

DOI:10.19853/j.zgjsps.1000-4602.2026.13.004

基于机器学习的电渗析单位能耗原位监测

刘颖¹, 王信洁¹, 李温涛¹, 张新波¹, 赵云峰², 陈锋³,
古金霞⁴, 李志猛⁵

(1. 天津城建大学 环境与市政工程学院, 天津 300384; 2. 国家管网集团北方管道有限责任公司, 河北 廊坊 065000; 3. 北华航天工业学院 建筑工程学院, 河北 廊坊 065000;
4. 天津城建大学 理学院, 天津 300384; 5. 天津城建大学 控制与机械工程学院, 天津 300384)

摘要: 针对双极膜电渗析(BMED)过程单位能耗(SEC)难以在线监测的问题,提出一种基于物联网(IoT)架构的机器学习(ML)监测方法。基于离线配制的NaOH溶液数据,对比了多层感知机(MLP)、支持向量回归(SVR)、梯度提升回归(GBR)和长短期记忆网络(LSTM)四种碱浓度预测模型,其中MLP表现最优,在测试集上的决定系数(R^2)均值为1.000 0。将该模型迁移应用于BMED系统,通过碱室中原位部署的pH、温度、电导率、液位及膜堆电压传感器实时采集数据,在线预测碱浓度并推演SEC。实验表明,浓度预测的 R^2 为0.905 0,且由此推演的SEC表现出“初始快速上升至峰值,经回落与小幅调整后,长期运行缓慢上升”的动态演化规律。该系统集成感知、传输、平台三层IoT架构,实现了从离线建模到在线验证的全流程智能监测,为BMED节能调控提供了有效工具。

关键词: 电渗析; 单位能耗; 机器学习; 原位监测; 多层感知机

中图分类号: TU992 **文献标识码:** A **文章编号:** 1000-4602(2026)13-0026-09

Machine Learning-based In-situ Monitoring of Specific Energy Consumption in Electrodialysis Processes

Liu Ying¹, Wang Xinjie¹, Li Wentao¹, Zhang Xinbo¹, Zhao Yunfeng², Chen Feng³,
Gu Jinxia⁴, Li Zhimeng⁵

(1. School of Environmental and Municipal Engineering, Tianjin Chengjian University, Tianjin 300384, China; 2. National Pipe Network Group Northern Pipeline Co. Ltd., Langfang 065000, China; 3. School of Civil Engineering and Architecture, North China Institute of Aerospace Engineering, Langfang 065000, China; 4. School of Science, Tianjin Chengjian University, Tianjin 300384, China; 5. School of Control and Mechanical Engineering, Tianjin Chengjian University, Tianjin 300384, China)

Abstract: To address the challenge of online monitoring of specific energy consumption (SEC) in bipolar membrane electrodialysis (BMED) processes, a machine learning (ML)-assisted monitoring approach based on the Internet of Things (IoT) was proposed. Using data obtained from offline prepared NaOH solutions, four predictive models for alkali concentration including multilayer perceptron (MLP),

基金项目: 天津市自然科学基金资助面上项目(24JCYBJC00600)

通信作者: 李志猛 E-mail: lzmexg@tcu.edu.cn

support vector regression (SVR), gradient boosting regression (GBR) and long short-term memory (LSTM) were compared. The MLP model demonstrated the best performance, achieving a coefficient of determination (R^2) of 1.000 0 on the test dataset. The developed model was subsequently transferred for online prediction of alkali concentration during the BMED process. Real-time data were acquired by in-situ sensors deployed within the alkali compartment, which monitored parameters including pH, temperature, conductivity, liquid level, and membrane stack voltage. These data streams enabled the online prediction of alkali concentration and the subsequent derivation of SEC. Experimental results showed that the R^2 for online concentration prediction reached 0.905 0, and the derived SEC exhibited a characteristic dynamic evolution pattern of initially rapidly rising to a peak, followed by a decline and minor adjustments, and then slowly increasing over long-term operation. The proposed system integrated a three-tier IoT architecture comprising the perception layer, transmission layer and platform layer, enabling full-process intelligent monitoring that spans from offline model development to online validation. This framework provides a viable and effective tool for facilitating energy-efficient operation and dynamic regulation of the BMED process.

Keywords: electrodialysis; specific energy consumption; machine learning; in-situ monitoring; multilayer perceptron

随着全球对绿色化工技术需求的增长,双极膜电渗析(BMED)因其能将盐转化为酸和碱、实现资源循环利用而备受关注^[1-4]。BMED是一种联合运用电渗析(ED)和双极膜(BPM)的技术,将ED的盐分离功能与BPM的水解离性能相结合。在直流电场作用下,BPM将水解离为 H^+ 和 OH^- ,结合离子交换膜的选择透过特性,使阳离子向阴极迁移、阴离子向阳极迁移,同时BPM解离产生的 H^+ 和 OH^- 在膜两侧分别生成酸和碱,从而在同一装置中同步完成离子分离与酸碱制备^[5-6]。BMED在废水处理、酸碱制备和资源回收领域优势显著,但是其单位能耗(SEC)是制约技术经济性的核心因素^[7-10]。BMED过程系统能耗主要由四部分组成:电极反应能耗,占比5%~10%,源于正、负极的析氧和析氢等电化学反应过电位;BPM水解离能耗,占比60%~80%,是生成 H^+ 和 OH^- 的核心能耗;膜电阻损耗,占比10%~20%,源于离子传导过程中的焦耳热损耗;流体输送能耗,占比 $\leq 3\%$,来自驱动溶液循环的泵功消耗。该能耗构成为SEC监测提供了明确参考。

传统BMED能耗监测方法主要包括人工记录和简单仪表测量^[11]。人工记录通过操作人员定期读取电表、流量计等仪表数据并手动记录,再通过简单计算估算能耗。该方法虽操作简单,但实时性差,无法及时捕捉能耗的瞬间变化与异常波动,当

设备故障或工艺参数异常导致能耗骤变时难以及时发现与处理,易造成能源浪费与生产效率下降。简单仪表测量虽能实时获取部分参数,但仅能实现单一参数监测,无法结合多参数进行综合分析 with 能耗推导,且受仪表精度与测量范围限制,难以满足复杂BMED过程中能耗精准监测的需求。尽管物联网(IoT)与机器学习(ML)为在线监测提供了可能,但现有软测量方法往往无法有效处理时序数据的复杂关联,导致模型性能下降且更新困难。

为此,本研究提出一种基于IoT架构的ML原位监测方法。首先,通过配制不同浓度的NaOH溶液,采集pH、温度、电导率数据,构建离线训练数据集;在此基础上,分别采用多层感知机(MLP)、支持向量回归(SVR)、梯度提升回归(GBR)和长短期记忆网络(LSTM)四种典型ML算法建立碱浓度预测模型,通过对比实验筛选出最优模型^[12]。然后,将最优模型应用于实际BMED过程,构建涵盖感知层、传输层、平台层的三层IoT架构,实现碱室中pH、温度、电导率、液位及膜堆电压等多源参数的同步采集与低延迟传输,利用实时采集数据进行碱浓度在线预测,并结合能耗计算公式动态推演SEC,完成从离线建模到在线验证的全流程实时监测。该方法旨在克服传统监测方法的滞后性与单一性,为BMED过程的节能优化提供实时监测支持。

1 研究方法

1.1 双极膜电渗析单位能耗计算

BMED过程SEC为总能耗(W)与产碱量(m)的比值,记作 E (单位: $\text{kW}\cdot\text{h}/\text{kg}$), W 和 m 的计算方法为:

$$W = \frac{1}{3.6 \times 10^6} \int_0^t U(t) I dt \quad (1)$$

$$m = c \cdot V \cdot M \quad (2)$$

式中: $U(t)$ 为时刻 t 的膜堆电压,通过电压变送器实时采集, V ; I 为运行电流,实验采用恒流模式,设定为6 A; t 为运行时间,s; c 为碱溶液浓度,通过模型预测得到, mol/L ; V 为碱室溶液体积,考虑储液罐不规则性,采用“初始体积+实时变化量”计算,L; M 为NaOH的摩尔质量,取40 g/mol。

初始溶液体积设定为0.5 L(500 mL),通过量筒精准量取;实时变化量由液位传感器采集的实时液位高度与储液罐横截面积 S 的乘积获得。

1.2 关键参数采集方法与传感器类型

基于上述计算公式,需原位采集的关键参数包括:膜堆电压 $U(t)$ 、碱室溶液的pH、温度、电导率、液位高度 $h(t)$,所有参数采集频率均设定为1次/s,确保数据时效性。其中,膜堆电压:阿尔泰DAM-3053模块传感器,量程为0~35 V,精度为0.2%;液位高度:MAQI-136投入式液位传感器,量程为0~9 cm,精度为 ± 0.2 cm; pH: JF-PH-485基础型常规水质监测数字传感器,量程为0~14,精度为 ± 0.1 ; 温度: JF-COND-485常规水质检测数字电导率传感器,量程为-10~150 $^{\circ}\text{C}$,精度为 ± 0.3 $^{\circ}\text{C}$; 电导率: JF-COND-485常规水质检测数字电导率传感器,量程为0~200 mS/cm ,精度为 $\pm 2\%$ 。除膜堆电压传感器安装在膜堆正负极外,其他传感器均安装在碱室储液罐内,且所有设备均具备抗干扰设计,适配BMED系统复杂工况(如溶液腐蚀、电磁干扰)。

2 数据处理与输入特征分析

2.1 数据预处理

由于在线仪表采集过程中存在数据上传延迟、传感器测量误差等问题,原始数据中会出现较多空值、重复值及异常值。为获得可靠的浓度预测结果,需要对原始数据进行清洗和处理。本实验收集了pH、温度和电导率三个特征在11个不同浓度(0.03~0.33 mol/L)下的测量数据,针对异常数据按照以下情况进行处理:①将三个特征数据中的非

数值和空值直接删除;②由于同一浓度的三个特征数据采集时间可能存在不完全同步,对每个浓度的三个特征取最小长度进行对齐,确保每个样本的三个特征在时间上一致。经过以上处理,得到4 462条有效样本数据。

2.2 数据归一化

pH、温度和电导率三个特征具有不同的物理意义和数值范围,其量纲差异会显著影响模型的训练效率和预测精度。为了消除特征间量纲的影响,采用最小-最大归一化方法将所有特征值线性映射到[0,1]区间。具体而言,对每个特征维度,将其原始数值减去该维度上的最小值,再除以该维度上的极差(最大值与最小值之差),使得所有特征处于同一数量级^[13]。

由于本研究采用4折交叉验证对所有样本进行评估,未划分独立的测试集,且为避免数据泄漏,归一化操作在每次数据划分之后执行。具体流程为:在每一折中,基于训练集计算每个特征的最小值和极差,对训练集的特征进行归一化;然后使用同一组最小值与极差,对当前折的验证集特征执行相同的归一化变换。同时,对于MLP、SVR、GBR和LSTM四种模型,均对目标浓度值进行相同的基于训练集的最小-最大归一化处理,以加速模型收敛。通过这种在交叉验证框架内逐折实施的归一化策略,不同特征对模型的影响权重更加均衡,显著提升了模型的训练效率和预测稳定性,并确保了评估结果的真实泛化能力。

2.3 输入特征的相关性分析与选取依据

为明确模型输入层的特征选择依据,在训练数据的基础上,对pH、温度、电导率与NaOH溶液浓度之间的相关性进行了分析。结果表明,在15~30 $^{\circ}\text{C}$ 的实验温度区间内,11个浓度组(0.03~0.33 mol/L)均呈现出一致的变化规律:同一浓度下,电导率随温度升高呈显著上升趋势,这是由于温度升高会加快溶液中 Na^+ 、 OH^- 的迁移速率,降低溶液黏度与离子迁移阻力,进而增强溶液导电性;同一温度下,溶液浓度越高,电导率值越大,二者呈近似正相关关系,这是因为浓度直接决定了溶液中离子总量。该趋势清晰呈现了温度与浓度对电导率的双因素协同调控机制,既印证了温度通过影响离子迁移能力间接关联浓度的物理化学逻辑,也凸显了电导率作为浓度敏感特征的合理性,为二者共同作为模型输

入特征提供了机理层面的支撑。

NaOH 溶液电导率、pH 与浓度的相关性散点图及线性拟合结果显示,电导率与浓度的线性拟合方程为 $y=130.33x+3.53$, 决定系数 (R^2)=0.994 0, 表明二者具有极强的正线性相关性, 这一结果缘于 NaOH 溶液的特性: 浓度直接决定离子总量, 而电导率的核心影响因素正是离子浓度与迁移能力, 因此电导率可快速、精准地表征浓度的动态变化。pH 与浓度的线性拟合方程为 $y=2.36x+12.47$, $R^2=0.804 0$, 虽然线性相关性弱于电导率, 但仍呈现显著的正相关关系, 这是因为碱浓度升高会直接增加溶液中 OH⁻ 浓度, 导致 pH 呈规律性上升。上述结果直接验证了电导率与 pH 作为浓度预测输入特征的有效性, 二者与浓度的 R^2 均大于 0.8, 包含了浓度预测所需的核心信息, 且特征间功能互补, 电导率反映离子总量, pH 反映 OH⁻ 特异性浓度, 为模型精准捕捉浓度变化奠定了数据基础。

综上所述, pH、温度、电导率与碱浓度均存在明确且稳定的物理化学关联: 温度通过调控离子迁移能力间接影响浓度相关信号, 电导率与 pH 则直接反映浓度相关的离子特性。这种强关联性带来两方面核心优势: 一是可以确保模型输入信息的有效性, 避免了无关特征引入的噪声干扰, 为模型实现高预测精度提供了前提; 二是特征间的协同互补性有效降低了模型学习难度, 为模型结构的简化与实时性优化创造了条件。因此, 本研究选择 pH、温度、电导率作为模型构建的输入特征进行训练。

3 模型构建

3.1 算法选择

3.1.1 多层感知机算法

MLP 是一种经典的前馈人工神经网络, 其核心结构由一个输入层、至少一个隐藏层和一个输出层组成, 它通过非线性激活函数引入非线性表达能力, 从而能够拟合输入特征与目标变量之间复杂的非线性映射关系。模型训练通常采用反向传播算法, 通过最小化损失函数来逐层调整网络中的连接权重。优化方法可以选择 Levenberg-Marquardt、梯度下降等算法以提高收敛效率。凭借其强大的通用逼近特性, MLP 能够自适应地学习数据中的高维非线性模式, 适用于多种回归与分类任务。

3.1.2 支持向量回归算法

SVR 是支持向量机在回归问题上的扩展, 其核

心思想是通过寻找一个最优的回归超平面, 使得所有训练样本点与该平面的偏差尽可能小, 且不超过预设的容忍阈值。与传统的回归方法不同, SVR 通过引入核函数将原始特征映射到高维空间, 从而有效处理非线性关系, 并在高维空间中构造线性回归模型。SVR 通过调节正则化参数和核函数参数, 能够在保持模型稀疏性的同时, 获得良好的泛化能力和鲁棒性, 特别适用于小样本、高维且存在复杂非线性模式的回归预测任务。

3.1.3 梯度提升回归算法

GBR 是一种基于集成学习的回归算法, 它通过序贯地组合多个弱学习器来构建一个强大的预测模型。其核心思想是在每一轮迭代中, 新的弱学习器被训练以拟合当前模型预测值与真实值之间的残差, 从而逐步减少整体模型的误差。通过调节弱学习器的数量、学习率以及树的结构复杂度, GBR 能够在控制模型复杂度的同时有效捕捉数据中复杂的非线性关系与交互效应, 在回归任务中表现出卓越的预测精度和鲁棒性。相较于单一模型, 这种逐步优化的集成策略使 GBR 能够更好地平衡偏差与方差, 从而成为处理多种回归问题的强大工具。

3.1.4 长短期记忆网络算法

LSTM 是一种基于循环神经网络架构的时序深度学习算法, 它通过特殊的门控机制与细胞记忆单元构建具备长依赖捕捉能力的时序预测模型^[14]。通过调节网络层数、神经元数量、时间步长及超参数配置, LSTM 能够在控制模型拟合风险的同时精准挖掘时序数据内部复杂的非线性关联与前后演化规律, 在时间序列拟合与趋势预测任务中展现出优异的特征提取能力与泛化性能。相较于传统 ML 回归模型, 这种门控记忆更新的循环架构使 LSTM 能够充分利用历史时序信息刻画动态变化规律, 进而成为处理各类时序回归与序列建模问题的核心算法。

3.2 评估指标

本次模型评估指标主要采用 R^2 、均方根误差 (RMSE) 与平均绝对误差 (MAE)。其中, R^2 用于衡量模型预测值对真实值变化的解释能力, 其取值范围为 $[0, 1]$, 数值越接近 1, 表明模型的拟合优度越高, 预测结果越可靠; RMSE 能够反映预测值的总体偏离程度, 且对较大误差更为敏感; MAE 则直接度量了预测值与真实值之间的平均偏差, 结果更为直

观稳健^[15]。

3.3 模型训练

为保证实验的可复现性及模型对比的公平性,本文对所有预处理后的样本采用随机索引实现等效随机划分,并按 4 折交叉验证策略依次进行模型训练与评估。具体地,每轮取其中 1 折作为测试集,其余 3 折作为训练集,循环 4 次,计算 4 次测试 R^2 、RMSE、MAE 的均值,以此作为 MLP、SVR、GBR 和

LSTM 四种模型的性能评估依据,避免单次数据划分带来的随机误差。

超参数调优采用控制变量正交法,对各模型的候选超参数进行组合搜索。对每一组超参数组合,均执行上述 4 折交叉验证,取 4 次测试集指标的平均值作为该组参数的评分,选取评分最优的组合作为最终参数。各模型超参数的调优范围及最优值如表 1 所示。

表 1 各模型超参数调优范围与最优值

Tab.1 Tuning ranges and optimal values of hyperparameters for each model

模型	超参数	调优范围	最优值
MLP	第 1 隐藏层神经元数量	[15, 20, 25, 30, 35]	25
	第 2 隐藏层神经元数量	[10, 15, 20, 25, 30]	20
	最大训练迭代次数	[1 000, 1 500, 2 000, 2 500, 3 000]	2 000
SVR	惩罚系数	[10, 20, 30, 40, 50]	30
	ε -不敏感区宽度	$[0.8 \times 10^{-4}, 1.6 \times 10^{-4}, 2.4 \times 10^{-4}, 3.2 \times 10^{-4}, 4 \times 10^{-4}]$	1.6×10^{-4}
	RBF 核函数尺度参数	[0.04, 0.06, 0.08, 0.10, 0.12]	0.08
GBR	叶节点最小样本数	[1, 2, 3, 4, 5]	1
	基学习器数量	[75, 80, 85, 90, 95]	85
	学习率	[0.2, 0.3, 0.4, 0.5, 0.6]	0.4
LSTM	滑动窗口大小	[25, 30, 35, 40, 45]	35
	LSTM 层隐藏神经元数量	[16, 24, 32, 40, 48]	24
	初始学习率	$[3 \times 10^{-3}, 4 \times 10^{-3}, 5 \times 10^{-3}, 6 \times 10^{-3}, 7 \times 10^{-3}]$	6×10^{-3}

依据表 1 中的最优超参数,采用 4 折交叉验证对各模型进行训练与评估^[16],得到性能指标均值。MLP、SVR、GBR 和 LSTM 的 R^2 分别为 1.000 0、1.000 0、0.999 7、0.998 1, RMSE 分别为 0.000 2、0.000 6、0.001 6、0.004 1, MAE 分别为 0.000 1、0.000 1、0.000 6、0.003 2。可见,MLP 模型的 R^2 最高,表明其拟合效果最佳,同时 RMSE 和 MAE 最小,说明预测精度最高。因此,MLP 模型兼具最优的拟合能力与泛化性能,更适用于本研究的预测任务。

3.4 模型可解释性分析

为揭示各输入特征对 NaOH 浓度预测的作用机制,基于 SHAP 方法对模型进行可解释性分析。由特征重要性排序可知,电导率、pH、温度对预测结果的贡献依次递减(平均 SHAP 值分别为 0.068 9、0.041 9、0.025 6),电导率的重要性显著高于其他两个特征,是模型预测的核心主导因素,这与 NaOH 溶液的理化特性高度吻合。图 1 的特征贡献概要图进一步验证了这一结论:电导率的贡献分布范围最广,高电导率样本对预测浓度具有明显的正向推动作用;pH 的贡献多集中在负区间,主要通过限制预

测上限影响结果;温度的贡献几乎围绕 0 值波动,对预测结果的影响较弱,仅起到微调作用。




图 1 模型 SHAP 特征贡献概要图

Fig.1 SHAP summary plot of feature contributions

图 2 的 SHAP 依赖图清晰揭示了各特征的分阶段影响规律:在低浓度区间,电导率低于 15 mS/cm 时对应的 SHAP 值为负,pH 小于 12.5 时 SHAP 逐渐降至全段最低负值,特征取值增加反而会压低模型预测浓度,该曲线特征直观对应体系低浓度工况,此时 pH 不足会显著限制预测浓度的上限,成为主要限制因素;随浓度升高,电导率处于 15 ~ 45 mS/cm

区间时,其SHAP曲线由负值快速攀升至峰值,正向贡献激增,对应体系浓度快速抬升,电导率进入强主导阶段,其数值的微小提升都会带来预测浓度的大幅增长;在高浓度区间,电导率大于45 mS/cm后,SHAP从峰值逐步回落、边际增益下降,电导率的边际效应减弱,pH和温度的辅助微调作用开始显现。

整体来看,三个特征之间呈现明显的互补关系,电导率决定预测浓度的整体水平,pH负责修正中低浓度区间的预测偏差,温度则在不同区间起到辅助放大或抑制作用。相较于单一或两个特征,三者结合能够更全面地捕捉NaOH溶液的理化特性,从而保证模型预测的准确性与可靠性。




图2 各特征SHAP依赖图

Fig.2 SHAP dependence plots for individual features

4 模型应用

4.1 BMED浓度监测的IoT系统搭建

为实现BMED溶液浓度的精准监测与全流程能耗管控,本研究构建了一套多参数协同监测与智能分析的IoT系统,系统的核心创新在于具备多源异构传感器数据的集成处理能力,通过分层架构设计,有效解决了传统电化学监测中数据同步性差、兼容性不足等问题。该系统具体架构如图3所示。




图3 BMED-IoT系统架构

Fig.3 Architecture diagram of BMED-IoT system

BMED系统核心为自主组装膜堆,由6片双极膜、5片阳离子交换膜和5片阴离子交换膜交替排列构成。系统配备4台蠕动泵,分别驱动酸室、碱室、盐室及极室溶液循环,蠕动泵转速稳定在100 r/

min,各室溶液储存单元为500 mL储液罐。实验采用恒流模式,工作电流为6 A。极室初始溶液为0.14 mol/L Na_2SO_4 ,盐室初始溶液为4 mol/L NaCl,酸室与碱室初始均为去离子水。

IoT系统以Niagara软件为核心枢纽,通过电压变送器实时采集膜堆电压,并在碱室内部署pH、温度、电导率及液位传感器,所有传感器均实现同步数据采集。传感器输出的模拟信号经过A/D转换以后传输至JACE控制器,再由JACE推送至Niagara平台进行存储与预处理,最终通过交互接口传输至MATLAB平台,用于算法建模与能耗计算。该系统涵盖感知层、传输层、平台层及监测对象,实现从多源数据采集、融合传输到智能分析、可视化展示的全链路闭环管理,兼具针对性与通用性。

感知层以多源异构高精度传感设备为载体,负责实时捕获BMED系统运行中的核心参数。针对不同传感器信号特性设计统一同步触发机制,确保数据时序一致性:膜堆电压通过高精度电压变送器以1次/s频率采集;碱溶液的pH、温度、电导率及液位通过原位水质传感器同步采集,频率同样为1次/s。所有传感器均集成了抗电磁干扰与耐腐蚀设计,以适应BMED系统复杂工况。

传输层承担多源异构数据的实时传输、双向交互与融合预处理功能。通过无线通信模块构建低延迟数据链路,引入多源数据缓存融合机制,对感知层数据进行实时缓存与格式标准化处理,支持断点续传;同时,通过内置协议转换单元,实现不同类型传感器数据与 Niagara、MATLAB 软件的无缝兼容,构建“同步传输-缓存融合-协议适配”的一体化数据链路。

平台层依托 Niagara 与 MATLAB 软件的协同集成,实现数据处理与智能分析。Niagara 负责数据的存储、分类管理与初步可视化,通过 Modbus-TCP 接口与 MATLAB 建立高可靠通信链路。MATLAB 基于能耗计算公式实时输出 SEC 结果,并借助 ML 工具箱训练 MLP 模型,代入实时采集参数实现浓度精准预测。Modbus-TCP 协议确保数据交互延迟控制在毫秒级,形成“数据接收-深度分析-结果反馈”的闭环处理机制。

4.2 数据采集

系统连续运行 10 min,通过 Niagara 同步采集膜堆电压、碱室 pH、温度、电导率、液位等在线数据,并实时传输至 MATLAB。同时,通过人工取样,采用滴定法离线检测碱浓度,共获取 20 组离线基准数据及对应时刻在线数据。基于在线数据,通过浓度预测模型预测碱浓度,并结合能耗计算公式得到在线监测结果。

4.3 数据分析

选取表现最优的 MLP 模型在独立验证集上开展性能评估,以验证其泛化能力,并绘制预测浓度与真实浓度的散点拟合关系图,见图 4。从散点分布特征来看,预测值整体沿理想拟合线呈明显的线性分布趋势,低浓度至中浓度区间的预测点与拟合线贴合度较高,仅在高浓度区间存在少量离散点,整体无明显系统性偏差。综上,量化指标与分布特征共同证实,MLP 模型具备优良的泛化性能与预测稳定性,能够有效实现目标变量的精准预测,完全满足本研究对预测模型的精度与可靠性要求。

通过 MATLAB 软件对 BMED 过程的 SEC 数据进行预处理,包括剔除监测异常值和采用滑动窗口平滑降噪后,绘制了 SEC 随运行时间的变化趋势曲线(见图 5)。可见,MLP 模型可精准捕捉 BMED 过程 SEC 的动态演化规律,预测曲线完整复现了系统从启动快速上升、首个峰值回落、阶段性回升调整

至长期缓慢上升的全周期能耗变化特征,为过程能耗的原位监测与分析提供了可靠依据。




图4 MLP预测值散点图

Fig.4 Scatter plot of MLP predicted values




图5 SEC随时间的变化

Fig.5 Variation of SEC with time

从能耗演化特征来看,BMED过程SEC呈现出清晰的阶段性变化:启动阶段SEC随运行时间快速攀升并达到首个峰值,随后快速回落至阶段性低点后小幅回升形成次高峰,最终在小幅回落后趋于稳定,并呈现缓慢且持续的上升趋势,这与BMED过程的物理化学机制高度契合:系统启动初期,膜堆内离子浓度低、迁移阻力大,需施加较高电压驱动离子迁移,此时总能耗较高但产碱量较少,因此SEC快速升高并达到峰值;随着运行时间推进,膜堆内离子浓度梯度逐步建立,离子迁移阻力减小、膜堆工作电压降低,SEC随之快速回落,受系统工况调整与离子分布再平衡影响,SEC触底后小幅回升;当系统进入长期运行后,受浓差极化加剧、膜污染累积

或电解质消耗等因素影响,维持相同电流密度所需的工作电压逐渐升高,导致 SEC 在长期运行阶段呈现缓慢上升的趋势。

4.4 离线与在线数据域偏移性能影响分析

本研究用于模型训练与离线测试的数据集,均采集于人工配制的静态 NaOH 标准溶液实验场景,属于理想状态下的离线稳态数据。该实验工况可控性高,溶液体系无持续化学反应、离子迁移与物质消耗生成等动态过程,pH、温度、电导率三类核心理化参数变化平缓、稳定性极强,数据采集过程受外界干扰极小。因此,离线数据集具备分布均匀、噪声低、信噪比高、数据特征单一稳定的特点,使模型能够精准学习稳态溶液参数与目标指标之间的映射关系,最优模型离线测试集决定系数 R^2 可达 1.000 0,拟合精度极高。

然而,将基于静态离线数据训练得到的模型直接迁移应用于 BMED 动态电解反应在线场景时,模型预测性能出现显著衰减,在线验证集 R^2 仅为 0.905 0,模型精度整体下降 9.5%。产生该现象的核心原因是离线稳态数据与在线动态数据存在显著的域偏移问题。在 BMED 实际电解反应过程中,体系始终处于持续电解、离子定向迁移、反应物消耗与产物生成的非稳态动态工况,溶液理化特性时刻发生变化。同时,实验过程中设备采集精度误差、实验室环境微小扰动、电化学反应滞后惯性、溶液微量杂质干扰等多重不确定因素叠加,导致在线数据集存在大量不规则波动与随机噪声,数据分布复杂度远高于静态配液数据。

模型基于传统监督学习方式完成训练,拟合规律高度依附于训练数据集的特征分布,泛化能力存在局限性。模型仅学习了静态稳态配液场景下的数据映射逻辑,无法有效捕捉 BMED 动态反应过程中复杂、多变的理化数据特征,难以适配非稳态、高扰动的真实工况,最终导致模型在线预测精度大幅回落。这也充分说明,仅依靠理想稳态离线数据训练的预测模型,环境适配性与场景通用性较差,无法直接适配复杂的工业与动态实验工况。

针对本文模型因数据域偏移导致在线预测性能下降的问题,后续可通过数据优化与算法改进两种方式完善模型,提升模型的场景泛化能力与预测稳定性。其一,扩充 BMED 动态反应工况下的在线实验样本,构建包含多扰动、多工况的动态数据集,

对预训练模型进行在线微调,让模型学习动态场景的数据特征规律,适配真实电解工况;其二,引入迁移学习与域自适应算法,弱化离线稳态数据与在线动态数据之间的分布差异,消除域偏移带来的预测偏差,进一步弥补模型在线预测的精度损失,有效提升模型在复杂动态反应体系中的通用性、鲁棒性与工程应用价值。

5 结论

① 通过配制不同浓度的 NaOH 溶液,采集 pH、温度、电导率数据,经精细化处理获得 4 462 条有效样本,特征相关性分析表明,电导率与浓度的决定系数 R^2 达 0.994 0,pH 与浓度的 R^2 为 0.804 0,三者与浓度存在显著的物理化学关联,为浓度预测模型的输入特征选取提供了机理与数据支撑。

② 基于配制溶液数据集,对比了 MLP、SVR、GBR 和 LSTM 四种算法的浓度预测性能。其中 MLP 模型表现最优,在测试集上的 R^2 为 1.000 0, RMSE 为 0.000 2, MAE 为 0.000 1。将训练好的 MLP 模型应用于实际 BMED 过程碱室溶液的在线浓度预测,验证集 R^2 为 0.905 0, RMSE 为 0.028 8, MAE 为 0.024 3。模型在低中浓度区间预测精度较高,高浓度区间存在少量偏差,整体泛化能力满足 BMED 工艺浓度预测的需求。

③ 构建了涵盖感知层、传输层、平台层的三层 IoT 架构,实现了 BMED 系统多源参数的同步采集、低延迟传输与智能分析。结合 MLP 模型的浓度预测结果与能耗计算公式,动态推演 SEC,能够准确捕捉 BMED 系统 SEC 的动态变化规律,该方案有效突破了传统监测方法的技术局限,为 BMED 系统的节能调控与优化运行提供了实用的技术工具。

参考文献:

- [1] Merkel A, Rudolph-Schöpping G, Suwal S, et al. Application of bipolar membrane electrodialysis for acidification of skim milk. A comprehensive study on process performance and effects on ion-exchange membranes [J]. Journal of Membrane Science, 2024, 694: 122429.
- [2] 董隽,薛上峰,沈江南,等.复循环双极膜电渗析处理煤化工含盐废水制备酸碱的研究[J].膜科学与技术,2023,43(2):112-122.
- Dong Jun, Xue Shangfeng, Shen Jiangnan, et al.

- Multi-circulation bipolar membrane electrodialysis treatment of coal chemical salt wastewater for preparation of acid and base [J]. Membrane Science and Technology, 2023, 43(2): 112–122 (in Chinese).
- [3] Jarma Y A, Çermikli E, Ipekçi D, et al. Comparison of two electrodialysis stacks having different ion exchange and bipolar membranes for simultaneous separation of boron and lithium from aqueous solution [J]. Desalination, 2021, 500: 114850.
- [4] Parnamae R, Mareev S, Nikonenko V, et al. Bipolar membranes: a review on principles, latest developments, and applications [J]. Journal of Membrane Science, 2021, 617: 118538.
- [5] Zhao W Y, Zhou M, Yan B, et al. Waste conversion and resource recovery from wastewater by ion exchange membranes: state-of-the-art and perspective [J]. Industrial & Engineering Chemistry Research, 2018, 57(18): 6025–6039.
- [6] Peng Z, Wang H, Cheng Y, et al. Treatment of carbocysteine wastewater by bipolar membrane electrodialysis: from lab- to pilot-scale [J]. Journal of Membrane Science, 2023, 687: 122056.
- [7] Wu D S, Chen G Q, Hu B S, et al. Feasibility and energy consumption analysis of phenol removal from salty wastewater by electro-electrodialysis [J]. Separation and Purification Technology, 2019, 215: 44–50.
- [8] Bao Z Q, Zhang X, Wang H F, et al. A simultaneous energy self-sufficient desalination and energy output process based on a novel membrane stack design [J]. Separation and Purification Technology, 2025, 354: 129200.
- [9] Wu S, Fu R, Yan J, et al. Online neutralization promotes water dissociation equilibrium forward in bipolar membranes to achieve 9.2 mol/L NaOH production [J]. Chemical Engineering Journal, 2024, 490: 151610.
- [10] Zhu J, Asadi A, Kang D, et al. Bipolar membranes electrodialysis of lithium sulfate solutions from hydrometallurgical recycling of spent lithium-ion batteries [J]. Separation and Purification Technology, 2025, 354: 128715.
- [11] 田磊, 王岱, 巢志理. 双极膜电渗析在高浓盐水资源化的性能评价指标研究 [J]. 应用化工, 2021, 50(11): 3011–3014.
- Tian Lei, Wang Dai, Chao Zhili. Study on evaluation index of bipolar membrane electrodialysis in concentration brine resource utilization [J]. Applied Chemical Industry, 2021, 50(11): 3011–3014 (in Chinese).
- [12] 朱静怡, 黄苑曦, 周石庆, 等. 基于机器学习的高锰酸钾与有机污染物反应活性预测 [J]. 中国给水排水, 2024, 40(11): 41–48.
- Zhu Jingyi, Huang Yuanxi, Zhou Shiqing, et al. Prediction of reactivity between potassium permanganate and organic pollutants based on machine learning [J]. China Water & Wastewater, 2024, 40(11): 41–48 (in Chinese).
- [13] 白雨鑫, 田丽, 李长芳, 等. 基于机器学习的污水厂总氮超标预警及风险控制 [J]. 中国给水排水, 2025, 41(19): 109–115.
- Bai Yuxin, Tian Li, Li Changfang, et al. Early warning and risk control for total nitrogen exceeding discharge standard in wastewater treatment plants based on machine learning [J]. China Water & Wastewater, 2025, 41(19): 109–115 (in Chinese).
- [14] Slošić V, Batoš M, Nađ Đ, et al. Diver velocity estimation using inertial measurements and LSTM neural networks trained on DVL data [J]. Control Engineering Practice, 2026, 174: 107018.
- [15] 李双宇, 张明凯, 施汉昌, 等. 基于LSTM模型的排水系统流量预测研究 [J]. 中国给水排水, 2022, 38(5): 59–64.
- Li Shuangyu, Zhang Ming kai, Shi Hanchang, et al. Flow prediction of drainage system based on long short time memory model [J]. China Water & Wastewater, 2022, 38(5): 59–64 (in Chinese).
- [16] 范鹏辉, 姜涛, 陈兵, 等. 基于液位监测及CNN-SVM的排水管网缺陷诊断 [J]. 中国给水排水, 2023, 39(23): 30–39.
- Fan Penghui, Jiang Tao, Chen Bing, et al. Fault diagnosis method of drainage network based on liquid level monitoring data and CNN-SVM [J]. China Water & Wastewater, 2023, 39(23): 30–39 (in Chinese).

作者简介: 刘颖(1988—), 女, 内蒙古赤峰人, 博士, 副教授, 从事膜法水处理技术、膜材料的制备及表征、机器学习、智慧水务等研究。

E-mail: chifengluying@126.com

收稿日期: 2026-04-21

修回日期: 2026-05-28

(编辑: 李德强)