



基于多通道时空卷积注意力网络的铝电解槽阳极效应趋势预测

陈祖国 刘辉 黄毅 陈超洋

Anode Effect Trend Prediction of Aluminum Electrolysis Cells Based on Multi-channel Spatiotemporal Convolutional Attention Network

CHEN Zu-Guo, LIU Hui, HUANG Yi, CHEN Chao-Yang

在线阅读 View online: <https://doi.org/10.16383/j.aas.c250635>

您可能感兴趣的其他文章

基于多层注意力和消息传递网络的药物相互作用预测方法

Drug-drug Interaction Prediction Method Based on Multi-level Attention Mechanism and Message Passing Neural Network

自动化学报. 2023, 49(12): 2507–2519 <https://doi.org/10.16383/j.aas.c220371>

基于多注意力机制的维吾尔语人称代词指代消解

Anaphora Resolution of Uyghur Personal Pronouns Based on Multi-attention Mechanism

自动化学报. 2021, 47(6): 1412–1421 <https://doi.org/10.16383/j.aas.c180678>

基于注意力机制的协同卷积动态推荐网络

Attention-based Collaborative Convolutional Dynamic Network for Recommendation

自动化学报. 2021, 47(10): 2438–2448 <https://doi.org/10.16383/j.aas.c190820>

基于重组性高斯自注意力的视觉Transformer

Vision Transformer Based on Reconfigurable Gaussian Self-attention

自动化学报. 2023, 49(9): 1976–1988 <https://doi.org/10.16383/j.aas.c220715>

基于动态注意力深度迁移网络的高炉铁水硅含量在线预测方法

Online Prediction Method for Silicon Content of Molten Iron in Blast Furnace Based on Dynamic Attention Deep Transfer Network

自动化学报. 2023, 49(5): 949–963 <https://doi.org/10.16383/j.aas.c210524>

融合自注意力机制和相对鉴别的无监督图像翻译

Unsupervised Image-to-Image Translation With Self-Attention and Relativistic Discriminator Adversarial Networks

自动化学报. 2021, 47(9): 2226–2237 <https://doi.org/10.16383/j.aas.c190074>

基于多通道时空卷积注意力网络的铝电解槽阳极效应趋势预测

陈祖国^{1,2} 刘辉^{1,3} 黄毅^{1,2} 陈超洋^{1,2}

摘要 在铝电解过程中, 阳极效应是影响电能利用效率的典型异常工况, 其发生往往伴随阳极电阻的剧烈波动. 若能实现阳极电阻变化的实时预测, 即可对阳极效应进行前瞻性识别. 为此, 提出一种融合机理约束与数据驱动思想的多通道时空预测模型(卷积长短期记忆-二维卷积-多头注意力, ConvLSTM-Conv2D-MHA), 以联合刻画多槽系统的共性与差异特征. 模型利用堆叠 ConvLSTM 提取时序动态, 通过 Conv2D 分支强化空间特征表达, 并引入 MHA 机制捕捉长时依赖关系, 从而提升对趋势变化及早期波动的敏感度. 实验结果表明, 该模型在阳极电阻趋势预测中表现出更高的精度与稳定性, 较传统时序模型更能利用多槽间潜在的耦合关联.

关键词 电阻趋势预测; 多通道 ConvLSTM; 多头注意力机制; 阳极效应

引用格式 陈祖国, 刘辉, 黄毅, 陈超洋. 基于多通道时空卷积注意力网络的铝电解槽阳极效应趋势预测. 自动化学报, 2026, 52(7): 1413–1425

DOI 10.16383/j.aas.c250635 **CSTR** 32138.14.j.aas.c250635

Anode Effect Trend Prediction of Aluminum Electrolysis Cells Based on Multi-channel Spatiotemporal Convolutional Attention Network

CHEN Zu-Guo^{1,2} LIU Hui^{1,3} HUANG Yi^{1,2} CHEN Chao-Yang^{1,2}

Abstract In the process of aluminum electrolysis, the anode effect is a typical abnormal operating condition that affects electrical energy utilization efficiency and is usually accompanied by sharp fluctuations in anode resistance. Real-time prediction of anode resistance variations enables proactive identification of anode effects. To address this issue, a multi-channel spatiotemporal prediction model integrating convolutional long short-term memory (ConvLSTM), two-dimensional convolution (Conv2D), and multi-head attention (MHA), namely ConvLSTM-Conv2D-MHA, is proposed by combining mechanism constraints with data-driven principles to jointly capture both the commonalities and differences within multiple cell systems. The model employs stacked ConvLSTM to extract temporal dynamics, utilizes a Conv2D branch to enhance spatial feature representation, and incorporates MHA mechanism to capture long-term dependencies, thereby improving sensitivity to trend changes and early-stage fluctuations. Experimental results demonstrate that the proposed model achieves higher accuracy and stability in anode resistance trend prediction and is more effective than conventional time-series models in exploiting the potential coupling relationships among multiple cells.

Keywords resistance trend prediction; multi-channel ConvLSTM; multi-head attention mechanism; anode effect

Citation Chen Zu-Guo, Liu Hui, Huang Yi, Chen Chao-Yang. Anode effect trend prediction of aluminum electrolysis cells based on multi-channel spatiotemporal convolutional attention network. *Acta Automatica Sinica*, 2026, 52(7): 1413–1425

收稿日期 2025-11-17 录用日期 2026-03-19

Manuscript received November 17, 2025; accepted March 19, 2026

国家自然科学基金(62373144, 62403193), 湖南省科技创新计划(2025RC3197, 2024RC9015, 2025RC4012)资助

Supported by National Natural Science Foundation of China (62373144, 62403193) and Technology Innovation Program of Hunan Province (2025RC3197, 2024RC9015, 2025RC4012)

本文责任编辑 那靖

Recommended by Associate Editor NA Jing

1. 湖南科技大学三亚研究院 三亚 572000 2. 湖南科技大学信息与电气工程学院 湘潭 411201 3. 湖南科技大学计算机科学与工程学院 湘潭 411201

1. Sanya Research Institute, Hunan University of Science and Technology, Sanya 572000 2. College of Information and Electrical Engineering, Hunan University of Science and Technology, Xiangtan 411201 3. College of Computer Science and Engineering, Hunan University of Science and Technology, Xiangtan 411201

铝电解是全球最广泛采用的铝冶炼工艺, 基于霍尔-埃鲁(Hall-Héroult)电解法, 在高温熔融氟盐中将氧化铝还原为金属铝^[1]. 该过程能耗巨大, 电解槽电能消耗占总能耗 90% 以上. 阳极效应是典型异常状态, 会导致电压突升、能耗增加及设备损伤, 其演化通常伴随阳极电阻波动. 因此, 通过预测阳极电阻趋势, 可实现阳极效应的早期识别, 对提升电流效率与能耗管理具有重要意义^[2–3].

阳极电阻受电流波动、电磁扰动以及多槽交互效应影响, 因此具有明显的非线性与时变特征, 使趋势预测困难. 传统机理建模依赖假设和参数, 工况变化时精度易下降, 数据驱动方法通过变量映射

预测状态或趋势,已在工业预测中广泛应用^[4-6].如 Zhang 等^[7]采用核极限学习机估计氧化铝浓度, Xu 等^[8]利用 LSSVM 预测电解槽电压,但这些方法在刻画非线性动态和长时依赖方面仍存在限制,对阳极效应早期趋势识别能力不足.

深度学习在复杂工业过程建模中表现良好. LSTM (long short-term memory)、GRU (gated recurrent unit) 和 CNN (convolutional neural network) 等能够有效刻画非线性动态过程^[9-14],并已用于电压、电流和功率预测. ConvLSTM (convolutional long short-term memory) 结合卷积和时序记忆机制,可同时处理时间和空间特征,在空间分布明显的工业系统和复杂非线性过程建模中表现出色^[15-16].

在单槽电解建模中, LSTM、ConvLSTM 等深度学习方法已取得一定的成果,但在多槽联合建模方面的研究仍较少.部分学者为克服单槽建模的限制,开始尝试构建多槽协同预测模型. Zhang 等^[17]利用多通道 CNN 挖掘时空相关性以提升多传感器预测精度. Chen 等^[18]提出基于信息-协同-熵的多特征融合来实现多源数据的集成. Ilyushin 等^[19]从磁流体动力学角度展示共电源系统的非线性不稳定性,为多槽间隐式耦合提供理论支持.然而,这些研究大部分侧重局部空间特征,从而导致未能充分刻画共电源驱动的多槽系统的全局依赖性与动态弱相关性.

实际上,多槽系统具有“共电源、共工艺”的弱耦合特性:各槽虽然受同一电源驱动,理论上呈现一定同步性,但受极距、温度及局部扰动差异影响,其信号相关性较弱^[20-23],形成“整体一致-局部差异”的复杂空间依赖^[24-27].因此,需要一种能够同时表征多槽弱相关性与全局时空依赖的建模方法,使其更准确地反映多槽系统的动态演化特征.

针对以上问题,本文提出基于多通道输入的 CLCM (ConvLSTM-Conv2D-MHA) 模型用于阳极效应趋势预测.该方法以多槽共电源为物理先验,将三槽特征作为通道维度输入,通过堆叠 ConvLSTM 提取多槽时空依赖特征,并结合二维卷积 (two-dimensional convolution, Conv2D) 分支增强局部空间模式表达,从而有效捕捉多槽系统的弱相关性及隐式耦合特征.在此基础上,为强化对全局长程依赖与早期微小波动的感知能力,引入多头注意力 (multi-head attention, MHA) 机制^[28],对序列中不同时间步的关联性进行加权建模.模型以阳极电阻一阶差分作为预测目标,并结合归一化及滑动窗口策略,实现对电解槽由稳定向异常演化的前瞻

识别.实验结果表明,该方法在真实工业数据上表现优异,为多槽异常监测及智能优化提供可行方案.

1 技术理论

1.1 卷积 LSTM (ConvLSTM)

卷积长短期记忆网络 (ConvLSTM) 是一种结合卷积神经网络 (CNN) 和长短期记忆 (LSTM) 网络特点的深度学习模型,适用于处理具有时空特征的数据^[29]. ConvLSTM 的核心在于将传统 LSTM 单元中的输入门、遗忘门和输出门的线性操作替换为卷积操作,从而能够同时捕捉空间和时间依赖. ConvLSTM 内部在每个门和候选记忆计算后引入批归一化 (batch normalization, BN) 操作. ConvLSTM 的内部结构图如图 1 所示.

具体而言, ConvLSTM 中每个门的计算如下:

输入门:

$$i_t = \sigma(W_i * X_t + U_i * h_{t-1} + b_i) \quad (1)$$

遗忘门:

$$f_t = \sigma(W_f * X_t + U_f * h_{t-1} + b_f) \quad (2)$$

输出门:

$$o_t = \sigma(W_o * X_t + U_o * h_{t-1} + b_o) \quad (3)$$

隐藏状态更新:

$$h_t = o_t \odot \tanh(C_t) \quad (4)$$

记忆单元更新:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tanh(W_C * X_t + U_C * h_{t-1} + b_C) \quad (5)$$

其中,卷积操作“*”替代了标准 LSTM 的线性矩阵乘法; $\odot$ 表示 Hadamard 逐元素乘积; $\sigma(\cdot)$ 为 Sig-




图 1 ConvLSTM 内部结构

Fig.1 Internal structure of ConvLSTM

moid 激活函数; $\tanh(\cdot)$ 为双曲正切函数; i_t 、 f_t 和 o_t 分别表示输入门、遗忘门和输出门; X_t 、 h_{t-1} 和 C_{t-1} 分别表示当前输入、上一时刻隐藏状态和上一时刻记忆单元; C_t 和 h_t 分别表示当前时刻记忆单元和隐藏状态; W_i 、 W_f 、 W_o 、 W_C 和 U_i 、 U_f 、 U_o 、 U_C 表示卷积权重; b_i 、 b_f 、 b_o 、 b_C 表示偏置参数. 为了图示简化, 将输入卷积权重统一记作 W_x ; 隐藏状态卷积权重统一记作 W_h ; W_{peep} 表示连接权重, 用于将上一时刻记忆单元信息直接引入门控计算. 通过上述结构, ConvLSTM 能够对时空数据进行有效建模.

1.2 多头注意力 (MHA) 机制

多头注意力机制是一种基于注意力权重分配的特征建模方法^[30], 通过计算序列中任意位置之间的相关性, 实现全局信息交互. 与卷积的局部建模不同, MHA 能够直接捕获长程依赖关系, 从而增强模型对全局动态变化的感知能力.

MHA 结构由多个并行的注意力头组成, 每个注意力头通过独立的线性映射生成查询 (query)、键 (key) 和值 (value) 向量, 并计算加权输出, 最后将各头结果拼接后再经线性变换, 实现多子空间特征的融合 (如图 2 所示). 其计算过程如下:

$$Q = HW^Q, K = HW^K, V = HW^V \quad (6)$$

$$\text{head} = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_K}}\right)V \quad (7)$$

$$\text{MHA}(H) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O \quad (8)$$




图 2 多头注意力 (MHA) 机制结构

Fig.2 Structure of multi-head attention (MHA) mechanism

其中, H 表示输入特征矩阵; W^Q 、 W^K 、 W^V 和 W^O 为可训练权重矩阵; Q 、 K 和 V 分别表示查询 (query)、键 (key) 和值 (value) 矩阵; d_K 为每个头的维度; h 为注意力头数; head_i 表示第 i 个注意力头的输出; $\text{Softmax}(\cdot)$ 为归一化函数; K^T 表示矩阵 K 的转置; $\text{Concat}(\cdot)$ 表示按列拼接操作. MHA 通过多头并行的全局依赖建模, 能够在不同子空间中提取互补特征, 从而提升模型的全局特征表达能力.

2 铝电解槽阳极效应趋势预测模型框架

2.1 输入变量选择

在铝电解槽运行过程中, 阳极效应是影响电流效率、能耗水平及槽体稳定性的关键异常状态, 其演化过程通常伴随阳极电阻 (单位: $\mu\Omega$) 的显著波动. 因此, 将阳极电阻作为预测目标, 可有效捕捉阳极效应的趋势, 实现早期识别.

影响阳极电阻变化的因素包括短期动态特征与长期演化特征 (如表 1 所示). 动态特征 (如槽电压、滤波电阻、平滑电阻、波动差值及斜率数据总和等) 反映电解槽的瞬时运行状态与电流波动; 长期特征 (如槽龄、额外喂料量等) 体现系统的渐变趋势与长期稳定性.

表 1 模型输入参数
Table 1 Model input parameters

序号	参数	描述
1	槽电压	电解槽电解质熔体中的总电压降
2	滤波电阻	电解槽中过滤系统的电阻
3	平滑电阻	电解槽电解质层的电阻
4	波动差值	电解槽电压或电流波动幅度
5	斜率数据总和	电压或电流变化的速率
6	槽龄	电解槽已运行的时间
7	额外喂料量	电解槽中添加氟盐和三氧化二铝量

这些特征构成多通道 CLCM 模型的输入变量, 使其在时空尺度上同时建模, 刻画阳极电阻的短期波动与长期演化, 从而提升趋势预测与异常感知能力.

2.2 模型结构设计

为实现电解槽阳极电阻趋势的高精度预测, 本文构建了一种基于 CLCM 的多通道时空融合模型, 其整体结构如图 3 所示. 该模型综合利用时序建模、空间卷积与注意力机制, 对阳极电阻的短期波动特征、长期演化趋势以及多槽之间的弱相关关系进行联合刻画.

模型整体由四个功能模块组成: 多槽通道输入层 (multi-channel input layer)、空间卷积分支




图3 CLCM 结构

Fig.3 Structure of CLCM

(spatial convolutional branch)、时序注意力模块(temporal attention module) 以及特征融合输出层(feature fusion output layer). 其中, 多槽通道输入层用于并行接收各电解槽的历史运行序列; 空间卷积分支在槽通道维度上显式建模槽间弱相关结构; 时序注意力模块对不同时刻的特征响应进行自适应加权; 特征融合输出层输出预测结果.

需要强调的是, 本文模型并非对现有时空预测结构的简单叠加, 而是针对多槽电解槽系统“共电源驱动、槽间响应弱相关且扰动存在异步性”的运行特性进行定向设计. 其中, ConvLSTM 层用于刻画单槽阳极电阻序列中的局部短期与中期动态特征; 空间卷积分支弥补仅进行时间建模难以捕捉跨槽协同特征的不足; 时序注意力模块则进一步强化对关键扰动片段及长程时间依赖关系的建模能力. 各模块以串联方式协同工作, 形成面向多槽弱相关工业时序预测的统一建模框架.

2.2.1 多槽通道输入层

多槽通道输入层用于在保留各电解槽独立特征的同时, 实现多槽信息的并行建模与共享表达, 为后续槽间弱相关特征的空间建模提供结构先验. 该层支持多源特征的统一输入, 有助于提升模型对复杂运行状态的整体表征能力.

具体而言, 将各槽的关键运行特征(如电压、阳极电阻、波动幅值及加料量等)按槽通道维度进行堆叠, 构建多通道时序输入张量, 其形式如式(9)所示:

$$x \in \mathbf{R}^{N \times T \times P \times D} \quad (9)$$

其中, N 为样本数量; T 为时间步长; P 为每槽特征数量; D 为槽通道数. 通过在通道维度堆叠多槽数据, 神经网络可以同时处理多源信号. 通过在通道维度引入多槽数据, 模型能够在保持单槽特征独立性的同时, 自适应学习槽间弱相关信息, 从而提升整体预测性能. 结合阳极电阻变化特性与预测稳定性需求, 本文将输入序列长度 n_lag 设定为 10, 在保证模型能够捕捉有效历史信息的同时避免引入过多冗余特征. 为保证对比实验的可比性, 需要输入序列模型均采用相同的输入窗口长度.

为增强模型对局部动态变化的感知能力, 在进入多槽通道结构之前, 对阳极电阻序列进行一阶差分处理, 以突出微小波动并抑制缓慢趋势漂移的影响. 设原始阳极电阻序列为 $\{\Delta R_t\}$, 其中 R_t 表示第 t 时刻的阳极电阻测量值. 为刻画阳极电阻在相邻时刻之间的动态变化特征, 对原始序列进行一阶差分处理, 其定义为:

$$\Delta R_t = R_t - R_{t-1} \quad (10)$$

其中, ΔR_t 表示阳极电阻在短时间尺度内的变化量, 反映了阳极工作状态及工况条件的瞬时波动特征.

将 ΔR_t 作为预测目标, 使模型重点学习阳极电阻的短期变化趋势而非绝对水平, 从而降低长期工况变化对预测结果的干扰. 该设计有助于放大阳极效应发生前波动幅值与频率逐步增强的动态特征, 为后续时空特征建模提供更加稳定且信息密集的输入表示. 相关效果在后续局部均方根误差 (root mean squared error, RMSE) 分析中得到进一步验证.

2.2.2 空间卷积分支

空间卷积分支用于对多槽输入在空间维度上进行显式建模(如图4), 以捕捉相邻电解槽之间的局部相关结构, 并弥补缺相关工况下仅依赖时序建模可能造成的槽间特征耦合不足. 在实际工业运行中, 相邻电解槽在共用电源与整体工况调节条件下, 其宏观运行趋势具有一定一致性, 但在局部扰动、瞬态响应及波动幅值方面仍呈现出明显的弱相关特征, 因此有必要在模型中引入专门的空间建模机制.




图4 Conv2D 原理流程图

Fig.4 Flowchart of Conv2D principle

在完成 ConvLSTM 时序特征提取后, 将其输出的多槽特征张量按照“时间步 $\times$ 槽通道 $\times$ 特征维度”的形式进行重排, 并构建对应的二维特征平面. 在该平面上施加二维卷积操作, 使卷积核在时间维度与槽通道维度上同时滑动, 从而在局部感受野内学习多槽之间的协同变化模式, 实现对槽间弱空间相关性的显式建模. 二维卷积运算的数学形式表示为:

$$H_{t,s}^{(l)} = \sum_{i=0}^{K_t-1} \sum_{j=0}^{K_s-1} \sum_{m=1}^M W_{i,j,m}^{(l)} \cdot H_{t+i,s+j,m}^{(l-1)} + b^{(l)} \quad (11)$$

其中, $H_{t,s}^{(l)}$ 表示第 l 层二维卷积在时间索引 t 与槽位索引 s 处的输出特征; $H_{t+i,s+j,m}^{(l-1)}$ 为上一层 (ConvLSTM 层) 的输入特征, m 表示输入特征的通道索引, $t+i$ 与 $s+j$ 分别表示卷积核在时间维度与槽通道维度上的局部感受位置; $W_{i,j,m}^{(l)}$ 为第 l 层二维卷积参数, 用于刻画第 m 个输入通道在时间维度偏移 i 与槽位维度偏移 j 下对输出特征的贡献权重; $b^{(l)}$ 为第 l 层的偏置项; K_t 和 K_s 分别为卷积核在时间维度与槽通道维度上的尺寸; M 为输入特征的通道数。

通过在槽通道维度上引入局部卷积感受野, 该空间卷积分支允许相邻电解槽之间的特征进行信息交互, 从而刻画由电流分布、电压扰动或局部工况变化引发的槽间协同响应特性。该结构不同于逐槽独立建模方式, 它并不假设槽间存在强空间相关性, 而是通过局部卷积自适应提取槽间微弱但稳定的关联特征, 从而增强模型在弱相关多槽结构下的特征表达能力。

最终, 空间卷积分支提取的槽间空间特征在特征融合阶段与时序注意力模块输出的全局时间依赖特征进行联合建模: 前者偏向刻画多槽结构层面的局部一致性与空间约束; 后者侧重时间维度上的动态重要性选择。二者相互补充, 使模型在复杂工况条件下同时具备稳定的空间建模能力与灵敏的时序响应能力。

2.2.3 时序注意力模块

该模块用于对多槽差分序列进行深层时序建模, 并实现关键时间步的自适应加权, 以增强模型对非平稳时序中微小波动与长程依赖特征的刻画能力。首先, 采用多层 ConvLSTM 对多通道输入特征进行编码。ConvLSTM 在时间递归结构中引入卷积运算, 能够在保持时序依赖建模能力的同时提取局部动态模式, 从而有效刻画阳极电阻在短期扰动与中长期演化过程中的变化特征。通过多层堆叠并结合层归一化与 Dropout 等正则化策略, 可进一步提升模型训练的稳定性与泛化性能。

在 ConvLSTM 输出的隐状态序列基础上, 引入多头时序注意力机制以建模全局时间依赖关系。设 ConvLSTM 输出的隐状态表示为:

$$H = \{s_1, s_2, \dots, s_T\} \quad (12)$$

其中, $s_t \in \mathbf{R}^d$ 表示第 t 个时间步的特征向量, d 为特征维度。MHA 模块通过三组独立的线性映射构

建查询、键和值向量, 并将特征维度划分为多个注意力头, 在不同子空间中并行计算时间步之间的相关性权重。

在多槽建模场景下, 各槽通道特征已在多通道输入层与 ConvLSTM 编码阶段完成融合, 多头注意力机制主要沿时间维度对隐状态序列进行加权建模, 从而突出对趋势突变或异常演化具有指示意义的关键时间片段, 避免等权时序建模造成的重要信息稀释, 并增强模型对长程依赖与非平稳波动的建模能力。最终, MHA 输出具有时间加权特性的全局时序表示, 为后续二维卷积分支进行槽间空间特征融合提供动态时序先验, 使模型在多槽弱相关条件下仍能保持稳定且灵敏的预测性能。

2.2.4 特征融合输出层

特征融合输出层的作用是将全局时序特征与局部空间特征统一建模, 生成高层语义表示并输出趋势预测结果, 同时结合 Dropout 和激活函数提高鲁棒性和非线性表达能力。具体设计为将 MHA 输出向量与空间卷积输出拼接, 经过全连接 (fully connected, FC) 层和 ReLU 激活映射生成融合特征, 最后通过线性回归层输出预测结果。为了清晰展示特征融合与输出流程, 图 5 是特征融合输出层结构示意图。

其计算过程如下:

$$F = \text{Concat}(u, S) \quad (13)$$

$$F' = \text{Dropout}(\text{ReLU}(W_f F + b_f)) \quad (14)$$

$$\hat{y}_i = W_o F' + b_o \quad (15)$$

训练过程中用均方误差 (mean squared error, MSE) 作为损失函数:

$$\mathcal{L} = \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (16)$$

其中, u 表示时间特征分支输出; S 表示空间特征分支输出; F 为特征拼接后的融合表示; F' 表示经非线性变换后的特征表示; y_i 表示第 i 个样本的真实值; $\hat{y}_i$ 表示第 i 个样本的预测值; N 为样本数量; $\mathcal{L}$




图 5 特征融合输出层结构示意图

Fig.5 Feature fusion output layer structure diagram

表示损失函数。

该模型通过多通道输入、ConvLSTM 以及注意力和 Conv2D 分支联合建模时空特征, 实现对多槽阳极效应趋势的准确预测。

2.3 模型预测方法与流程

为实现对电解槽阳极效应趋势的高精度预测, 本研究设计了一个多槽差分特征的时空融合预测算法, 具体步骤如图 6 所示。其整体流程包括数据输入与特征构建、时序建模、空间特征建模与融合, 以及预测输出与还原四个阶段。




图 6 基于阳极电阻的阳极效应趋势预测方法流程

Fig. 6 Flowchart of anode effect trend prediction method based on anode resistance

步骤 1. 数据输入与特征构建: 同步整理三槽时序数据, 选取关键工艺参数构建多槽特征矩阵, 并通过槽间差值刻画弱相关性, 为时空特征建模提供基础。

步骤 2. 时序建模: 利用多层 ConvLSTM 对前 n_lag 步序列进行建模, 捕捉阳极电阻短期波动与长期趋势, 并通过层归一化与 Dropout 提高训练稳定性和泛化能力, 实现槽间弱相关性与时间动态特征的高效刻画。

步骤 3. 空间特征建模与融合: ConvLSTM 层提取多槽时序依赖后, 经多头注意力 (MHA) 机制

强化关键时序信息; 同时, 空间分支通过 Conv2D 对多槽特征在空间维度进行局部卷积, 显式建模槽间弱相关性与差异特征。随后, 将时序与空间特征进行融合并经全连接层映射, 实现对阳极电阻时空演化特征的联合建模与趋势预测。

步骤 4. 预测输出与还原: 融合特征经全连接层映射得到下一时刻阳极电阻差分预测值, 再通过归一化反变换和一阶反差分还原为实际趋势, 实现阳极效应前瞻识别, 为运行分析和智能优化提供可验证依据。

CLCM 模型的算法流程细节如算法 1 所示。

算法 1. 多槽差分特征的时空融合预测算法

```

1: 初始化;
2: while 未达到训练终止条件 do
3:   利用 ConvLSTM 网络提取时序特征 (式 (1) 和 (5));
4:   利用 MHA 融合时间依赖特征 (式 (6) 和 (8));
5:   for  $j = 1 : N$  do
6:     利用 Conv2D 提取空间卷积特征 (式 (11));
7:   end for
8:   for  $j = 1 : N$  do
9:     融合 MHA 输出与空间卷积特征, 并通过全连接生成预测 (式 (13) 和 (15));
10:  end for
11: end while
12: 对测试集进行预测差分, 并通过基准值恢复原始序列预测;
13: 计算性能指标 RMSE、MAPE、 $R^2$  进行评估 (式 (17) ~ (19)).
  
```

2.4 模型评价指标

电解槽阳极效应趋势预测属于回归任务。本文采用三类常用指标评估模型性能: 均方根误差 (RMSE)、平均绝对百分比误差 (mean absolute percentage error, MAPE) 以及判定系数 (coefficient of determination, R^2), 用于衡量预测精度和拟合效果。

RMSE 反映预测值与真实值的平均偏离程度, 数值越小表示误差越低、预测越稳定。其计算公式为:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (17)$$

MAPE 表示预测值相对真实值的平均误差比例, 值越小表示模型相对误差越低。其计算公式为:

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (18)$$

R^2 反映模型对真实值波动的拟合程度, 取值越

接近 1 表示拟合效果越好. 其计算公式为:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (19)$$

其中, $\bar{y}$ 表示真实值序列的均值.

3 实验采集与讨论

3.1 数据采集与预处理

本文实验数据来源于某大型电解铝企业的实际生产过程, 采集对象为共用电源的相邻三台电解槽 (编号 2830、2831 和 2835). 在共用电源条件下, 各电解槽整体运行趋势具有一定一致性, 但受局部工艺差异与随机扰动影响, 其动态响应仍表现出明显的个体差异性, 呈现“共性与差异并存”的运行特征, 为多槽联合建模提供了潜在的信息增益. 为保证模型评估的客观性与泛化能力, 数据按照时间顺序划分为训练集、验证集和测试集, 其中末尾 3 000 条样本作为测试集, 剩余样本中 10% 用于验证集, 其余作为训练集. 训练集用于模型参数优化, 验证集用于早停判断, 测试集用于最终预测性能评估. 具体数据规模与划分如表 2 所示.

表 2 实验数据集信息
Table 2 Experimental dataset information

参数	数值
数据产生时间	2016 年 6 月 25 日至 2016 年 6 月 28 日
电解槽数量	3
特征数量	7
实验数据样本数	34 560
训练集/验证集/测试集占比	28 404 : 3 156 : 3 000

在数据预处理阶段, 以阳极电阻为预测对象, 对其进行一阶差分得到目标变量 ΔR_t , 通过差分处理消除长期趋势成分并突出短期动态波动特征. 对输入特征采用基于训练集统计参数的 Min-Max 归一化, 将其缩放至 $[0, 1]$; 对差分后的预测目标 ΔR_t 采用标准化 (零均值、单位方差) 处理, 以增强模型对局部波动幅值变化的建模稳定性. 验证集与测试集数据均使用训练集统计参数进行一致化处理.

如图 7 所示, SCADA 数据采集系统以 10 s 为采样间隔对电解槽运行状态进行连续记录, 覆盖约 4 d 的稳定生产周期, 共获得 34 560 条有效样本. 每个电解槽采集 8 项关键工艺特征, 包括平均电压 (mV)、阳极电阻 ($\mu\Omega$)、滤波电阻 ($\mu\Omega$)、平滑电阻

($\mu\Omega$)、波动差值 ($\mu\Omega$)、斜率累加 (μ/s)、槽龄 (d) 以及额外喂料量 (kg). 这些特征能够较为全面地表征电解槽运行状态及其动态变化特征.

样本采用滑动窗口方式构建, 并将三槽数据在通道维度进行堆叠后输入模型, 在保留单槽时序特征的同时体现槽间结构关系. 皮尔逊相关性分析结果如图 8 所示, 各槽之间的线性相关系数接近 0, 表明在共用电源条件下三槽动态行为仍以弱相关为主, 且可能存在非线性耦合关系. 基于上述特性, 本文在完成差分、归一化与滑窗构建的基础上, 引入多通道 ConvLSTM 进行时序特征建模, 并进一步

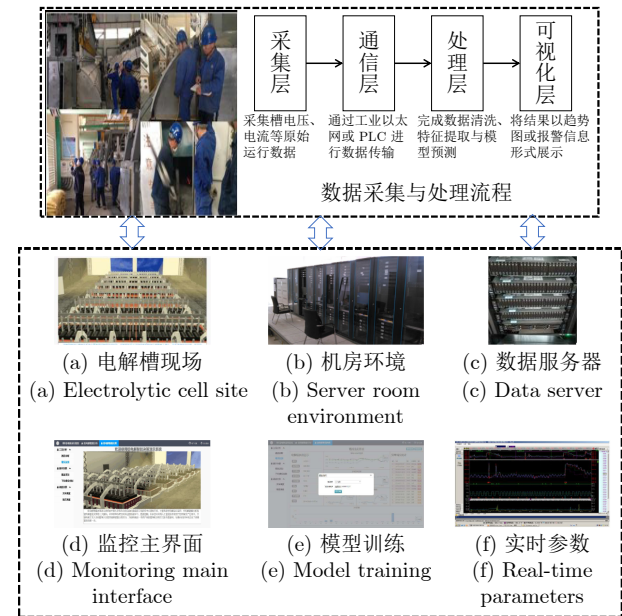


图 7 铝电解数据采集与处理系统示意图

Fig. 7 Schematic diagram of aluminum electrolysis data collection and processing system




图 8 三槽相关性热力图

Fig. 8 Heatmap of correlation among three cells

结合 Conv2D 空间卷积分支对槽间弱空间相关特征进行显式提取。

3.2 预测精度评估与对比分析

本文以相邻三台电解槽采集的 34 560 条高频时序样本为研究对象, 每条样本由当前时刻前连续 10 个时间步的多槽特征及槽间差异特征构成。模型的主要参数设置如表 3 所示。

表 3 CLCM 模型参数
Table 3 Parameters of CLCM model

参数	数值
卷积层	3
卷积核大小	1×3
移动步长	1
ConvLSTM 层隐藏单元数	30
初始学习率	0.001
最大迭代次数	100
批量大小 batch	64

鉴于深度学习模型在训练过程中可能受到随机初始化和批次采样等因素的影响, 为保证实验过程可复现, 模型开发阶段固定了随机种子。在此设置下, CLCM 模型在测试集上的预测性能表现稳定, 关键评价指标波动较小, 整体性能具有良好一致性。为进一步验证模型在不同时间区段及不同设置下的稳健性, 实验采用滑动窗口 RMSE 对消融实验中的局部预测性能进行评估, 以刻画模型在高频扰动区段的稳定性; 同时, 利用配对 t 检验对消融实验结果进行显著性分析, 以验证各结构改进带来的性能提升是否具有统计意义。在全局对比实验中, 引入 Diebold-Mariano (DM) 检验, 以统计方式验证模型预测性能的优势。基于上述分析方法, 实验中所展示的定量结果与预测曲线均来自一次具有代表性的独立实验, 但相关统计检验结果充分表明模型具有良好的稳健性与可靠性。

从数据特性角度看, 阳极电阻序列在较长时间尺度上呈现缓慢变化的运行趋势, 而在短时间尺度内叠加幅值较小但频繁出现局部波动, 并在部分关键时段伴随突发型扰动或明显的峰谷变化。预测曲线与局部时间区段对比结果表明, 此类高频扰动与短时异常在阳极效应发生前通常具有逐步增强的演化特征, 使得阳极电阻序列整体呈现出显著的非平稳性。因此, 预测模型不仅需要具备对长期趋势的稳定拟合能力, 还需对短期微小扰动保持足够的响应灵敏度, 否则容易出现局部峰谷偏移或异常响应滞后的问题。

从空间维度分析, 在共用电源及统一工况调节条件下, 相邻电解槽的宏观运行趋势具有一致性; 但在局部波动幅值、瞬态响应及扰动触发时刻等方面, 槽间响应往往并不同步, 呈现出“弱相关而非强耦合”的运行特征。该特性一方面增加了多槽联合预测的建模难度, 使逐槽独立建模或简单特征拼接难以有效刻画槽间协同响应; 另一方面也为在模型中引入多通道输入结构与槽间空间建模机制提供了现实依据, 从而在保留单槽动态特征的同时, 充分挖掘多槽弱相关信息对预测稳定性的潜在增益。

在模型训练过程中, 所有对比方法均采用一致的数据划分方式、输入特征集合及训练策略, 包括相同的时间窗口长度 (10 步)、优化器参数及早停机机制, 以保证实验结果的公平性与可比性。所有模型均在相同的 CPU 计算环境下完成训练与测试, 未使用 GPU 或其他异构加速设备, 以避免计算资源差异对实验结果造成影响。训练过程中模型收敛过程平稳, 未出现明显波动或发散现象。

最终预测结果如图 9 所示, 所提出模型能够较好地跟踪阳极电阻的短期波动变化, 整体拟合效果良好。鉴于阳极电阻变化能够反映阳极效应的发展趋势, 模型在实现高精度预测的同时, 可为阳极效应趋势识别提供间接参考, 为后续异常预警与工艺优化提供支持。




图 9 CLCM 模型预测结果

Fig.9 Prediction results of CLCM model

需要说明的是, 由于模型输出为阳极电阻的一阶差分, 在性能评估前需对预测结果进行反变换还原。具体而言, 首先对差分预测结果进行反标准化处理以恢复其原始数值尺度, 随后基于预测起始时刻的真实阳极电阻值对差分结果进行累加还原。设预测起始时刻的真实阳极电阻为 R_{t_0} , 则预测时刻 t 的还原值可表示为:

$$\hat{R}_t = R_{t_0} + \sum_{i=t_0+1}^t \Delta \hat{R}_i \quad (20)$$

其中, $\Delta \hat{R}_t$ 表示模型预测得到的阳极电阻变化量; $\hat{R}_t$ 为经反差分处理后恢复的阳极电阻预测值. 经反标准化与反差分处理后, 预测结果被恢复至实际物理量纲 ($\mu\Omega$), 并据此计算各项性能评价指标, 相关结果如表 4 所示.

表 4 CLCM 模型性能评价结果

Table 4 Performance evaluation results of CLCM model

参数	数值
RMSE	8.485
MAPE	0.097%
R^2	0.982

3.3 融合模型和单一模型的对比分析

3.3.1 全局预测性能对比

为评估各模块对模型性能的贡献, 实验中分别构建了 SingleSlot (单槽 ConvLSTM)、NoMHA (去除多头注意力)、NoSpatial (去除二维卷积分支) 等消融模型, 需要指出的是, 所有消融模型均在相同的数据预处理与差分建模策略下进行训练, 因此消融实验结果主要反映不同结构模块在差分增强特征条件下对局部动态波动与时序模式的建模能力差异. 将 RMSE、 R^2 以及 MAPE 作为评价指标, 整体预测结果如图 10 所示, 量化指标列于表 5.




图 10 单一模型与融合模型的预测结果

Fig. 10 Prediction results of single model and fusion model

为进一步分析不同指标与模型性能之间的关系, 将从 RMSE、MAPE 和 R^2 三个方面进行讨论. RMSE 用于衡量预测误差的整体规模, 完整模型的 RMSE 最低, 表明其整体预测偏差最小; MAPE 对微小扰动较为敏感, 完整模型的 MAPE 最低, 说明其对阳极电阻序列中细微波动具有最强的刻画能力; R^2 反映模型对整体变化趋势的拟合程度, 完整模型取得最高 R^2 , 进一步验证了其在时空特征联合建模

表 5 单一模型和融合模型性能对比

Table 5 Performance comparison between single model and fusion model

模型	RMSE	R^2	MAPE (%)
SingleSlot	9.309	0.978	0.127
NoMHA	17.995	0.920	0.328
NoSpatial	15.405	0.940	0.288
CLCM	8.485	0.982	0.097

方面的优势.

实验结果表明, 不同结构模型在阳极电阻趋势预测上的性能差异较为显著. 完整模型整体性能最优, 其 RMSE 为 8.485, R^2 达到 0.982, MAPE 仅为 0.097%, 说明该模型能够同时捕捉长程依赖特征与局部微小扰动. 相比之下, SingleSlot 模型仅利用单槽信息进行建模, RMSE 上升至 9.309, R^2 降至 0.978, 表明多槽之间的弱相关信息及潜在空间模式对提升预测精度具有重要作用. NoMHA 模型在去除多头注意力后, RMSE 显著上升至 17.995, 说明多头注意力在捕捉跨时间步长程依赖关系、增强对早期微弱扰动响应方面具有关键作用. NoSpatial 模型在移除二维卷积分支后, RMSE 为 15.405, 预测性能同样明显下降, 表明空间卷积分支在提取多槽局部空间特征、刻画槽间协同响应方面发挥了重要作用.

综上可见, 所提模型通过多槽通道堆叠、局部卷积增强及全局注意力机制, 有效利用了三槽弱相关性及潜在非线性信息, 从而显著提升了阳极电阻趋势预测精度.

3.3.2 局部预测稳定性分析

为更加全面地评估模型在不同时间区段下的预测稳定性, 将 CLCM、NoMHA、NoSpatial 和 SingleSlot 四种模型的预测误差进行滑动窗口计算, 得到局部 RMSE 随时间变化的曲线, 如图 11 所示. 局部 RMSE 能够刻画模型在短时间扰动条件下的瞬时误差波动特征, 有效弥补全局 RMSE、 R^2 和 MAPE 等指标难以反映局部动态差异的不足, 因此可用于分析模型对高频扰动与瞬态变化的响应能力.

从图 11 可以观察到, 各模型的局部 RMSE 在相似时间区段均出现同步波动, 说明不同模型在相同运行阶段受到一致的外部扰动影响. 然而, 所提模型在整个测试区间内的局部 RMSE 始终保持最低且波动幅度最小, 表明其在短期扰动条件下具有更稳定的预测性能. SingleSlot 模型的局部 RMSE 整体略高于所提模型, 说明仅依赖单槽信息建模会削弱对瞬时波动的抑制能力. 相比之下, NoMHA 与 NoSpatial 模型的局部 RMSE 进一步升高, 且二




图 11 不同模型局部 RMSE 随时间变化曲线

Fig. 11 Time-varying local RMSE curves of different models

者差异相对较小,表明无论去除多头注意力还是二维卷积分支,都会显著削弱模型对复杂时空特征的联合建模能力,从而导致短期预测误差放大。

从模型结构机制角度分析,二维卷积分支通过在槽通道维度内引入局部感受野,实现对槽间弱空间相关特征的显式建模;多头注意力则通过对不同时间步特征进行动态加权,增强了模型对关键历史信息及长程依赖关系的刻画能力。尽管在本研究中未对注意力权重进行显式可视化,但消融实验中局部 RMSE 曲线的显著差异表明,去除任一模块都会导致预测误差放大与稳定性下降,从性能退化角度间接验证了上述模块在提升局部预测稳定性方面的有效性。

需要说明的是,消融实验关注的是同一模型在不同结构配置下的性能差异,相关结果基于多次独立实验统计获得。因此,在模型训练与验证过程中采用配对样本 t 检验对局部 RMSE 进行显著性分析,而非用于比较预测误差序列的 DM 检验。对 10 次独立实验所得局部 RMSE 结果进行配对样本 t 检验 (表 6) 可知,CLCM 模型相较于 NoMHA、No-Spatial 及 SingleSlot 模型的性能提升均具有高度统计显著性 ($p < 0.001$),进一步验证了本文所引入结构模块在提升局部预测精度与稳定性方面的可靠贡献。

表 6 消融实验模型局部 RMSE 显著性检验结果
Table 6 Significance test results of local RMSE for ablation experiment models

对比模型	t 值	p 值	显著性 ($p < 0.05$)
CLCM 与 NoMHA	-27.150	< 0.001	显著
CLCM 与 NoSpatial	-24.163	< 0.001	显著
CLCM 与 SingleSlot	-22.544	< 0.001	显著

综合上述分析,CLCM 模型能够在短期扰动与高频波动条件下保持更低且更稳定的局部预测误

差,从局部层面进一步验证了其结构设计的合理性与工程适用性。

3.4 预测精度评估与对比

3.4.1 全局指标对比分析

从全局评价指标 (RMSE、MAPE、 R^2) 来看,CLCM 在所有模型中表现最佳 (如表 7、图 12 所示),其 RMSE 为 8.485、MAPE 为 0.097%、 R^2 达到 0.982,显著优于其他深度学习与传统模型。

具体而言,LSTM_diff 的 RMSE 为 10.537,MAPE 为 0.160%, R^2 为 0.972,在整体趋势拟合方面具备一定能力,但在误差控制与微小波动响应方面仍不及所提出模型;TCN 的 RMSE 为 14.422,MAPE 为 0.267%, R^2 为 0.948,表明其在长程趋势建模上存在一定优势,但在高频扰动区段容易出现相位偏移与幅值衰减;XGBoost 在 RMSE (21.605) 与 MAPE (0.405%) 上表现较差,说明基于树模型的方法在弱相关、高噪声工业时序中的建模能力受限;ARIMA 与 Persistence 的 RMSE 分别为 21.273 和 22.574, R^2 均低于 0.890,整体预测

表 7 不同方法预测评价结果
Table 7 Prediction evaluation results of different methods

模型	RMSE	R^2	MAPE (%)
Persistence	22.574	0.873	0.250
ARIMA	21.273	0.887	0.236
LSTM_diff	10.537	0.972	0.160
XGBoost	21.605	0.884	0.405
TCN	14.422	0.948	0.267
CLCM	8.485	0.982	0.097




图 12 不同方法预测性能对比

Fig. 12 Prediction performance comparison of different methods

精度最低, 反映线性模型难以刻画多槽电解系统中的复杂非线性动态。

综合对比可见, 传统统计模型在非线性与多槽弱相关特征建模方面存在明显不足; XGBoost 与 TCN 虽具备一定的非线性学习能力, 但在长程时间依赖与槽间空间特征的联合建模方面仍存在局限。相比之下, CLCM 能够在全局尺度上实现更准确的趋势拟合与误差控制, 体现出其在整体预测性能上的综合优势。

从指标含义角度分析, RMSE 与 MAPE 的同步降低表明该模型在绝对误差控制与相对波动响应方面均具有优势, 而较高的 R^2 则反映其对长期运行趋势的稳定拟合能力。上述结果说明, 所提出模型在多槽弱相关条件下仍能保持较高的整体预测精度, 具备良好的工程鲁棒性与应用潜力。

3.4.2 局部预测性能与统计显著性分析

为进一步评估模型在短时间尺度下对局部扰动的响应能力, 选取测试集中典型短窗区段 (区间 2 100 ~ 2 200), 对多种基线方法的预测结果进行对比分析 (图 13)。结果表明, CLCM 能够较好地跟踪真实序列中的高频局部波动, 并对短期扰动及峰谷变化作出快速响应。相比之下, LSTM_diff 在局部区段内出现明显的幅度收缩; ARIMA 呈现出典型的过度平滑特征; Persistence 模型存在较为显著的相位滞后; TCN 虽能部分刻画整体趋势, 但在局部高频波动区段仍表现出轻微的相位延迟与幅值偏移, 难以准确重构细粒度动态结构; XGBoost 的预测偏移最为明显, 局部波动形态基本无法还原。

上述结果表明, 所提出模型在短时间尺度内对高频扰动与局部异常变化具有更强的跟踪能力和更低的瞬时预测误差。对于铝电解槽运行过程而言, 此类局部波动通常对应负载调整、工况扰动或阳极电阻异常演化的早期阶段, 因此模型在该区段内的稳定预测能力对异常前兆识别具有重要意义。在此基础上, 为验证不同模型预测性能差异的统计显著性, 本文基于各模型在相同测试集上的预测误差序列, 引入 DM 统计检验对模型间性能进行对比分析 (表 8)。以 CLCM 为基准模型, 其与 LSTM_diff、ARIMA、Persistence、XGBoost 与 TCN 的 DM 统计量分别为 -11.928、-7.482、-7.919、-56.812 和 -59.111, 对应的 p 值均小于 0.001, 表明所提出模型在局部预测误差上相对于所有基线方法均具有极显著的统计优势。

结合局部预测曲线与 DM 检验结果可以看出, CLCM 在高频扰动与短时波动条件下所体现出的误差改进, 并非源于个别时间点的偶然拟合, 而是




图 13 不同模型在局部区间的预测结果对比

Fig. 13 Comparison of prediction results of different models in local intervals

表 8 各模型相对于 CLCM 的 DM 显著性检验结果
Table 8 DM significance test results of each model relative to CLCM

对比模型	t 值	p 值	显著性 ($p < 0.05$)
CLCM 与 LSTM_diff	-11.928	< 0.001	显著
CLCM 与 ARIMA	-7.482	< 0.001	显著
CLCM 与 Persistence	-7.919	< 0.001	显著
CLCM 与 XGBoost	-56.812	< 0.001	显著
CLCM 与 TCN	-59.111	< 0.001	显著

在整体预测误差层面具有良好的一致性与统计稳定性。

从工程应用角度看, 铝电解槽运行过程中阳极电阻的短时波动往往幅值较小但演化频繁, 对模型的时序响应能力提出了较高要求. 所提出模型在短时间尺度内能够有效抑制噪声放大, 并稳定捕捉细粒度动态变化, 为阳极电阻异常演化趋势的提前识别提供了更加可靠的局部预测依据, 对运行监测、异常预警及工艺调节决策具有实际应用价值。

4 结束语

本文提出了一种基于多通道输入的 CLCM 预测模型, 用于铝电解槽阳极效应发展趋势的建模与预测. 该方法通过多槽通道堆叠与 ConvLSTM 结构对时序与空间依赖关系进行联合建模, 并引入二维卷积分支与多头注意力机制, 分别强化槽间局部空间特征提取能力与关键时间信息的动态建模能力, 从而实现对阳极电阻微小波动与短期扰动的敏感捕捉。

基于真实工业生产数据的实验结果表明, 所提模型在全局预测精度与局部预测稳定性方面均优于多种对比方法. 在多槽弱相关、非平稳波动及局部峰谷变化等复杂运行条件下, 该模型仍能够保持较低预测误差和良好的趋势拟合能力, 验证了该模型在刻画铝电解过程非线性时空特征方面的有效性与鲁棒性。

上述研究结果表明, 该模型可为多槽运行状态评估与异常演化趋势识别提供可靠的前端预测支持, 具有与现有运行监测与预警系统相结合的应用潜力. 未来工作将进一步研究阳极电阻变化与阳极效应发生之间的直接关联建模机制, 并引入多源工艺参数与多尺度特征融合方法, 以提升模型对复杂工况的适应能力与工业应用价值。

参考文献

1 Gui Wei-Hua, Yue Wei-Chao, Xie Yong-Fang, Zhang Hong-Li-ang, Yang Chun-Hua. Review on intelligent optimization and manufacturing of aluminum electrolysis production. *Acta Auto-*

matica Sinica, 2018, **44**(11): 1957–1970
(桂卫华, 岳伟超, 谢永芳, 张红亮, 阳春华. 铝电解生产智能优化制造研究综述. *自动化学报*, 2018, **44**(11): 1957–1970)

2 Wang J, Xie Y F, Xie S W, Chen X F. Development of data-knowledge-driven predictive model and multi-objective optimization for intelligent optimal control of aluminum electrolysis process. *Engineering Applications of Artificial Intelligence*, 2024, **134**: Article No. 108664

3 Yin G, Li Y H, Yan F Y, Quan P C, Wang M, Cao W Q, et al. Deep learning for electrolysis process anode effect prediction based on long short-term memory network and stacked denoising autoencoder. *Rare Metals*, 2024, **43**(12): 6730–6741

4 Ye Tao, Zhu Xue-Feng, Li Xiang-Yang, Shi Bu-Hai. Soft sensor modeling based on improved k-nearest neighbor regression algorithm. *Acta Automatica Sinica*, 2007, **33**(9): 996–999
(叶涛, 朱学峰, 李向阳, 史步海. 基于改进 k-最近邻回归算法的软测量建模. *自动化学报*, 2007, **33**(9): 996–999)

5 Melo A, Camara M M, Pinto J C. Data-driven process monitoring and fault diagnosis: A comprehensive survey. *Processes*, 2024, **12**(2): Article No. 251

6 Li S J, Zhou B H, Shang J L, Chen X F, Yu J B. Review of recent applications and future perspectives on process monitoring approaches in industrial processes. *Journal of Manufacturing Systems*, 2025, **82**: 509–530

7 Zhang S, Zhang T, Yin Y X, Xiao W D. Alumina concentration detection based on the kernel extreme learning machine. *Sensors*, 2017, **17**(9): Article No. 2002

8 Xu C H, Tu Z C, Zhang W J, Cen J, Xiong J B, Wang N. A method of optimizing cell voltage based on STA-LSSVM model. *Mathematics*, 2022, **10**(24): Article No. 4710

9 Tang Jian, Guo Hai-Tao, Xia Heng, Wang Ding, Qiao Jun-Fei. Image generation and its application research for industrial process: A survey. *Acta Automatica Sinica*, 2024, **50**(2): 211–240
(汤健, 郭海涛, 夏恒, 王鼎, 乔俊飞. 面向工业过程的图像生成及其应用研究综述. *自动化学报*, 2024, **50**(2): 211–240)

10 Li Q S, Zhang Y, Long J H, Bai H, Hu R, Li W. Photovoltaic power prediction based on IMFO-LSTM model. *Journal of Electric Power Science and Technology*, 2024, **39**(3): 199–206

11 Xu J Y, Gong J Y, Li Y B, Fu Z, Wang L Y. Surf-riding and broaching prediction of ship sailing in regular waves by LSTM based on the data of ship motion and encounter wave. *Ocean Engineering*, 2024, **297**: Article No. 117010

12 Lughofer E, Pichler K. Data-driven prediction of possible quality deterioration in injection molding processes. *Applied Soft Computing*, 2024, **150**: Article No. 111029

13 Zhao L, Zhang X N, Peng X Y. Power fluctuation mitigation strategy for microgrids based on an LSTM-based power forecasting method. *Applied Soft Computing*, 2022, **127**: Article No. 109370

14 He Y L, Lv S H, Zhu Q X, Lu S. Novel multiattribute space-based LSTM for industrial soft sensor applications. *IEEE Transactions on Industrial Informatics*, 2024, **20**(3): 4745–4752

15 Tian H X, Chen J H. Deep learning with spatial attention-based ConvLSTM for SOC estimation of lithium-ion batteries. *Processes*, 2022, **10**(11): Article No. 2185

16 Zhang Shu, Xu Jian. Review on nonlinear dynamics in systems with coupling delays. *Chinese Journal of Theoretical and Applied Mechanics*, 2017, **49**(3): 565–587
(张舒, 徐鉴. 时滞耦合系统非线性动力学的研究进展. *力学学报*, 2017, **49**(3): 565–587)

17 Zhang Y D, Jie J, Liu L Q, Lan C M, Shi P. STP-cube-multivariate time series forecasting based on spatiotemporal correlations and periodicity. *Neural Processing Letters*, 2025, **57**(5): Article No. 80

- 18 Chen Z G, Lu M, Zhou Y M, Chen C Y. Information-synergy-entropy based multi-feature information fusion for the operating condition identification in aluminium electrolysis. *Information Sciences*, 2021, **548**: 275–294
- 19 Ilyushin Y V, Boronko E A. Analysis of energy sustainability and problems of technological process of primary aluminum production. *Energies*, 2025, **18**(9): Article No. 2194
- 20 Sun Y, Gui W H, Chen X F, Xie Y F. Evaluation model of aluminum electrolysis cell condition based on multi-source heterogeneous data fusion. *International Journal of Machine Learning and Cybernetics*, 2024, **15**(4): 1375–1396
- 21 da Silva M L J, Besancon G, Ferrante F, Fiacchini M, Roustan H. Convection-diffusion model for alumina concentration in Hall-Héroult process. *IFAC-PapersOnLine*, 2022, **55**(21): 150–155
- 22 Wan R Z, Mei S P, Wang J, Liu M, Yang F. Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting. *Electronics*, 2019, **8**(8): Article No. 876
- 23 Yuan Q, Wei Z Q, Guan X, Jiang M J, Wang S, Zhang S G, et al. Toxicity prediction method based on multi-channel convolutional neural network. *Molecules*, 2019, **24**(18): Article No. 3383
- 24 Rosato A, Araneo R, Andreotti A, Succetti F, Panella M. 2-D convolutional deep neural network for the multivariate prediction of photovoltaic time series. *Energies*, 2021, **14**(9): Article No. 2392
- 25 Qiu J, Zhang Z D, Zhu Z H, Luo C Q. Accurate state of charge estimation for lithium-ion batteries using a temporal convolutional network and bidirectional long short-term memory hybrid model. *Batteries*, 2026, **12**(2): Article No. 50
- 26 Ozcan A, Catal C, Kasif A. Energy load forecasting using a dual-stage attention-based recurrent neural network. *Sensors*, 2021, **21**(21): Article No. 7115
- 27 Sakib S, Mahadi M K, Abir S R, Moon A M, Shafullah A, Ali S, et al. Attention-based models for multivariate time series forecasting: Multi-step solar irradiation prediction. *Heliyon*, 2024, **10**(6): Article No. e27795
- 28 Li S Y, Jin X Y, Xuan Y, Zhou X Y, Chen W H, Wang Y X, et al. Enhancing the locality and breaking the memory bottleneck of Transformer on time series forecasting. In: Proceedings of the 29th Annual Conference on Neural Information Processing Systems. Vancouver, Canada: Advances in Neural Information Processing Systems, 2019. 5244–5254
- 29 Shi X J, Chen Z R, Wang H, Yeung D Y, Wong W K, Woo W C. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. In: Proceedings of the 29th Annual Conference on Neural Information Processing Systems. Montreal, Canada: Advances in Neural Information Processing Systems, 2015. 802–810
- 30 Cui G, Hu T, Zhang W, Bao H J. MMTransformer: A multivariate time-series resource forecasting model for multi-component applications. *Scientific Reports*, 2025, **15**: Article No. 29740



陈祖国 湖南科技大学信息与电气工程学院副教授。2018 年获得中南大学博士学位。主要研究方向为人工智能, 机器人控制技术和复杂工业过程智能决策。

E-mail: zg.chen@hnust.edu.cn

(**CHEN Zu-Guo** Associate professor at the College of Information and Electrical Engin-

earing, Hunan University of Science and Technology. He received his Ph.D. degree from Central South University in 2018. His research interests include artificial intelligence, robot control technology, and intelligent decision-making for complex industrial processes.)



刘 辉 湖南科技大学计算机科学与工程学院硕士研究生。2023 年获得广州城市理工学院学士学位。主要研究方向为工业数据处理。本文通信作者。E-mail: 24020502022@mail.hnust.edu.cn

(**LIU Hui** Master student at the College of Computer Science and Engineering, Hunan University of Science and Technology. He received his bachelor degree from Guangzhou University of Technology in 2023. His main research interest is industrial data processing. Corresponding author of this paper.)



黄 毅 湖南科技大学信息与电气工程学院副教授。2021 年获得中南大学博士学位。主要研究方向为复杂无人系统建模与协同控制, 海洋装备智能化技术, 有色金属冶炼过程优化策略研究。

E-mail: yi.huang@hnust.edu.cn

(**HUANG Yi** Associate professor at the College of Information and Electrical Engineering, Hunan University of Science and Technology. He received his Ph.D. degree from Central South University in 2021. His research interests include modeling and cooperative control of complex unmanned systems, intelligent marine equipment technology, and research on optimization strategies for non-ferrous metal smelting processes.)



陈超洋 湖南科技大学信息与电气工程学院教授。2021 年获得华中科技大学博士学位。主要研究方向为智能电网可靠性分析, 复杂网络理论及应用, 群机器人系统协同控制, 网络化系统性能分析, 非线性系统分析与控制。

E-mail: ouzk@163.com

(**CHEN Chao-Yang** Professor at the College of Information and Electrical Engineering, Hunan University of Science and Technology. He received his Ph.D. degree from Huazhong University of Science and Technology in 2021. His research interests include reliability analysis of smart grids, theory and applications of complex networks, cooperative control of multi-robot systems, performance analysis of networked systems, and analysis and control of nonlinear systems.)