

# 超临界CO<sub>2</sub>注入井筒腐蚀预测模型研究进展

鲁佳伟, 唐伟茗, 周文豪, 付梦祥, 饶瀚博, 张伟豪, 朱俊鑫, 赵明轩, 郑 或, 刘 键  
重庆科技大学石油与天然气工程学院, 重庆

收稿日期: 2026年2月28日; 录用日期: 2026年4月10日; 发布日期: 2026年4月30日

## 摘 要

超临界CO<sub>2</sub>注入井筒作为CCUS技术工程化应用的核心环节, 面临高温高压、多杂质耦合、多相流冲刷的复杂腐蚀环境, 井筒腐蚀失效直接威胁工程安全与长效运行, 而精准的腐蚀预测是开展腐蚀防控的关键前提。本文以超临界CO<sub>2</sub>注入井筒腐蚀预测模型为研究核心, 系统梳理了传统经验模型、半经验模型、机理模型的研究现状、适用范围及局限性, 重点介绍了机器学习、神经网络等前沿算法在腐蚀预测中的应用进展, 分析了不同模型在超临界CO<sub>2</sub>井筒腐蚀预测中的适配性与现存问题, 最后展望了腐蚀预测模型的未来发展方向。研究表明: 传统模型虽奠定了腐蚀预测的理论基础, 但受限于多因素耦合作用的复杂性, 难以适配超临界CO<sub>2</sub>井筒的极端工况; 以机器学习、神经网络为代表的智能预测模型, 凭借强非线性拟合与多源数据处理能力, 成为超临界CO<sub>2</sub>腐蚀预测的前沿发展方向, 但目前仍存在样本数据不足、模型可解释性差、工程化验证缺乏等问题。未来需推动传统机理模型与智能算法的融合, 构建多场耦合、数据驱动的一体化腐蚀预测模型, 为超临界CO<sub>2</sub>注入井筒的腐蚀防控提供精准技术支撑。

## 关键词

超临界CO<sub>2</sub>, 注入井筒, 腐蚀预测, 机理模型, 机器学习, CCUS

# Research Progress on Corrosion Prediction Models of Supercritical CO<sub>2</sub> Injection Wellbores

Jiawei Lu, Weiming Tang, Wenhao Zhou, Mengxiang Fu, Hanbo Rao, Weihao Zhang, Junxin Zhu, Mingxuan Zhao, Yu Zheng, Jian Liu

School of Petroleum Engineering, Chongqing University of Science and Technology, Chongqing

Received: February 28, 2026; accepted: April 10, 2026; published: April 30, 2026

## Abstract

As the core link in the engineering application of CCUS technology, supercritical CO<sub>2</sub> injection wells

文章引用: 鲁佳伟, 唐伟茗, 周文豪, 付梦祥, 饶瀚博, 张伟豪, 朱俊鑫, 赵明轩, 郑或, 刘键. 超临界 CO<sub>2</sub> 注入井筒腐蚀预测模型研究进展[J]. 矿山工程, 2026, 14(3): 506-514. DOI: 10.12677/me.2026.143052

face a complex corrosion environment characterized by high temperature, high pressure, multi-impurity coupling, and multiphase flow erosion. Wellbore corrosion failure directly threatens engineering safety and long-term operation, and accurate corrosion prediction is a critical prerequisite for corrosion prevention and control. This paper focuses on corrosion prediction models for supercritical CO<sub>2</sub> injection wells. It systematically reviews the research status, applicable scope, and limitations of traditional empirical models, semi-empirical models, and mechanistic models. It highlights the application progress of advanced algorithms such as machine learning and neural networks in corrosion prediction, and analyzes the adaptability and existing problems of different models in supercritical CO<sub>2</sub> wellbore corrosion prediction. Finally, the future development trends of corrosion prediction models are prospected. Studies show that although traditional models have laid a theoretical foundation for corrosion prediction, they are limited by the complexity of multi-factor coupling and are difficult to adapt to the extreme working conditions of supercritical CO<sub>2</sub> wells. Intelligent prediction models represented by machine learning and neural networks have become the frontier development direction of supercritical CO<sub>2</sub> corrosion prediction by virtue of their strong nonlinear fitting and multi-source data processing capabilities. However, they still suffer from insufficient sample data, poor model interpretability, and lack of engineering verification. In the future, it is necessary to promote the integration of traditional mechanistic models and intelligent algorithms, and build an integrated corrosion prediction model driven by multi-field coupling and data, so as to provide accurate technical support for the corrosion prevention and control of supercritical CO<sub>2</sub> injection wells.

## Keywords

Supercritical CO<sub>2</sub>, Injection Wellbore, Corrosion Prediction, Mechanistic Model, Machine Learning, CCUS

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

气候变化是 21 世纪全球面临的重大挑战之一[1]。政府间气候变化专门委员会的报告指出,2011~2020 年全球地表温度较 1850~1900 年已升高 1.1℃, 如不采取有效措施, 2030 年温室气体排放可能导致升温超过 1.5℃ [2]。在此背景下, 碳捕集、利用与封存技术被公认为最具前景的减排路径之一[3]。国际能源署数据显示, 2022 年全球能源相关的 CO<sub>2</sub> 排放量达到 36.8 Gt, 创历史新高, 凸显了 CCUS 技术规模化应用的紧迫性[4]。

在 CCUS 技术链条中, 注入井筒是连接地面输送与地下封存的核心枢纽。为避免两相流并提升输送效率, CO<sub>2</sub> 通常被压缩至超临界状态进行注入[5]-[7]。然而, 工业捕集的 CO<sub>2</sub> 并非纯净, 不可避免地含有 H<sub>2</sub>O、O<sub>2</sub>、SO<sub>x</sub>、NO<sub>x</sub>、H<sub>2</sub>S 等杂质。这些杂质在超临界条件下耦合作用, 形成高温高压、多相流冲刷的极端腐蚀环境, 严重威胁井筒的长期完整性[8]。美国 PHMSA 的统计表明, 1986~2008 年间 CO<sub>2</sub> 输送管道事故中, 腐蚀所致占比高达 45% [9], 因而精准的腐蚀预测是保障 CCUS 工程安全运行的技术前提。

腐蚀预测模型的发展经历了从经验关联到机理认知、再到数据驱动的演进历程[10]-[12]。然而, 超临界 CO<sub>2</sub> 环境具有特殊复杂的性质, 流体物性易发生突变、杂质间存在协同作用、腐蚀产物膜处于动态演化过程, 这些特征均对传统预测方法提出了严峻挑战[13]-[17]。近年来, 人工智能技术快速发展, 机器学习凭借其优异的非线性拟合能力与多源数据处理优势, 为超临界 CO<sub>2</sub> 腐蚀预测提供了全新思路与技术路

径[18]-[20]。本文系统梳理超临界 CO<sub>2</sub> 注入井筒腐蚀预测模型的研究进展，重点分析各类方法的技术特点、适用场景与现存问题，并对未来发展方向进行展望，以期为 CCUS 工程中的腐蚀防控提供理论参考。

## 2. 传统腐蚀预测模型

传统 CO<sub>2</sub> 腐蚀预测模型可归纳为三类：经验模型、半经验模型和机理模型[21]。这三类模型构成了腐蚀预测的理论基础，在特定条件下展现出实用价值，但也存在各自的局限性。

### 2.1. 经验模型与半经验模型

经验模型是最早发展的腐蚀预测方法，其核心思想是基于实验数据拟合腐蚀速率与关键影响因素之间的统计关系。最具代表性的是 De Waard-Milliams 模型及其后续改进版本(De Waard 93 模型、De Waard 95 模型等)，这些模型建立了温度、CO<sub>2</sub> 分压、pH 值等因素与腐蚀速率的经验关联式[22]。挪威船级社的 Norsok M-506 模型则进一步考虑了流速、壁面剪切力等因素的影响，成为工业界广泛采用的腐蚀评估工具[23]。

半经验模型在经验关联的基础上引入部分机理认知，如考虑腐蚀产物膜的抑制效应、传质过程的影响等[21]。De Waard 93 模型引入了“腐蚀产物膜因子”来修正裸钢腐蚀速率，体现了对腐蚀过程的深化认识[24]。这类模型在一定程度上扩展了适用范围，但其核心参数仍依赖于特定实验条件的拟合，外推至超临界工况时可靠性存疑。

经验与半经验模型的优势在于形式简洁、计算快捷，便于工程初步评估。然而，其局限性同样显著：首先，模型建立在特定实验数据基础上，难以涵盖超临界条件下多杂质耦合的复杂场景[13] [25]；其次，对于腐蚀产物膜的动态演化、杂质间的协同效应等非线性过程，经验关联式往往难以准确描述[6] [13]；再者，超临界 CO<sub>2</sub> 的物性突变导致传统模型基于亚临界条件建立的关联关系失效[26]。这些局限使得经验模型在 CCUS 注入井筒这类极端工况下的应用面临严峻挑战。

### 2.2. 机理模型

机理模型立足于腐蚀电化学、传质过程、热力学平衡等基本原理解释，试图从物理化学本质上描述腐蚀过程[27]。这类模型通常包含多个子模块：热力学溶解度模型、离子平衡模型、电化学反应模型、腐蚀产物膜生长模型和传质模型等[28]。

在热力学模型方面，Duan 等建立了适用于海水环境的 CO<sub>2</sub> 溶解度模型，能够计算两相及三相共存条件下的溶解度变化[29]-[31]。Spycher 等基于 Redlich-Kwong 状态方程和 Pitzer 活度方程，建立了 CO<sub>2</sub>-盐水相分配模型[32]。这些热力学模型为腐蚀预测提供了关键的溶液化学基础。

电化学机理模型的代表性工作源于 Nesic 团队，他们开发的 FREECORP 软件集成了电化学腐蚀与产物膜生长的耦合过程[33]。Anderko 等则构建了模拟 FeCO<sub>3</sub> 和 FeS 产物膜影响的综合模型，并集成于 OLI 软件平台[34]。OLI 最新发布的 V12.5 版本进一步扩展了混合溶剂电解质腐蚀框架，新增 S13Cr、S15Cr、S17Cr、316 SS、Alloy 625 等合金的支持，能够在非水、水贫乏等复杂体系中基于第一性原理进行腐蚀预测[35]。该平台通过热力学形态计算与电化学动力学的集成，实现了对超临界 CO<sub>2</sub> 腐蚀、氯化物腐蚀等场景的定量预测。

针对含杂质体系，Xiang 等建立了超临界 CO<sub>2</sub> 条件下含 SO<sub>2</sub>-O<sub>2</sub>-H<sub>2</sub>O 杂质的管线钢腐蚀预测模型[36]。Zheng 等开发了 CO<sub>2</sub>/H<sub>2</sub>S 体系中碳钢腐蚀的预测模型，为含 H<sub>2</sub>S 杂质体系的预测提供了理论基础[37]。最近，Ding 等提出了一种适用于封存井套管系统的多杂质耦合超临界 CO<sub>2</sub> 腐蚀预测模型，该模型集成了热力学溶解度模型、物种平衡模型、电化学模型、腐蚀产物膜生长模型和传质模型，能够计算

离子浓度、产物膜厚度和腐蚀速率等参数的动态演化[38]。该研究采用遗传算法与牛顿迭代法相结合的求解策略,既发挥了遗传算法处理非线性多峰问题的全局寻优能力,又利用了牛顿迭代法在局部区域的快速收敛特性。

机理模型的优势在于具有较强的理论基础和一定的外推能力,能够揭示腐蚀过程的物理化学本质。然而,其局限性也不容忽视:一是模型参数众多,许多参数在实际工程中难以获取[39];二是计算复杂度高,特别是采用有限元方法求解时,长周期模拟的计算成本难以承受[13];三是对于超临界条件下杂质耦合的复杂机理,现有理论认识仍不完善[38]。

### 3. 智能预测模型研究进展

面对传统模型在超临界 CO<sub>2</sub> 复杂工况下的局限,以机器学习、神经网络为代表的驱动方法近年来受到广泛关注[16]。这类方法不依赖预先设定的机理假设,而是直接从数据中学习输入参数与腐蚀速率之间的映射关系,展现出处理非线性、高维问题的独特优势[40]。

#### 3.1. 机器学习方法的应用

机器学习在腐蚀预测中的应用涵盖多种算法,包括随机森林、支持向量机、梯度提升决策树、K 近邻、多层感知器等[18]。这些算法在常规 CO<sub>2</sub> 腐蚀预测中已取得一定成效,但将其应用于超临界条件时,仍面临诸多挑战[41]。

丹麦技术大学的一项研究基于文献数据构建了包含杂质影响的腐蚀数据集,采用决策树、随机森林和 TreeNet 三种树模型对腐蚀速率进行预测[18]。结果表明,SO<sub>2</sub>、H<sub>2</sub>O 和 O<sub>2</sub> 是影响全面腐蚀和局部腐蚀的最显著因素。在模型性能方面,随机森林和 TreeNet 在训练集上表现出最低的误差,其中随机森林在测试集上的预测效果最优。考虑到计算复杂度较低,研究者推荐随机森林作为实际应用的优先选择。

国内学者也开展了相关探索。有研究提出基于神经遗忘决策集成的油管 CO<sub>2</sub> 腐蚀速率预测方法[42],该方法结合半经验模型预测结果和多维特征构建数据集,在某实例井的腐蚀预测中取得良好效果。这一思路体现了融合机理认知与数据驱动的初步尝试。

#### 3.2. 深度神经网络的前沿探索

深度神经网络以其强大的表达能力,成为超临界 CO<sub>2</sub> 腐蚀预测的前沿方向[43]-[45]。2025 年发表的一项研究首次将 Kolmogorov-Arnold 网络引入 CO<sub>2</sub> 腐蚀速率预测领域[18]。KAN 网络的理论基础是 Kolmogorov-Arnold 表示定理,其独特之处在于:传统 MLP 在神经元节点上应用固定激活函数,而 KAN 在连接边上学习可变的激活函数,通常采用样条函数(spline functions)作为参数化形式。这一架构使其能够更高效地逼近复杂的多元函数,并且通过学习得到的样条函数形状,可以直观地分析输入特征对输出的影响——例如,某个特征的样条函数若呈现单调递增趋势,则表明该特征对腐蚀速率具有正向促进作用;若呈现复杂波动,则可能反映该特征与其他因素的交互作用。文献[18]中通过可视化特征重要性排序,验证了 KAN 模型能够识别出 SO<sub>2</sub>、O<sub>2</sub> 等杂质的关键影响,从而提供了一定程度的可解释性。

研究者基于 43 篇文献的实验数据构建了包含溶解 O<sub>2</sub>、H<sub>2</sub>S、SO<sub>2</sub> 浓度及含水率等参数的独特数据集,对 KAN 模型进行了系统优化[18]。结果表明,最优网络配置为 3 层、grid 参数为 3;与传统 MLP 相比,KAN 模型在预测精度、计算速度和损失值方面均显著更优。更重要的是,KAN 模型展现出超越传统黑箱模型的可解释性潜力。

#### 3.3. 智能模型在超临界环境中的适配性分析

智能模型应用于超临界 CO<sub>2</sub> 腐蚀预测具有以下优势:一是能够捕捉多杂质耦合的非线性效应,传统

模型难以处理的协同作用可通过数据学习来表征[41]；二是可以融合多源异构数据，如实验数据、现场数据、理论计算结果等[46]；三是模型具有较强的自适应能力，可通过新数据的加入持续优化[40]。

然而，智能模型在超临界环境中的应用仍面临严峻挑战。首先是数据问题：超临界 CO<sub>2</sub> 腐蚀实验成本高、周期长，公开发表的可靠数据有限[38]。KAN 模型研究的数据集仅包含 43 篇文献，这在机器学习领域属于小样本学习。其次是模型可解释性问题：尽管 KAN 展现出一定潜力，但多数神经网络仍是“黑箱”，难以提供腐蚀机理层面的洞察[18]。再次是工程化验证不足：现有研究多基于实验数据，在实际注入井筒工况下的验证有待加强[47]。

## 4. 模型适配性分析与存在问题

### 4.1. 不同模型的适用边界

综合上述分析，三类模型在超临界 CO<sub>2</sub> 注入井筒腐蚀预测中各有其适用边界。为便于直观对比，表 1 从基本原理、关键输入参数、优势、局限性及超临界工况下的特定挑战五个维度，对各类模型进行了系统总结。

**Table 1.** Comparison of corrosion prediction models for wellbores under supercritical CO<sub>2</sub> injection  
**表 1.** 超临界 CO<sub>2</sub> 注入井筒腐蚀预测模型对比

模型类型	基本原理	关键输入参数	优势	局限性	在超临界 CO <sub>2</sub> 工况下的特定挑战
经验	基于实验数据拟合	温度、CO <sub>2</sub> 分压、pH 等	形式简洁、计算快捷	依赖特定实验条件，适用性差	难以涵盖多杂质耦合、物性突变
半经验	在经验关联基础上引入机理修正因子	温度、CO <sub>2</sub> 分压、流速、产物膜因子等	考虑部分机理，适用范围稍广	核心参数仍依赖实验拟合	对腐蚀产物膜动态演化描述不足
机理	基于电化学与传质等理论	溶液化学、电化学参数、传质系数等	理论基础强，揭示本质	参数多、计算复杂，理论认识不完善	超临界条件下杂质耦合机理不明确
机器学习	从数据中学习映射	多特征(杂质浓度、温压、流速等)	处理非线性、高维问题能力强	依赖数据质量，可解释性差	样本数据不足，外推能力存疑
深度神经网络	多层神经网络学习复杂映射	多特征(杂质浓度、温压、流速等)	表达能力强，捕捉复杂交互	需要大量数据，外推能力受限	数据稀疏时易过拟合，可解释性挑战

### 4.2. 核心瓶颈问题

从上述不同腐蚀预测模型的对比可以看出，各类模型在超临界 CO<sub>2</sub> 注入井筒场景下均存在明显的局限性。综合来看，当前超临界 CO<sub>2</sub> 注入井筒腐蚀预测研究主要存在以下三方面核心瓶颈：

一是多杂质耦合的腐蚀机理认识仍不充分。虽然已有研究识别出 SO<sub>2</sub>、O<sub>2</sub>、H<sub>2</sub>S 等杂质对腐蚀的影响，但多种杂质同时存在时的相互作用规律尚不明确。尤其在超临界温压条件下，流体物性和腐蚀环境变化剧烈，现有的机理认识难以完整描述复杂的腐蚀过程，限制了模型的适用范围。

二是高质量实验数据不足，数据分布不均衡。超临界 CO<sub>2</sub> 腐蚀实验成本高、周期长，公开的实验数据在工况范围、材料种类、环境参数等方面覆盖有限，难以满足智能模型训练所需的数据规模与多样性。数据偏少、代表性不足会直接影响模型精度与泛化能力。

三是模型在实际工程中的验证不够充分。现有模型大多基于实验室理想条件建立，对真实井筒中多相流冲刷、温压波动、材料受力等复杂工况考虑不足，缺少在实际注入井现场的长期验证。模型从实验室到工程应用仍存在一定差距。

## 5. 未来发展方向

### 5.1. 机理 - 数据融合模型

机理模型与数据驱动方法的融合是突破当前瓶颈的重要路径[48]-[50]。通过机理模型提供腐蚀过程的先验知识,明确电化学反应路径与传质控制步骤,进而生成仿真数据以补充实验样本的不足;同时,利用机器学习从实验数据中学习机理模型未能捕捉的非线性特征和杂质协同效应。例如,物理信息网络(PINN)将控制方程作为损失函数的一部分嵌入网络训练,使预测结果同时满足物理守恒律和数据分布,提升了模型的外推能力与机理一致性[48]。遗传算法与牛顿迭代法的结合应用已展现出这种融合思路的潜力。未来可进一步探索基于符号回归的公式发现方法,从数据中直接提取可解释的腐蚀规律。

### 5.2. 多场耦合一体化模型

注入井筒的腐蚀行为是流动场、温度场、应力场、化学场多场耦合的结果[51]-[54]。现有模型多聚焦于电化学腐蚀过程,对流动冲刷的力学-化学耦合效应、热应力对产物膜稳定性的影响等关注不足。因此需整合计算流体力学、有限元分析和电化学动力学等多学科方法,构建多场耦合的一体化预测模型。

### 5.3. 可解释人工智能的应用

黑箱性质是智能模型在腐蚀领域推广应用的主要障碍之一[55]。KAN网络的初步探索表明[18],通过设计具有可解释性的网络架构,可以在保持预测精度的同时提供特征重要性分析。未来可进一步引入注意力机制、符号回归等方法,从数据中提取可解释的腐蚀规律,形成“预测-理解-决策”的闭环。

### 5.4. 数字孪生与全生命周期管理

数字孪生为注入井筒腐蚀全生命周期管理提供了全新技术路径[56]。通过构建井筒虚拟映射模型,融合现场监测数据与腐蚀预测模型,可实现腐蚀状态实时评估与早期预警。未来可进一步打通设计、运行、检修全流程数据,实现腐蚀风险动态跟踪与防护策略闭环优化,提升井筒长期安全运行与智能化管理水平。

### 5.5. 不确定性量化与风险评估

对于安全攸关的井筒完整性管理,仅提供腐蚀速率的单点预测值远不能满足工程决策的需求,必须对预测结果的不确定性进行量化[57]。智能模型天然具备处理不确定性的潜力:贝叶斯神经网络通过对网络权重赋予先验分布,能够输出预测的后验分布,从而给出置信区间[58];蒙特卡洛 dropout 通过在测试时开启随机失活,近似贝叶斯推断,得到预测方差[59];集成学习方法则可利用多个模型的预测差异来估计不确定性[60]。这些方法将预测结果从确定性数值扩展为包含置信区间的概率分布。未来研究应致力于将不确定性量化模块嵌入腐蚀预测模型,推动从确定性评估向概率风险评估的转变。

## 6. 结论

1) 超临界 CO<sub>2</sub> 注入井筒的腐蚀预测是保障 CCUS 工程安全运行的关键技术环节。传统经验模型、半经验模型和机理模型奠定了腐蚀预测的理论基础,但在面对多杂质耦合、高温高压、多相流冲刷的极端工况时,各自存在适用范围局限、参数获取困难、计算复杂度高等问题。

2) 以机器学习、神经网络为代表的智能预测模型展现出处理非线性、高维腐蚀问题的独特优势。随机森林等树模型在多杂质影响分析中表现优异;KAN 网络等新型深度学习方法在预测精度和可解释性方面取得突破。

3) 当前研究面临的核心瓶颈包括：多杂质耦合机理认知不足、高质量训练数据匮乏、模型工程化验证缺失。解决这些问题需要机理研究与数据驱动方法的深度融合。

4) 未来发展方向包括：构建机理 - 数据融合模型以兼顾理论一致性与预测精度；发展多场耦合一体化模型以反映井筒真实服役环境；引入可解释人工智能技术以提升模型透明性；发展不确定性量化方法以实现概率风险评估；探索数字孪生方法以实现全生命周期的腐蚀智能管理。

## 参考文献

- [1] 姜克隽. IPCC 1.5°C特别报告发布, 温室气体减排新时代的标志[J]. 气候变化研究进展, 2018, 14(6): 640-642.
- [2] 水煮花生. 联合国政府间气候变化专门委员会第六次综合评估报告发布[J]. 科学, 2023, 75(3): 10.
- [3] Maqui, D.M. and Choi, A.E. (2026) Carbon Capture, Utilization, and Storage: Scientific Basis, Practical Applications, and Climate Role. *Chemical Engineering Journal Advances*, **25**, Article 101049. <https://doi.org/10.1016/j.cej.2026.101049>
- [4] IEA (2023) CO<sub>2</sub> Emissions in 2022. International Energy Agency. <https://www.iea.org/reports/co2-emissions-in-2022>
- [5] 赵海军, 魏爱华, 彭昊, 等. 非均质多孔介质超临界 CO<sub>2</sub> 非混相驱替特征及机理研究[J]. 工程地质学报, 2024, 32(5): 1825-1837.
- [6] Ding, H., Xiang, Y., Zhang, Y., Yang, Z., Zhao, Z., Yan, K., et al. (2025) A Mechanistic Corrosion Prediction Model for the Casing System of Sequestration Wells in Supercritical CO<sub>2</sub>-Saturated Aqueous Environment with Multi-Impurities. *Corrosion Science*, **256**, Article 113203. <https://doi.org/10.1016/j.corsci.2025.113203>
- [7] 李裴晨. 超临界 CO<sub>2</sub> 驱替流特性及分注工艺研究[D]: [硕士学位论文]. 荆州: 长江大学, 2020.
- [8] Zhu, R., Honda, H., Zhang, L. and Zhu, J. (2025) Effect of Impurities on Supercritical CO<sub>2</sub> Corrosion in Carbon Capture and Storage: A Review. *Geoenergy Science and Engineering*, **255**, Article 214092. <https://doi.org/10.1016/j.geoen.2025.214092>
- [9] PHMSA (2025) Pipeline Safety Data Report Index. U.S. Department of Transportation, Pipeline and Hazardous Materials Safety Administration. <https://www.phmsa.dot.gov/data-and-statistics/pipeline/pipeline-safety-data-report-index>
- [10] Li, R.Y., Wang, H.C., Zhu, Y.H., et al. (2025) Machine Learning-Assisted *in Situ* Corrosion Monitoring: A Review. *Corrosion Reviews*, **44**, Article 20250014.
- [11] Nestic, S., Nordsveen, M., Nyborg, R. and Stangeland, A. (2001) A Mechanistic Model for CO<sub>2</sub> Corrosion with Protective Iron Carbonate Films. *CORROSION* 2001, Houston, 11-16 March 2001, 1-28. <https://doi.org/10.5006/c2001-01040>
- [12] Chen, L.C., Wang, S., Lu, X.Y., et al. (2025) Research on Corrosion Prediction Model Based on Mechanism and Data Fusion. *2025 Pressure Vessels and Piping Conference*, Montreal, 20-25 July 2025, V006T09A006.
- [13] 刘广瑜, 支树洁, 柳歆, 等. CCUS 超临界/密相 CO<sub>2</sub> 管道内腐蚀研究进展[J]. 油气储运, 2024, 43(5): 510-523.
- [14] 丁天聪, 杨帅, 孙冲, 等. 超临界 CO<sub>2</sub> 和 H<sub>2</sub>S 环境中 N80 钢腐蚀形态及腐蚀膜演化机制[J]. 中国石油大学学报(自然科学版), 2025, 49(6): 224-233.
- [15] Huang, C., Zhang, W., yan, J., Gu, T., Fan, H., Sun, L., et al. (2025) Dynamic Evolution of Corrosion Products and Their Influence on Carbon Steel Corrosion in Supercritical CO<sub>2</sub>. *The Journal of Supercritical Fluids*, **224**, Article 106670. <https://doi.org/10.1016/j.supflu.2025.106670>
- [16] Sun, C., Sun, J., Wang, Y., Sui, P., Lin, X., Liu, H., et al. (2017) Effect of Impurity Interaction on the Corrosion Film Characteristics and Corrosion Morphology Evolution of X65 Steel in Water-Saturated Supercritical CO<sub>2</sub> System. *International Journal of Greenhouse Gas Control*, **65**, 117-127. <https://doi.org/10.1016/j.ijggc.2017.09.002>
- [17] Sun, C., Ding, T., Sun, J., Lin, X., Zhao, W. and Chen, H. (2023) Insights into the Effect of H<sub>2</sub>S on the Corrosion Behavior of N80 Steel in Supercritical CO<sub>2</sub> Environment. *Journal of Materials Research and Technology*, **26**, 5462-5477. <https://doi.org/10.1016/j.jmrt.2023.08.277>
- [18] Dong, Z., Zou, L., Xu, Y., Guo, C., Wen, F., Wang, W., et al. (2025) Kolmogorov-Arnold Network for Predicting CO<sub>2</sub> Corrosion and Performance Comparison with Traditional Data-Driven Approaches. *Processes*, **13**, Article 3174. <https://doi.org/10.3390/pr13103174>
- [19] Seto, E., Li, M. and Liu, J. (2024) Predicting Corrosion Severity of Pipeline Steels in Supercritical CO<sub>2</sub> Environments Using Supervised Machine Learning. *CONFERENCE 2024*, New Orleans, 3-7 March 2024, 1-15. <https://doi.org/10.5006/c2024-20803>
- [20] 中国石油化工股份有限公司, 中石化安全工程研究院有限公司. 一种基于随机森林和改进型 ACE 算法的富 CO-

- 2 相腐蚀预测方法[P]. 中国专利, 202410088903.3. 2025-07-22.
- [21] Simonsen, K.R., Ostadi, M., Zychowski, M., Pedersen, S. and Bram, M.V. (2026) Review of CO<sub>2</sub> Corrosion Modeling for Carbon Capture, Utilization and Storage (CCUS) Infrastructure. *Processes*, **14**, Article 170. <https://doi.org/10.3390/pr14010170>
- [22] Doiron, A. and Papavinasam, S. (2009) Prediction of Internal Corrosion of Oil and Gas Pipelines: Miscellaneous Models. *Picon Journal*.
- [23] Olsen, S., Halvorsen, A.M., Lunde, P.G. and Nyborg, R. (2005) CO<sub>2</sub> Corrosion Prediction Model—Basic Principles. *CORROSION* 2005, Houston, 3-7 April 2005, 1-13. <https://doi.org/10.5006/c2005-05551>
- [24] de Waard, C., Lotz, U. and Milliams, D.E. (1991) Predictive Model for CO<sub>2</sub> Corrosion Engineering in Wet Natural Gas Pipelines. *CORROSION* 1991, Cincinnati, 11-15 March 1991, 1-16. <https://doi.org/10.5006/c1991-91577>
- [25] Yan, Y., Lyu, W., Yu, H., Lv, W., Wei, K. and Jiang, L. (2025) Advances in Synergistic Corrosion Mechanisms of and Management Strategies for Impurity Gases during Supercritical CO<sub>2</sub> Pipeline Transportation. *Molecules*, **30**, Article 4094. <https://doi.org/10.3390/molecules30204094>
- [26] 陈兵, 张萧玉, 房启超, 等. 含杂质超临界 CO<sub>2</sub> 输送管道水膜生成模拟及腐蚀威胁预测[J]. 腐蚀与防护, 2025, 46(3): 68-76.
- [27] Zhang, Z. (2008) A Study of Top-of-the-Line Corrosion under Dropwise Condensation. Ohio University.
- [28] Zhang, Z., Hinkson, D., Singer, M., Wang, H. and Nešić, S. (2007) A Mechanistic Model of Top-of-the-Line Corrosion. *Corrosion*, **63**, 1051-1062. <https://doi.org/10.5006/1.3278321>
- [29] Duan, Z. and Sun, R. (2003) An Improved Model Calculating CO<sub>2</sub> Solubility in Pure Water and Aqueous NaCl Solutions from 273 to 533 K and from 0 to 2000 Bar. *Chemical Geology*, **193**, 257-271. [https://doi.org/10.1016/s0009-2541\(02\)00263-2](https://doi.org/10.1016/s0009-2541(02)00263-2)
- [30] Min, G. and Rowe, D.M. (2000) Improved Model for Calculating the Coefficient of Performance of a Peltier Module. *Energy Conversion and Management*, **41**, 163-171. [https://doi.org/10.1016/s0196-8904\(99\)00102-8](https://doi.org/10.1016/s0196-8904(99)00102-8)
- [31] Zerai, B. (2006) Carbon Dioxide Sequestration in Saline Aquifer: Geochemical Modeling, Reactive Transport Simulation and Single-Phase Flow Experiment. Case Western Reserve University.
- [32] Spycher, N. and Pruess, K. (2010) A Phase-Partitioning Model for CO<sub>2</sub>-Brine Mixtures at Elevated Temperatures and Pressures: Application to CO<sub>2</sub>-Enhanced Geothermal Systems. *Transport in Porous Media*, **82**, 173-196. <https://doi.org/10.1007/s11242-009-9425-y>
- [33] Institute for Corrosion and Multiphase Technology (2008) Freecorp Software Released by ICMT. [https://www.icmt.ohio.edu/Articles/2008/10/03-Freecorp\\_software\\_release.asp](https://www.icmt.ohio.edu/Articles/2008/10/03-Freecorp_software_release.asp)
- [34] Anderko, A. (2000) Simulation of FeCO<sub>3</sub>/Fes Scale Formation Using Thermodynamic and Electrochemical Models. *CORROSION* 2000, Orlando, 26-31 March 2000, 1-18. <https://doi.org/10.5006/c2000-00102>
- [35] Spica, C. (2025) Smarter Models, Safer Assets, Broader Chemistry in OLI v12.5 Release. OLI Systems, Inc. <https://olisystems.com/resources/blog/smarter-models-safer-assets-broader-chemistry-oli-v12-5-release/>
- [36] Xiang, Y., Wang, Z., Xu, M., Li, Z. and Ni, W. (2013) A Mechanistic Model for Pipeline Steel Corrosion in Supercritical CO<sub>2</sub>-SO<sub>2</sub>-O<sub>2</sub>-H<sub>2</sub>O Environments. *The Journal of Supercritical Fluids*, **82**, 1-12. <https://doi.org/10.1016/j.supflu.2013.05.016>
- [37] Zheng, Y., Ning, J., Brown, B. and Nešić, S. (2015) Electrochemical Model of Mild Steel Corrosion in a Mixed H<sub>2</sub>S/CO<sub>2</sub> Aqueous Environment in the Absence of Protective Corrosion Product Layers. *Corrosion*, **71**, 316-325. <https://doi.org/10.5006/1287>
- [38] Simons, A., Tavangar, R., Verbeke, K. and Depover, T. (2025) A Review of Corrosion in Flowing Conditions during Dense Phase CO<sub>2</sub> Transport for Carbon Capture, Utilization, and Storage (CCUS). *Engineering Failure Analysis*, **181**, 109905. <https://doi.org/10.1016/j.engfailanal.2025.109905>
- [39] Saleh, A.F., Kamardin, M.Z., Safi, S.N. and Ahmad, M.F. (2021) Optimizing CAPEX and OPEX for High CO<sub>2</sub> and H<sub>2</sub>S Field by Using Mechanistic Corrosion Modelling Approach. *Abu Dhabi International Petroleum Exhibition & Conference*, Abu Dhabi, 15-18 November 2021, SPE-207696-MS. <https://doi.org/10.2118/207696-ms>
- [40] Mitraningsih, F., Hartoyo, F., Tarigan, W.L., Hidayat, M.I.P. and Pramata, A.D. (2025) A Comparative Study of Supervised Machine Learning Application for CO<sub>2</sub> Top of Line Corrosion Prediction. *MECC 2025, Dhahran Expo*, 11-13 November 2025, 1-15. [https://doi.org/10.5006/m2025\\_00092](https://doi.org/10.5006/m2025_00092)
- [41] Kumari, P., Halim, S.Z., Kwon, J.S. and Quddus, N. (2022) An Integrated Risk Prediction Model for Corrosion-Induced Pipeline Incidents Using Artificial Neural Network and Bayesian Analysis. *Process Safety and Environmental Protection*, **167**, 34-44. <https://doi.org/10.1016/j.psep.2022.07.053>
- [42] 周驰宇, 张智, 王杨, 等. 基于神经遗忘决策集成的油管 CO<sub>2</sub> 腐蚀速率预测[J]. 中国安全生产科学技术, 2023,

- 19(6): 127-134.
- [43] 郑度奎, 胡晨章, 蒲月华. 基于人工神经网络的油气管道 CO<sub>2</sub> 腐蚀速率预测研究进展[J]. 热加工工艺, 2021, 50(18): 25-31.
- [44] 席金杨, 徐继法, 任乐, 等. 超临界 CO<sub>2</sub> 运输管道腐蚀模式聚类分析[J]. 工业安全与环保, 2025, 51(11): 67-71.
- [45] 马良涛, 董海防, 朱刚, 等. 神经网络预测海洋环境下金属腐蚀速率的应用及研究[J]. 材料保护, 2018, 51(9): 35-39.
- [46] 李阳, 张建, 范振宁, 等. 齐鲁石化-胜利油田 CO<sub>2</sub> 长输管道数智化关键技术与创新实践[J]. 天然气工业, 2024, 44(9): 1-12.
- [47] Valdez, M., Morales, C., Polisenio, J., Choi, Y., Wang, X., Morland, B.H., *et al.* (2025) Evaluation of Various Downhole Materials under Simulated CCUS Environments—Supercritical CO<sub>2</sub> with Impurities and Comparison of Different Experimental Techniques. *CONFERENCE 2025*, Nashville, 6-10 April 2025, 1-17. <https://doi.org/10.5006/c2025-00035>
- [48] Su, F., Yin, A., Qiao, Z. and Wang, X. (2025) Physical Constraint-Based LSTM for Pipeline Corrosion Prediction. *Engineering Research Express*, 7, Article 045294. <https://doi.org/10.1088/2631-8695/ae1d16>
- [49] Zhou, T.T., Liu, Y.Z., Zheng, W.P., *et al.* (2025) Pipeline Corrosion Prediction Method Based on Physics-informed Neural Networks. *Journal of Chinese Society for Corrosion and protection*, 45, 1320-1330.
- [50] Bonneville, C., Bieberdorf, N., Hegde, A., Asta, M., Najm, H.N., Capolungo, L., *et al.* (2025) Accelerating Phase Field Simulations through a Hybrid Adaptive Fourier Neural Operator with U-Net Backbone. *npj Computational Materials*, 11, Article No. 14. <https://doi.org/10.1038/s41524-024-01488-z>
- [51] Lv, W., Liang, T., Lu, C., Li, M., Zhou, P., Yu, X., *et al.* (2025) Flow and Corrosion Analysis of CO<sub>2</sub> Injection Wells: A Case Study of the Changqing Oilfield CCUS Project. *Processes*, 13, Article 439. <https://doi.org/10.3390/pr13020439>
- [52] Cao, H., Xiong, Z., Guo, H., Lu, Z., Xu, Z. and Bai, L. (2024) Mechanical Degradations of Fe-C Alloys Induced by Stress Corrosion in Supercritical CO<sub>2</sub> Environments: A Study Based on Molecular Dynamics Simulation and Machine Learning. *Journal of Materials Science*, 59, 17609-17624. <https://doi.org/10.1007/s10853-024-10188-4>
- [53] Pfennig, A. and Kranzmann, A. (2012) Effect of CO<sub>2</sub> and Pressure on the Stability of Steels with Different Amounts of Chromium in Saline Water. *Corrosion Science*, 65, 441-452. <https://doi.org/10.1016/j.corsci.2012.08.041>
- [54] 何世明, 陈俞霖, 马德新, 等. 井壁稳定多场耦合分析研究进展[J]. 西南石油大学学报(自然科学版), 2017, 39(2): 81-92.
- [55] Braham, E.J., Ruddock, J.M. and Hardin, J.O. (2025) Generating and Leveraging Explanations of AI/ML Models in Materials and Manufacturing Research. *Patterns*, 6, Article 101340. <https://doi.org/10.1016/j.patter.2025.101340>
- [56] Vieira dos Santos, M., Menezes Duarte Rosa, R., Alves de Oliveira, L., Newmar, C., Rodrigues Gonalves da Silva, F., Fasolin, K., *et al.* (2022) Development and Deployment of Digital Twin for Production and Well Integrity. *SPE Annual Technical Conference and Exhibition*, Houston, 3-5 November 2022, SPE-210260-MS. <https://doi.org/10.2118/210260-ms>
- [57] Bacheaga Cruz, J.P., Veruz, E.G., Aoki, I.V., Schleder, A.M., de Souza, G.F.M., Vaz, G.L., *et al.* (2026) Uniform Corrosion Assessment in Oil and Gas Pipelines Using Commercial Corrosion Prediction Models—Part 2: Uncertainty and Risk Considerations Based on Statistical Analyses of Gravimetric Laboratorial Tests, Offshore Pipelines Inspections, and Manufacturing Tolerances. *Journal of Loss Prevention in the Process Industries*, 100, Article 105836. <https://doi.org/10.1016/j.jlpi.2025.105836>
- [58] Blundell, C., Cornebise, J., Kavukcuoglu, K., *et al.* (2015) Weight Uncertainty in Neural Network. *International Conference on Machine Learning*, Lille, 6-11 July 2015, 1613-1622.
- [59] Gal, Y. and Ghahramani, Z. (2016) Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning. 2016 *International Conference on Machine Learning*, New York, 19-24 June 2016, 1050-1059.
- [60] Lakshminarayanan, B., Pritzel, A. and Blundell, C. (2017) Simple and Scalable Predictive Uncertainty Estimation Using Deep Ensembles. 2017 *Advances in Neural Information Processing Systems*, Long Beach, 4-9 December 2017, 1-12.