盐度对STI与StTI呈相反作用。

(3)基于1290组样本建立的3层BPNN在训练与独立盲测中均获得较高精度($R^2 > 0.98$, RMSE < 0.01),可实现多场景封存行为快速预测。

(4)与数值模拟相比,BPNN单次预测约0.05 s,效率提升近4个数量级,适用于封存风险评估与选址优化;所提出的“数值模拟+机器学习”耦合框架在保持物理机制完整性的同时显著降低计算成本,具备工程应用潜力。

参考文献

- [1] Bradshaw J, Bachu S, Bonijoly D, et al. CO₂ storage capacity estimation: issues and development of standards [J]. International Journal of Greenhouse Gas Control, 2007, 1(1): 62-68.
- [2] IPCC. Climate Change 2023: Synthesis rReport. Contribution of working groups I, II and III to the sixth assessment report of the intergovernmental panel on climate change [R]. Geneva: IPCC, 2023.

(下转第241页)

计简单、综合性能好等优点,可为未来液氢加氢站的优化设计提供一种参考。

参考文献

- [1] 国家发展改革委,国家能源局.氢能产业发展中长期规划(2021—2035年)[EB/OL].(2022-03-23)[2025-05-04].https://www.gov.cn/xinwen/2022-03/24/content_5680975.htm.
- [2] 国家能源局.中国氢能发展报告(2025)[EB/OL].(2025-04-30)[2025-05-04].<https://www.nea.gov.cn/20250430/96022785b3a747248288ad1e57d3a025/c.html>.
- [3] 崔胜民.氢能技术:制备、储运与应用[M].北京:化学工业出版社,2024:202-203.
- [4] Tian Z, Lv H, Zhou W, *et al.* Review on equipment configuration and operation process optimization of hydrogen refueling station[J]. *International Journal of Hydrogen Energy*, 2022, 47(5): 3033-3053.
- [5] 冯一宁,朱绍伟,薛明喆,等.液氢加氢站加注过程焓分析[J].真空与低温,2024,30(4):417-423.
- [6] Gong C, Na H, Yun S, *et al.* Liquid hydrogen refueling stations as an alternative to gaseous hydrogen refueling stations: Process development and integrative analyses[J]. *eTransportation*, 2025, 23: 100386.
- [7] Gong C, Na H, Kim H, *et al.* Energy-efficient and sustainable design of a hydrogen refueling station utilizing the cold energy of liquid hydrogen[J]. *ACS Sustainable Chemistry & Engineering*, 2024, 12(37): 13763-13773.
- [8] 董林鑫.基于不同增压方式的液氢加氢站加氢流程研究[D].杭州:浙江大学,2023.
- [9] 韩冰川,陈永东,吴晓红,等.液氢加氢站热管理系统与核心装备技术分析[J].流体机械,2025,53(2):23-31.
- [10] Hu R Z, Yang B, Shi C Y, *et al.* Cryogenic cold energy recovery in liquid hydrogen refueling station with double-pipe heat exchanger[J]. *Journal of Renewable and Sustainable Energy*, 2023, 15(5): 054102.
- [11] Kang D, Mun H, Park J, *et al.* System design and economic evaluation of a liquid hydrogen superstation[J]. *Korean Journal of Chemical Engineering*, 2025, 42: 233-255.
- [12] 王荧光,蔡旭东,梁勇,等.循环工质对LNG冷能发电系统性能的影响[J].低碳化学与化工,2024,49(10):113-122.
- [13] 万腾,周卫红.液化天然气冷能回收系统的设计与优化分析[J].低碳化学与化工,2024,49(5):123-132.
- [14] Ghorbani B, Zengehboudi S, Saady N M, *et al.* Strategies to improve the performance of hydrogen storage systems by liquefaction methods: A comprehensive review[J]. *ACS Omega*, 2023, 8: 18358-18399.
- [15] 孙兰义,刘立新,薄守石,等.过程模拟实训——Aspen HYSYS教程[M].2版.北京:中国石化出版社,2018:374-378.
- [16] 李光让,马倩倩,魏瑾,等.基于LNG接收站的氢气液化流程设计与优化[J].低碳化学与化工,2024,49(9):113-122.
- [17] Mun H, Park S, Lee I. Liquid hydrogen cold energy recovery to enhance sustainability: Optimal design of dual-stage power generation cycles[J]. *Energy*, 2023, 284: 129229.
- [18] Joy J, Chowdhury K. Enhancing generation of green power from the cold of vaporizing LNG at 30 bar by optimising heat exchanger surface area in a multi-staged organic Rankine cycle[J]. *Sustainable Energy Technologies and Assessments*, 2021, 43: 100930.
- [19] 杨键萍,潘振,张丽,等.基于太阳能和LNG冷能的朗肯循环系统热力学分析[J].辽宁石油化工大学学报,2019,39(2):47-53.
- [20] 刘梅梅.中小型LNG气化站冷能利用研究[D].荆州:长江大学,2020.■
- (上接第235页)
- [3] 阳平坚,彭栓,王静,等.碳捕集、利用和封存(CCUS)技术发展现状及应用展望[J].中国环境科学,2024,44(1):404-416.
- [4] 赵志强,张贺,焦畅,等.全球CCUS技术和应用现状分析[J].现代化工,2021,41(4):5-10.
- [5] Zhu D, Peng S, Zhao S, *et al.* Comprehensive review of sealant materials for leakage remediation technology in geological CO₂ capture and storage process[J]. *Energy & Fuels*, 2021, 35(6): 4711-4742.
- [6] 周新媛,唐国强,赵连增,等.二氧化碳封存现状及经济性初探[J].油气与新能源,2022,34(6):20-28,49.
- [7] Alcalde J, Flude S, Wilkinson M, *et al.* Estimating geological CO₂ storage security to deliver on climate mitigation[J]. *Nature Communications*, 2018, 9(1): 2201.
- [8] 姜睿.二氧化碳封存技术在油气行业应用进展[J].当代石油石化,2022,30(2):34-38.
- [9] Zhou X, Wu Y S, Chen H, *et al.* Review of carbon dioxide utilization and sequestration in depleted oil reservoirs[J]. *Renewable and Sustainable Energy Reviews*, 2024, 202: 114646.
- [10] Wei B, Wang B, Li X, *et al.* CO₂ storage in depleted oil and gas reservoirs: A review[J]. *Advances in Geo-Energy Research*, 2023, 9(2): 76-93.
- [11] Cao C, Liu H, Hou Z, *et al.* A review of CO₂ storage in view of safety and cost-effectiveness[J]. *Energies*, 2020, 13(3): 600.
- [12] Kim Y, Jang H, Kim J, *et al.* Prediction of storage efficiency on CO₂ sequestration in deep saline aquifers using artificial neural network[J]. *Applied Energy*, 2017, 185: 916-928.
- [13] Liu M, Li Z, Qi J, *et al.* Prediction of CO₂ storage in different geological conditions based on machine learning[J]. *Energy & Fuels*, 2024, 38(22): 22340-22350.
- [14] Yamada K, Fernandes B R B, Kalamkar A, *et al.* Development of a hydrate risk assessment tool based on machine learning for CO₂ storage in depleted gas reservoirs[J]. *Fuel*, 2024, 357: 129670.
- [15] Vo Thanh H, Sugai Y, Sasaki K. Application of artificial neural network for predicting the performance of CO₂ enhanced oil recovery and storage in residual oil zones[J]. *Scientific Reports*, 2020, 10(1): 18204.
- [16] Abdulwarith A, Ammar M, Dindoruk B. Prediction/Assessment of CO₂ EOR and storage efficiency in residual oil zones using machine learning techniques[C]. *Proceedings of the 2024 Carbon Capture, Utilization, and Storage Conference (SPE/AAPG/SEG)*. Houston, USA, 2024-03-11—2024-03-13.
- [17] Metz B, Davidson O, De Coninck H, *et al.* IPCC special report on carbon dioxide capture and storage[M]. Cambridge: Cambridge University Press, 2005.
- [18] Nghiem L, Shrivastava V, Tran D, *et al.* Simulation of CO₂ storage in saline aquifers[C]. *SPE/EAGE Reservoir Characterization & Simulation Conference*. Abu Dhabi, United Arab Emirates, 2009.■