

DOI:10.19651/j.cnki.emt.2620590

南部沿海炼化装置腐蚀速率 TL-BiLSTM-Attention 智能预测^{*}

黄琛昊¹ 刘桂雄¹ 林壮敦² 袁武飞² 吴海泓³

(1. 华南理工大学机械与汽车工程学院 广州 510640; 2. 广东省特种设备检测研究院揭阳检测院 揭阳 522031;
3. 广东省特种设备检测研究院惠州检测院 惠州 516003)

摘要: 中国南部沿海炼化装置服役环境复杂、多源环境因素耦合显著,金属设备在长期服役中易产生加速腐蚀,亟需构建高精度预测模型以辅助设备健康管理。针对炼化装置腐蚀数据样本有限(目标域样本量 $N=12$)问题,本文提出一种结合迁移学习的 TL-BiLSTM-Attention 大气腐蚀速率预测方法。首先基于 MICAT 公共腐蚀数据集构建源域数据集,随后通过正交实验优化 BiLSTM-Attention 网络超参数,提高预训练模型性能,最后将最优预训练模型迁移至炼化装置本地腐蚀数据,通过不同冻结层策略实现微调。实验表明,BiLSTM-Attention 模型在源域预测中相比 LSTM、BiLSTM 具有更高拟合能力与更低误差;TL-BiLSTM-Attention 能够有效提升炼化装置中 Q235、304、316L、5A06 等材料的大气腐蚀速率预测精度,不同金属需采用差异化冻结策略以获得最佳结果。研究验证 TL-BiLSTM-Attention 方法在少样本条件下预测有效性、工程适用性,可为炼化装置腐蚀评估提供数据驱动的预测工具。

关键词: 腐蚀速率预测;迁移学习;少样本;BiLSTM-Attention

中图分类号: TN06;TE986 **文献标识码:** A **国家标准学科分类代码:** 430.4099;460.4030

Intelligent prediction of corrosion rate in southern coastal refinery units using TL-BiLSTM-Attention

Huang Chenhao¹ Liu Guixiong¹ Lin Zhuangdun² Yuan Wufei² Wu Haihong³

(1. School of Mechanical and Automotive Engineering, South China University of Technology, Guangzhou 510640, China;
2. Jieyang Inspection Institute, Guangdong Special Equipment Inspection and Research Institute, Jieyang 522031, China;
3. Huizhou Inspection Institute, Guangdong Special Equipment Inspection and Research Institute, Huizhou 516003, China)

Abstract: Refining units in southern coastal China operate in complex service environments where multiple environmental factors are strongly coupled, making metallic equipment prone to accelerated corrosion during long-term operation. High-accuracy prediction models are therefore needed to support equipment health management. To address the limited availability of corrosion data in refining units (target-domain sample size $N=12$), this study proposes an atmospheric corrosion-rate prediction method termed TL-BiLSTM-Attention, which integrates transfer learning with a BiLSTM-Attention network. First, a source-domain dataset is constructed from the public MICAT corrosion dataset. Then, orthogonal experiments are conducted to optimize the hyperparameters of the BiLSTM-Attention network to improve the performance of the pre-trained model. Finally, the optimal pre-trained model is transferred to the local corrosion dataset of the refining units, and fine-tuning is performed under different layer-freezing strategies. Results show that, in the source domain, the BiLSTM-Attention model achieves stronger fitting capability and lower errors than LSTM and BiLSTM. In the target domain, TL-BiLSTM-Attention improves the prediction accuracy of atmospheric corrosion rates for materials such as Q235, 304, 316L, 5A06 and different metals require differentiated freezing strategies to obtain the best performance. This study verifies the predictive effectiveness and engineering applicability of TL-BiLSTM-Attention under few-shot conditions and provides a data-driven tool for corrosion assessment in refining units.

Keywords: corrosion rate prediction; transfer learning; few-shot; BiLSTM-Attention

0 引言

炼化装置作为石油化工生产关键设备,其安全运行直

接关系到能源产业的稳定与社会经济的持续发展^[1]。尤其
是中国南部沿海地区气候湿热、盐雾浓度高、污染物种类复
杂,金属设备在服役过程中易受到多因素耦合作用而产生

收稿日期:2026-01-16

^{*} 基金项目:2024 年揭阳市社会发展领域科技计划项目(SHFZ2024020)资助

加速腐蚀,导致结构性能退化,造成安全隐患^[2],故研究温度、湿度、盐雾浓度、气体污染物等多源环境数据的炼化装置大气腐蚀速率预测模型构建方法对于提升炼化装置运行稳定性具有重要意义^[3]。目前,金属大气腐蚀建模包括函数^[4-5]、机器学习^[6-7]和神经网络^[8-9]等建模方法。其中函数建模根据腐蚀机理研究与数据分析提出金属材料腐蚀随时间变化规律函数,如文献[4]研究了 1070A 和 6063 铝合金在模拟海洋大气腐蚀环境下的失重变化与腐蚀动力学,并指出腐蚀失重与腐蚀时间呈幂指数关系;文献[5]结合灰色关联度分析法开展 3 种不锈钢腐蚀行为相关性研究,获得其在污染海洋大气环境下的腐蚀寿命预测幂函数,但目前函数建模多基于特定环境或材料经验拟合,难以刻画多源环境因素耦合作用下腐蚀过程的非线性与时序演化特征,在环境变化或小样本条件下精度低。机器学习建模通过训练学习历史数据获取特征间潜在关系,借助回归、分类等算法映射输入数据生成预测结果,如文献[6]基于室外暴露试验数据,利用随机森林模型对低合金钢大气腐蚀速率进行预测,为炼化装置暴露部件腐蚀评估提供数据驱动支撑;文献[7]应用随机森林、支持向量回归、多层感知器等 3 种机器学习算法有效构建土壤埋置钢材腐蚀电流密度回归预测模型,但现有机器学习建模依赖人工特征与静态映射关系,难以充分挖掘腐蚀过程中时序依赖特征,在小样本条件下易出现泛化能力不足问题。深度神经网络建模通过多层非线性结构求取提取环境参数与腐蚀速率复杂关系,有效捕获腐蚀过程动态变化特征,如文献[8]采用遗传算法优化 BP 神经网络(back propagation neural network),建立接地网腐蚀速率预测模型,腐蚀速率预测值 RMSE、MAPE 均得到显著提高;文献[9]研究 Transformer-LSTM(long short-term memory network)模型用于管道腐蚀速率预测,其平均绝对误差、均方根误差和平均绝对百分比误差等多项指标比 LSTM 明显提升。尽管深度神经网络具备较强的非线性建模能力,但其多依赖大样本与标准数据集训练,在炼化装置复杂工况及少样本场景下仍面临适应性与泛化能力不足的问题。近年来,“迁移学习(transfer learning, TL)^[10]+预测模型”方法在少样本条件下已表明是提升腐蚀预测模型预测性能有效手段^[11-13],如文献[12]将腐蚀加速试验数据通过迁移学习应用到室外长期大气腐蚀预测,并比较冻结层微调策略效果;文献[13]使用迁移学习将实验仿真数据迁移到自然环境中混凝土钢腐蚀情形,提升小样本条件下预测性能。

本文针对南部沿海炼化装置实际腐蚀数据获取周期长、时间分辨率低、环境参数复杂、腐蚀变化趋势不显著等状况,引入迁移学习技术,与双向长短期记忆网络(Bi-directional long short-term memory, BiLSTM)、注意力机制(Attention)相结合,研究 TL-BiLSTM-Attention 预测方法,突破少样本条件下($N=12$)炼化装置大气腐蚀速率预测难、预测精度低等关键问题。

1 TL-BiLSTM-Attention 预测方法机理

图 1 给出本文 TL-BiLSTM-Attention 方法的总体流程,包含数据集准备、模型预训练与模型迁移 3 部分。考虑到南部沿海炼化装置腐蚀监测周期长、采集成本高,现场可用于建模的目标域数据集 D_T 仅 $N=12$ 条(工况覆盖有限),直接在 D_T 上训练模型,容易出现参数学习不足与过拟合,难以稳定学习腐蚀速率的时序演化规律,进而造成预测精度下降。为突破小样本瓶颈,本文引入 TL,选取样本充足的金属大气腐蚀公共数据集 MICAT^[14]作为源域 D_s 。MICAT 来自 Ibero-American Map of Atmospheric Corrosiveness 项目,包含伊比利亚美洲 14 个国家、72 个沿海暴露试验场数据,其长期高湿、盐雾强且温度偏暖/季节性高温的沿海特征与华南沿海环境具有一致性,可用于炼化装置腐蚀预测模型的预训练,该论文被引用次数达 125 次。表 1 列出 MICAT 数据集中预测目标与环境因子及其单位,预测目标为碳钢大气腐蚀速率 R_{Fe} ;输入因子包括大气温度 T_{air} 、相对湿度 H_{air} 、潮湿时间 TOW (表面存在水膜/电解质的累计时间)、降水量 P 、氯化物沉积速率 S_{Cl^-} (表征海盐影响)和二氧化硫沉积速率 S_{SO_2} (表征工业污染影响),共同刻画热湿条件、水膜持续与腐蚀介质沉积水平。




图 1 TL-BiLSTM-Attention 预测方法总体功能流程
Fig. 1 Overall functional of the TL-BiLSTM-Attention prediction method

表 1 MICAT 数据集中预测目标与环境因子及其单位
Table 1 The MICAT dataset predicts the target and environmental factors and their units

参数	单位
碳钢大气腐蚀速率(R_{Fe})	$\mu\text{m}/\text{y}$
大气温度(T_{air})	$^{\circ}\text{C}$
大气湿度(H_{air})	%RH
潮湿时间(TOW)	year
降水量(P)	mm
氯化物沉积速率(S_{Cl^-})	mg/d
二氧化硫沉积速率(S_{SO_2})	$\text{mg}/\text{m}^2\cdot\text{d}$

在数据集准备阶段,依据表1选取腐蚀速率与环境因子构建 MICAT 多变量时间序列,并采用 TimeGAN(time-series generative adversarial networks)^[15] 进行数据增强:通过自编码重构对齐幅值分布、监督网络约束时间转移关系、生成器-判别器对抗训练保持时序依赖与变量耦合,生成与原数据同维度的合成样本;随后将合成样本与原始样本合并、剔除异常数据,得到用于 BiLSTM-Attention 预训练的源域数据集 D_s 。最后,在 D_s 上完成模型预训练并保存最优权重,再将权重迁移到目标域 D_T ,利用少量目标域样本进行微调/域适配,实现知识从源域向目标域迁移,从而在小样本条件下提升炼化装置腐蚀速率预测的精度与泛化能力。

下文详细讨论 TL-BiLSTM-Attention 预测方法工作机理。

1.1 BiLSTM-Attention 预测模型

与传统递归神经网络(recurrent neural network, RNN)相比,LSTM作为一种特殊 RNN,通过引入输入门、遗忘门、输出门,使得其能更好地处理序列中长期依赖关系^[16]。图2为面向碳钢大气腐蚀速率预测的 LSTM 单元门控结构示意图,其中激活函数 Sigmoid 为 σ ,按位相乘、相加的运算分别为 $\otimes$ 、 $\oplus$ 。在 t 时刻输入 $(t-1)$ 时刻 LSTM 记忆细胞状态 c_{t-1} 、隐藏层状态 h_{t-1} ;又将 t 时刻 T_{air} 、 H_{air} 、 TOW 、 P 、 S_{Cl^-} 、 S_{SO_2} 参数数据输入 x_t ,那么所输出该时刻碳钢大气腐蚀速率 R_{Fe} 对应 LSTM 记忆细胞状态 c_t 、隐藏层状态 h_t 。




图2 面向碳钢大气腐蚀速率预测的 LSTM 单元门控结构

Fig. 2 The LSTM unit gated structure for predicting the atmospheric corrosion rate of carbon steel

令 t 时刻遗忘门、输入门和输出门的输出、权重、偏置分别为 $O_f(t)$ 、 $O_i(t)$ 、 $O_o(t)$ 、 W_f 、 W_i 、 W_o 、 b_f 、 b_i 、 b_o ;记忆神经元状态为 c_t , 权重、偏置分别为 W_c 、 b_c ;输入门通过 tanh 函数计算候选记忆神经元状态 $\hat{C}_t$, 遗忘门、输入门采用按位相乘运算 $\otimes$ 更新 c_t 。LSTM 数学模型为:

$$\begin{cases} O_f(t) = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ O_i(t) = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ O_o(t) = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ \sigma(x) = 1/(1 + e^{-x}) \\ \hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ c_t = (O_f(t) \otimes c_{t-1}) \oplus (O_i(t) \otimes \hat{C}_t) \\ h_t = O_o(t) \otimes \tanh(c_t) \end{cases} \quad (1)$$

图3为面向碳钢大气腐蚀速率预测 BiLSTM 网络结构图,它在每个时间步运行两个独立前向 LSTM、后向 LSTM,使得模型能在前向提取序列特征同时反向进行上下文建模,全面提高模型上下文依赖关系捕捉能力^[17],非常适合金属大气腐蚀速率长、短期预测应用。




图3 面向碳钢大气腐蚀速率预测 BiLSTM 网络结构

Fig. 3 BiLSTM network structure for predicting the atmospheric corrosion rate of carbon steel

为突出对腐蚀演化更关键的暴露时段、抑制冗余时间步信息,本文在 BiLSTM 输出隐藏状态序列 $H = \{h_t\}_{t=1}^T$ 上引入时间注意力层 Attention^[18-19],其权重计算与加权汇聚过程如图4所示。先由打分函数得到 $e_t = f(h_t)$,经 Softmax 得到权重 α_t ,再加权求和得到上下文向量 $c = \sum_{t=1}^T \alpha_t h_t$ ^[20],最后输入全连接层输出腐蚀速率 $\hat{R}_{\text{Fe}}$ 。




图4 时间注意力层的权重计算与特征汇聚流程

Fig. 4 The weight calculation and feature aggregation process of the time attention layer

1.2 模型的预训练-微调迁移学习

目标域(南部沿海炼化装置)腐蚀监测样本极少且工况覆盖有限,若直接在目标域从头训练 BiLSTM-Attention,模型易出现参数学习不足与过拟合,难以稳定捕捉腐蚀速率的时序动态规律,从而导致预测精度下降。

为缓解小样本训练的不适定性,本文采用图 5 所示的预

训练-微调式迁移学习框架,将源域学习到的时序表征能力迁移到目标域,以提升目标域预测性能。迁移学习由领域 D (domain)和任务 T (task)构成^[21],它们分别定义为:

$$D = \{\mathcal{X}, P(X)\}; T = \{\mathcal{Y}, f(\cdot)\} \quad (2)$$

其中, $\mathcal{X}$ 为征空间, $P(X)$ 边际概率分布函数; $\mathcal{Y}$ 为签空间; $f(\cdot)$ 为目标预测函数。




图 5 TL-BiLSTM-Attention 预训练-微调迁移过程

Fig. 5 TL-BiLSTM-Attention pre-training-fine-tuning transfer process

本文中源域为 D_s (MICAT 构建的源域数据),目标域为 D_T (炼化装置本地数据), $D_s \neq D_T$ 或 $T_s \neq T_T$ 下,可通过迁移学习改进目标预测函数的学习效果。

设 BiLSTM-Attention 回归预测模型为 $\hat{y} = f(x, \theta)$, 其中 $\theta = \{\theta_F, \theta_R\}$, θ_F, θ_R 分别表示 BiLSTM-Attention 模型特征提取部分、回归头(全连接层)。对源域数据集、目标域小样本集,分别进行预训练、微调,即:

$$\begin{cases} D_s = \{(x_1^s, y_1^s), (x_2^s, y_2^s), \dots, (x_{N_s}^s, y_{N_s}^s)\} \\ D_T = \{(x_1^T, y_1^T), (x_2^T, y_2^T), \dots, (x_{N_T}^T, y_{N_T}^T)\}, N_T \ll N_s \end{cases} \quad (3)$$

在 D_s 上预训练,其目标是均方误差最小:

$$\begin{cases} \mathcal{L}_S(\theta) = \frac{1}{N_s} \sum_{i=1}^{N_s} (f(x_i^s, \theta) - y_i^s)^2 \\ \theta^* = \operatorname{argmin}_{\theta} \mathcal{L}_S(\theta) \end{cases} \quad (4)$$

得到的 θ^* 用作目标域训练的初始化权重。

在 D_T 上微调,为平衡保留源域知识、适配目标域差异,本文采用冻结层策略,将参数划分为冻结集合 θ_{fr} 、可训练集合 θ_{tr} , 并仅更新 θ_{tr} :

$$\begin{cases} \mathcal{L}_T(\theta_{tr}) = \frac{1}{N_T} \sum_{j=1}^{N_T} (f(x_j^T, \theta_{fr}, \theta_{tr}) - y_j^T)^2 + \lambda \|\theta_{tr}\|_2^2 \\ \theta_{tr}^* = \operatorname{argmin}_{\theta_{tr}} \mathcal{L}_T(\theta_{tr}) \end{cases} \quad (5)$$

其中, $\lambda \|\theta_{tr}\|_2^2$ 为可选正则项,用于抑制小样本下过拟合风险。若冻结层数过少,可能导致已迁移知识被冲刷;若冻结层数过多,则限制模型对目标域分布差异适配能力,故实验可对不同冻结方案进行对比,选择优化微调策略。

2 TL-BiLSTM-Attention 预测实验

实验选用增强后的 MICAT 数据集,数据集包含 6 种环境数据以及对应的碳钢大气腐蚀速率(如表 1 所示),原数据规模为 119 个,增强后数据规模为 952 个,图 6 为增强后 MICAT 数据集 T-SNE、PCA 对比图,结果表明生成数据与真实数据分布重叠度较高,整体结构自然且连续,保证了生成样本丰富性、较高保真度。采用四分位距(IQR)法剔除异常样本,异常样本率为 7.04%,剔除异常样本后

的数据规模为 885 个。




图6 增强后 MICAT 数据集 T-SNE、PCA 对比

Fig. 6 Comparison of T-SNE and PCA in the enhanced MICAT dataset

为验证所构建模型有效性、工程适用性,本节实验围绕源域预训练效果、迁移到目标域小样本有效性两条主线展开。首先,在源域(增强后的 MICAT 数据)上建立评价指标体系,用于量化模型拟合与误差水平;随后采用 L9(4³)正交试验对 BiLSTM-Attention 关键超参数进行系统寻优,并在最优超参数下与 LSTM、BiLSTM 进行对比,验证双向结构与时间注意力对源域时序特征学习的优势。最后,将最优预训练权重迁移至炼化装置目标域(样本仅十余条),设计不同冻结层微调策略(冻结 BiLSTM/冻结 BiLSTM+Attention/全冻结)并在 Q235、304、316L、5A06 等材料上开展对比,分析冻结策略对过拟合抑制与预测精度的影响,从而验证 TL-BiLSTM-Attention 在工程小样本腐蚀预测场景下的有效性与稳定性。

2.1 评价指标

本文实验采用决定系数 R^2 、平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、误差方差(variance of error, Var)、平均绝对百分比误差(mean absolute percentage error, MAPE)、标准差(standard deviation, SD)^[22-23] 作为金属大气腐蚀预测模型评价指标,令腐蚀速率预测过程第 n 个真实值为 y_n , 腐蚀速率预测过程第 n 个预测值为 $\hat{y}_n$, 增强并剔除异常值

后的 MICAT 数据集数据量为 M_{MICAT} , 目标域样本量为 $N=12$, 即:

$$\left\{ \begin{aligned} \bar{y} &= \frac{1}{M_{\text{MICAT}}} \sum_{n=1}^{M_{\text{MICAT}}} y_n \\ R^2 &= 1 - \frac{\sum_{n=1}^{M_{\text{MICAT}}} (\hat{y}_n - y_n)^2}{\sum_{n=1}^{M_{\text{MICAT}}} (\bar{y} - y_n)^2} \\ MAE &= \frac{1}{M_{\text{MICAT}}} \sum_{n=1}^{M_{\text{MICAT}}} |\hat{y}_n - y_n| \\ RMSE &= \sqrt{\frac{1}{M_{\text{MICAT}}} \sum_{n=1}^{M_{\text{MICAT}}} (\hat{y}_n - y_n)^2} \\ Var &= \frac{1}{M_{\text{MICAT}}} \sum_{n=1}^{M_{\text{MICAT}}} \left[(\hat{y}_n - y_n) - \frac{1}{M_{\text{MICAT}}} \sum_{k=1}^{M_{\text{MICAT}}} (\hat{y}_k - y_k) \right]^2 \\ MAPE &= \frac{100\%}{N} \sum_{n=1}^N \left| \frac{\hat{y}_n - y_n}{y_n} \right| \\ SD &= \sqrt{\frac{1}{N} \sum_{n=1}^N \left(\left| \frac{\hat{y}_n - y_n}{y_n} \right| \times 100\% - MAPE \right)^2} \end{aligned} \right. \quad (6)$$

各指标物理意义如下:决定系数 R^2 代表金属大气腐蚀预测模型拟合程度, R^2 越接近 1, 模型拟合程度越好;平均绝对误差 MAE 表示预训练预测模型 $y_n, \hat{y}_n$ 平均误差, MAE 越小, 模型预测效果越准确;均方根误差 RMSE 表示预训练预测模型 $y_n, \hat{y}_n$ 偏差, RMSE 越小, 预测模型拟合效果越好;误差方差 Var 表示预训练模型预测误差的离散程度与波动强度, Var 越小, 模型预测结果越稳定;平均绝对百分比误差 MAPE 表示预训练预测模型 $y_n, \hat{y}_n$ 相对误差平均百分比, MAPE 越小, 预测模型越准确;标准差 SD 表示目标域小样本预测模型预测误差离散程度、波动范围, SD 越小, 预测模型泛化稳定性越好。

2.2 预训练模型超参数优化

在源域预训练阶段,网络超参数会直接影响模型收敛速度、拟合精度,故需对关键超参数进行系统寻优。本文选取对时序建模影响较大的 4 个超参数:时间步长 $L_{\text{time_steps}}$ 、隐藏层神经元数量 $N_{\text{LSTM_units}}$ 、随机失活率 d_r 、批次大小 $N_{\text{batch_size}}$ 。为保证在有限实验次数下仍能覆盖主要组合并分析各因素影响程度,采用正交试验设计对上述 4 因素进行规划^[24],每个因素设置 3 个水平,具体水平取值如表 2 所示。表 2 明确因素—水平—取值映射关系,如 $L_{\text{time_steps}}$ 水平 1、2、3 分别对应 32、64、128。在此基础上,选用 L9(4³) 进行 9 组组合实验,并统一设置学习率 $l_r = 0.01$ 、训练轮次 epochs=300,以保证不同组合之间可比。

表 3 为正交实验直观分析表,给出正交试验的组合方案与性能结果:I~IX 分别对应 9 组超参数水平组合(前 4 列为 4 因素水平编号,最后 1 列为该组合下源域预训练决

表 2 正交实验变量及其水平

超参数水平	$L_{\text{time_steps}}$	$N_{\text{LSTM_units}}$	d_r	$N_{\text{batch_size}}$
水平 1	32	32	0.1	8
水平 2	64	64	0.3	16
水平 3	128	128	0.5	32

表 3 正交实验直观分析

组合	$L_{\text{time_steps}}$	$N_{\text{LSTM_units}}$	d_r	$N_{\text{batch_size}}$	R^2
I	32	32	0.1	8	0.942
II	32	64	0.3	16	0.937
III	32	128	0.5	32	0.966
IV	64	32	0.3	32	0.947
V	64	64	0.5	8	0.944
VI	64	128	0.1	16	0.983
VII	128	32	0.5	16	0.927
VIII	128	64	0.1	32	0.956
IX	128	128	0.3	8	0.945
K_1	0.948	0.939	0.960	0.944	—
K_2	0.958	0.946	0.943	0.949	—
K_3	0.943	0.965	0.946	0.956	—
R	0.015	0.026	0.017	0.012	—

定系数 R^2)。表 3 还给出 K_1 、 K_2 、 K_3 、 R 直观分析结果,其中 K_i 表示某一因素取第 i 个水平对应的 R^2 均值,例如 $K_2=0.958$ 表明当前时间步长 $L_{\text{time_steps}}$ 取水平 2 时,3 组含该水平试验结果平均 R^2 为 0.958; R 为极差,用于衡量该因素对模型性能影响强弱,极差越大,说明该超参数变化对 R^2 的影响越显著,这便于从 9 组结果中提炼各因素主效应并确定优选水平。

由表 3 可知:1)隐藏层神经元数量 $N_{\text{LSTM_units}}$ 极差最大(0.026),说明其对模型拟合能力影响最敏感,其后依次为随机失活率 d_r (0.017)、时间步长 $L_{\text{time_steps}}$ (0.015)、批次大小 $N_{\text{batch_size}}$ (0.012);2)根据各因素取最大均衡值 K_i 原则确定最优水平组合: $L_{\text{time_steps}}$ 取水平 2($K_2=0.958$)、 $N_{\text{LSTM_units}}$ 取水平 3($K_3=0.965$)、 d_r 取水平 1($K_1=0.960$)、 $N_{\text{batch_size}}$ 取水平 3($K_3=0.956$)。因此,预训练模型超参数最优取值汇总如表 4 所示,即: $L_{\text{time_steps}}=64$ 、 $N_{\text{LSTM_units}}=128$ 、 $d_r=0.1$ 、 $N_{\text{batch_size}}=32$,该最优组合用于后续源域消融对比与目标域迁移实验。

在获得最优超参数组合后,为定量验证网络结构改动带来增益,开展结构消融对比实验:以单向 LSTM 为基线模型,在保持训练数据与训练配置一致条件下,引入双向编码得到 BiLSTM,并在 BiLSTM 输出端叠加时间注意力层得到本文 BiLSTM-Attention,3 种结构在同一源域训练集上训练,采用 R^2 、MAE、RMSE、Var 对拟合能力与误差

表 4 BiLSTM-Attention 网络超参数取值结果

Table 4 BiLSTM-Attention network hyperparameter value result	
超参数	取值结果
$L_{\text{time_steps}}$	64
$N_{\text{LSTM_units}}$	128
d_r	0.1
$N_{\text{batch_size}}$	32

水平进行统一评价,结果汇总于表 5。

表 5 源域训练集上不同网络结构的预测性能对比
(消融实验)

Table 5 Comparison of prediction performance of different network structures on the source domain training set (ablation experiment)				
预测方法	R^2	MAE	RMSE	Var
BiLSTM-Attention	0.992	1.017	1.409	1.798
BiLSTM	0.986	1.262	1.754	2.847
LSTM	0.973	1.409	1.962	3.663

由表 5 可知,BiLSTM-Attention 在源域训练集上取得最优综合表现,其 $R^2=0.992$,较 BiLSTM、LSTM 分别提升 0.006、0.019,说明在相同数据与训练设置下,模型对腐蚀速率变化的解释能力进一步增强;MAE=1.017、RMSE=1.409,较 BiLSTM、LSTM 分别降低 0.245、0.345 和 0.392、0.553,表明预测误差与波动偏差均明显收敛;同时 Var=1.798,较 BiLSTM、LSTM 分别降低 1.049、1.865,表明预测结果的离散程度显著缩小,模型在复杂工况下输出稳定性得到显著提升。进一步地,由 LSTM→BiLSTM 的提升,体现双向递推对历史—未来上下文信息的联合建模优势;由 BiLSTM→BiLSTM-Attention 的提升,则源于时间注意力对关键时间步赋予更高权重、抑制冗余时间步噪声,使回归输出更稳定。基于上述结构消融结果,本文选取 BiLSTM-Attention 作为迁移学习的预训练骨干网络,但由于目标域样本仅十余条,小样本微调时冻结哪些层/训练哪些层,将直接影响知识保留与域适配能力,因此下一节进一步对不同冻结策略开展对比实验。

2.3 迁移学习微调方案对比实验

目标域为炼化装置本地数据集,可用于建模的样本仅 12 条($N=12$),因此在权重迁移后采用“冻结-微调”策略对模型进行域适配。本文以 BiLSTM-Attention(由 BiLSTM 层、注意力层与全连接回归层组成)为预训练骨干网络,针对 Q235、5A06、304、316L 4 种金属设计 3 种冻结方案:1)冻结 BiLSTM(微调 Attention+全连接);2)冻结 BiLSTM+Attention(仅微调全连接);3)全冻结(不更新参数)。

鉴于南部沿海炼化装置现场获取的高精度腐蚀数据样本极为稀缺,若沿用常规固定比例划分,其评估结果极易受样本分布随机性影响,导致结论缺乏统计显著性。为消除单次数据划分带来偶然性偏差,并准确评估模型在小样本条件下泛化稳健性,本文在目标域微调阶段引入留一法交叉验证 (leave-one-out cross-validation, LOOCV) 策略^[25]。具体实施步骤为:将目标域样本视为一个全集,每次循环选取 $N-1=11$ 个样本作为微调训练集以更新模型参数,保留 1 个样本作为独立测试集进行验证,该过程遍历所有样本共执行 12 次。最终评价指标由 12 次独立实验结果的预测误差 MAPE 算术平均值确定,并计算对应标准差构建置信区间,以均值±标准差形式表征预测误差波动范围。不同冻结策略在目标域上的预测误差 MAPE 对比如图 7 所示,定量结果汇总如表 6 所示。




图 7 目标域(本地样本数 $N=12$)不同冻结策略下各金属 MAPE 对比

Fig. 7 Comparison of MAPE of each metal under different freezing strategies in the target domain (local sample number $N=12$)

表 6 目标域 $N=12$ 下 3 种冻结策略 MAPE 对比

Table 6 MAPE comparison of three freezing strategies under the target domain $N=12$ %

材料	冻结 BiLSTM	冻结 BiLSTM+ Attention	全冻结 (不更新参数)
Q235	10.22±1.22	11.79±1.25	20.89±1.12
5A06	18.94±1.11	18.53±1.09	18.04±1.07
304	15.18±1.38	13.80±1.39	13.14±1.23
316L	12.02±1.17	11.41±1.14	10.18±1.02

本文遵循精度与稳定性综合评估原则,首先比较各策略在留一法验证下的 MAPE 均值,优先选择预测误差显著降低的策略($\Delta\text{MAPE}>5\%$);若不同策略的均值差异不显著($\Delta\text{MAPE}<2\%$),则进一步考察标准差,选取误差分布更窄、置信区间更收敛的策略作为最优解,以确保模型在少样本工程应用中的鲁棒性。由表 6 可得,各材料最优冻结策略存在明显差异,其中 Q235 在冻结 BiLSTM、微调 Attention+全连接时误差最低 ($\text{MAPE}=10.22\%\pm1.22\%$),全冻结时误差显著增大 ($\text{MAPE}=20.89\%\pm$

1.12%),说明其目标域分布差异更需要通过上层参数更新实现适配;304 与 316L 在全冻结时达到最优(MAPE 分别为 $13.14\%\pm1.23\%$ 、 $10.18\%\pm1.02\%$),表明在 $N=12$ 的小样本条件下,继续训练上层参数更易引入过拟合,直接使用预训练表征反而更稳健;5A06 3 种策略差异不足 1% ($18.94\%\pm1.11\%$ / $18.53\%\pm1.09\%$ / $18.04\%\pm1.07\%$),整体误差偏高,揭示其目标域数据噪声或样本代表性不足对预测上限形成约束。

综合而言,TL-BiLSTM-Attention 在仅 12 条目标域样本下仍可通过分材料选择冻结策略获得相对最优预测,仅当目标域材料与源域具备物理同质性(如 Q235 碳钢)且不同解冻策略带来的验证集误差改善率 $\Delta\text{MAPE}>5\%$ 时,才启用局部参数更新,以重塑本地多源环境因子权重分配;反之,对于 304、316L 等腐蚀机理与源域存在跨分布差异的异质材料,应保持网络全冻结以最大程度复用源域学习到的通用时序表征,规避盲目微调引入噪声干扰、过拟合风险。该策略为炼化装置多材料、小样本腐蚀预测提供了可操作的微调选型依据。

3 结 论

面向中国南部沿海炼化装置,针对炼化装置目标域腐蚀监测样本极少(本地可建模样本 $N=12$)导致深度模型易过拟合、难以稳定学习腐蚀速率时序规律的问题,本文构建源域预训练-目标域微调的 TL-BiLSTM-Attention 预测框架,以 MICAT 公共腐蚀数据作为源域进行表征学习,并在数据集准备阶段引入 TimeGAN 生成与原序列同维度的合成样本以增强源域训练规模,从而为目标域小样本迁移提供可复用的时序特征表示。

在源域预训练阶段,基于 $L9(4^3)$ 正交实验对关键超参数进行系统寻优,得到时间步长 64、隐藏层神经元数 128、随机失活率 0.1、批次大小 32 的组合,提高模型训练稳定性与拟合能力。在结构消融对比中,BiLSTM-Attention 综合性能优于 LSTM 与 BiLSTM(源域训练集 $R^2=0.992$ 、 $\text{MAE}=1.017$ 、 $\text{RMSE}=1.409$),说明双向时序建模与时间注意力对关键时段信息聚合可有效降低回归误差。

在目标域超小样本或极少样本迁移微调中,冻结策略对不同金属最佳效果存在显著差异:Q235 在冻结 BiLSTM、微调 Attention+全连接下达到最低误差($\text{MAPE}=10.22\%\pm1.22\%$),而全冻结会使误差显著增大 ($20.89\%\pm1.12\%$),表明碳钢类更依赖上层参数更新以实现域适配;304 与 316L 在全冻结时最优($\text{MAPE}=13.14\%\pm1.23\%$ 、 $10.18\%\pm1.02\%$),反映出在超小样本条件下继续更新参数更易诱发过拟合,直接复用预训练表征更稳健;5A06 3 种策略差异不足 1%且整体误差偏高(约 18%),提示其目标域样本代表性及噪声水平可能对预测上限形成约束。

需要指出的是,中国南部沿海炼化装置目标域样本量少或极少,且工况覆盖仍偏小,使结论统计稳定性受限,

5A06 误差偏高现象需更多样本验证;源域一目标域仍可能存在隐含分布偏移,后续可引入更显式域适配/特征对齐方法并按材料或场景分层迁移;同时建议补充注意力权重可视化、敏感性与不确定性评估(区间预测),并建立随新增监测数据增量更新机制,以提升工程部署可解释性、长期可用性。

参考文献

- [1] AL-MOUBARAKI A H, OBOT I B. Corrosion challenges in petroleum refinery operations: Sources, mechanisms, mitigation, and future outlook [J]. Journal of Saudi Chemical Society, 2021, 25(12): 101370.
- [2] CAI Y K, XU Y M, ZHAO Y, et al. Atmospheric corrosion prediction: A review [J]. Corrosion Reviews, 2020, 38(4): 299-321.
- [3] KHALAF A H, XIAO Y, XU N, et al. Emerging AI technologies for corrosion monitoring in oil and gas industry: A comprehensive review [J]. Engineering Failure Analysis, 2024, 155: 107735.
- [4] 宗立君, 吴亚平, 樊志彬, 等. 1070A 和 6063 铝合金在模拟海洋大气环境中的腐蚀行为[J]. 材料工程, 2025, 53(12): 239-249.
ZONG L J, WU Y P, FAN ZH B, et al. Corrosion behavior of 1070A and 6063 aluminum alloys in simulated marine atmospheric environment [J]. Materials Engineering, 2025, 53(12): 239-249.
- [5] 缪浩, 尹程辉, 王洪伦, 等. 污染海洋大气环境下不锈钢加速腐蚀试验环境谱评价及相关性[J]. 中国腐蚀与防护学报, 2025, 45(2): 449-459.
MIAO H, YIN CH H, WANG H L, et al. Evaluation and correlation of environmental spectra for accelerated corrosion testing of stainless steel in polluted marine atmosphere[J]. Journal of Chinese Society for Corrosion and Protection, 2025, 45(2): 449-459.
- [6] ZHI Y J, FU D M, ZHANG D W, et al. Prediction and knowledge mining of outdoor atmospheric corrosion rates of low alloy steels based on the random forests approach[J]. Metals, 2019, 9(3): 383.
- [7] DONG ZH, DING L, MENG ZH, et al. Machine learning-based corrosion rate prediction of steel embedded in soil[J]. Scientific Reports, 2024, 14(1): 18194.
- [8] 彭威龙, 曾松梧, 张宝庆, 等. 基于 GA-BP 模型的大型接地网腐蚀速率预测方法[J]. 电力科学与技术学报, 2024, 39(3): 264-270.
PENG W L, ZENG S W, ZHANG B Q, et al. Prediction method of corrosion rate for large grounding grids based on GA-BP model[J]. Journal of Electric Power Science and Technology, 2024, 39(3): 264-270.
- [9] JIANG J X, WAN X L, ZHU F, et al. A deep learning framework integrating Transformer and LSTM architectures for pipeline corrosion rate forecasting[J]. Computers & Chemical Engineering, 2025: 109365, DOI: 10.1016/j. compchemeng. 2025.109365.
- [10] CANONACO G, ROVERI M, ALIPPI C, et al. A transfer-learning approach for corrosion prediction in pipeline infrastructures [J]. Applied Intelligence, 2022, 52(7): 7622-7637.
- [11] ZHUANG F ZH, QI ZH Y, DUAN K Y, et al. A comprehensive survey on transfer learning [J]. Proceedings of the IEEE, 2021, 109(1): 43-76.
- [12] VANGRUNDERBEEK V, COELHO L B, ZHANG D W, et al. Exploring the potential of transfer learning in extrapolating accelerated corrosion test data for long-term atmospheric corrosion forecasting[J]. Corrosion Science, 2023, 225: 111619.
- [13] JI H D, TIAN Y, FU C Q, et al. Transfer learning enables prediction of steel corrosion in concrete under natural environments [J]. Cement and Concrete Composites, 2024, 148: 105488.
- [14] CHICO B, DE LA FUENTE D, DÍAZ I, et al. Annual atmospheric corrosion of carbon steel worldwide. An integration of ISOCORRAG, ICP/UNECE and MICAT databases[J]. Materials, 2017, 10(6): 601.
- [15] YOON J, JARRETT D, SCHAAR M V D. Time-series generative adversarial networks[J]. Advances in Neural Information Processing Systems, 2019, 32: 4771-5570.
- [16] 李泓沛, 刘桂雄, 邓威. 基于 LSTM+UKF 融合的动力锂电池 SOC 估算方法[J]. 中国测试, 2022, 48(8): 22-28.
LI H P, LIU G X, DENG W. SOC estimation method for power lithium batteries based on LSTM+UKF fusion[J]. China Measurement & Test, 2022, 48(8): 22-28.
- [17] SIAMI-NAMINI S, TAVAKOLI N, NAMIN A S. The performance of LSTM and BiLSTM in forecasting time series[C]. 2019 IEEE International Conference on Big Data(Big Data), 2019: 3285-3292.
- [18] LU W J, LI J ZH, WANG J Y, et al. A CNN-BiLSTM-AM method for stock price prediction[J]. Neural Computing and Applications, 2021, 33(10): 4741-4753.
- [19] 林泓, 刘桂雄, 戈燕红, 等. 单变量时间序列的 MHAGRU-MCCE 分类方法[J]. 电子测量技术,

2024,47(16):83-91.

LIN H, LIU G X, GE Y H, et al. MHAGRU-MCCE classification method for univariate time series [J]. Electronic Measurement Technology, 2024, 47(16): 83-91.

[20] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. ArXiv preprint arXiv: 1706.03762,2017.

[21] 魏新园,周京欢,张楠,等. 基于深度迁移学习的超声缺陷识别方法研究[J]. 仪器仪表学报,2024,45(12): 256-263.

WEI X Y, ZHOU J H, ZHANG N, et al. Research on ultrasonic defect identification method based on deep transfer learning[J]. Chinese Journal of Scientific Instrument, 2024, 45(12): 256-263.

[22] WANG L N, MAO M X, XIE J L, et al. Accurate solar PV power prediction interval method based on frequency-domain decomposition and LSTM model[J]. Energy, 2023, 262: 125592.

[23] LONG P J, YANG G P, LIU H Y, et al. Transfer learning-driven prediction of oil and gas pipeline corrosion rates in small sample scenarios [J]. PLoS One, 2025, 20(10):e0333914.

[24] 张京军,刘敏,贾国平,等. 正交试验理论线聚焦电磁超声换能器优化设计[J]. 中国测试,2024,50(2):91-99.

ZHANG J J, LIU M, JIA G P, et al. Optimal design

of line-focused electromagnetic ultrasonic transducer based on orthogonal experimental theory [J]. China Measurement & Test, 2024, 50(2): 91-99.

[25] 罗彬,常俊,孙江黎,等. 基于 LACNN 的 FMCW 雷达实时跌倒检测方法[J]. 电子测量技术,2025,48(4): 35-43.

LUO B, CHANG J, SUN J L, et al. Real-time fall detection method for FMCW radar based on LACNN[J]. Electronic Measurement Technology, 2025, 48(4): 35-43.

作者简介

黄琛湫,硕士研究生,主要研究方向为智能检测与仪器仪表。

E-mail:202420100341@mail.scut.edu.cn

刘桂雄(通信作者),博士,教授,博士生导师,主要研究方向为先进传感与仪器研究。

E-mail:megxliu@scut.edu.cn

林壮敦,本科,高级工程师,主要研究方向为特种设备检验及安全管理与评估。

E-mail:linzhuangdun@gdsei.org.cn

袁武飞,本科,高级工程师,主要研究方向为特种设备检验及安全管理与评估。

E-mail:yuanwufei@gdsei.org.cn

吴海泓,研究生,高级工程师,主要研究方向为特种设备检验及安全评估。

E-mail:wuhaihong@gdsei.org.cn