

DOI: 10.19650/j.cnki.cjsi.J2413385

基于 PID 搜索优化的 CNN-LSTM-Attention 铝电解槽电解温度预测方法研究*

尹 刚^{1,2}, 朱 森^{1,2}, 全鹏程³, 颜玥涵⁴, 刘期烈⁵

(1. 重庆大学煤矿灾害动力学与控制全国重点实验室 重庆 400044; 2. 重庆大学资源与安全学院 重庆 400044;
3. 阿坝铝厂 阿坝 623001; 4. 贵州大学电气工程学院 贵阳 550025; 5. 重庆邮电大学 重庆 400065)

摘 要:铝电解生产环境恶劣,受电场、磁场、流场、温度场等多物理场耦合影响,导致铝电解生产过程故障频发。铝电解温度是影响铝电解槽寿命和运行状态的重要参数,但由于槽内温度很高且具有强烈腐蚀性,至今尚未找到有效的电解温度在线检测与预测方法。为了解决这一技术难题,通过理论分析结合现场实验验证,揭示了铝电解槽电解温度与其工艺参数间的密切相关性,并据此提出一种基于深度学习的铝电解槽电解温度预测模型。考虑到铝电解槽工艺参数的复杂性、非线性、高维度、时序性等特征,采用卷积神经网络(CNN)用于提取数据的高维特征,长短期记忆网络用于建模(LSTM),处理铝电解生产过程中的时序数据,引入了注意力机制(Attention),学习输入参数不同部分之间的关联性,同时根据输入数据的重要程度进行加权处理,并采用 PID 搜索优化算法(PSA)对 CNN-LSTM-Attention 模型的参数进行寻优,减少训练时间并提高模型的性能。最后经铝电解实际生产数据进行现场实验验证,结果表明:提出的温度预测模型相关指数(R^2)为 0.963 7,均方根误差(RMSE)和平均绝对误差(MAE)分别为 5.417 6 和 3.382 5,与单一模型算法、其他预测算法和不同优化算法对比验证表明,该模型的性能更佳,能够准确预测铝电解槽电解温度,实现了铝电解槽电解温度的在线检测。

关键词: 铝电解;算法;电解温度;深度学习;过程控制

中图分类号: TH181 **文献标识码:** A **国家标准学科分类代码:** 450.40

Research on CNN-LSTM-Attention aluminum electrolyzer electrolysis temperature prediction method based on PID search optimization

Yin Gang^{1,2}, Zhu Miao^{1,2}, Quan Pengcheng³, Yan Yuehan⁴, Liu Qilie⁵

(1. State Key Laboratory of Coal Mine Disaster Dynamics and Control, Chongqing University, Chongqing 400044, China;
2. College of Resource and Safety Engineering, Chongqing University, Chongqing 400044, China;
3. Aba Aluminium Factory, Aba 623001, China; 4. School of Electrical Engineering, Guizhou University, Guiyang 550025, China; 5. Chongqing Post and Communications University, Chongqing 400065, China)

Abstract: The aluminum electrolysis production environment is harsh, influenced by the coupling of multiple physical fields such as electric, magnetic, flow, and temperature fields, leading to frequent failures during the production process. The temperature of the aluminum electrolysis cell is a crucial parameter that affects the lifespan and operational status of the electrolysis tank. However, due to the high temperatures and corrosive nature of the tank, no effective online detection or prediction method for electrolysis temperature has been established so far. To address this issue, this study reveals the close correlation between the electrolysis temperature of aluminum electrolyzers and their process parameters through theoretical analysis and on-site experimental validation. Based on this, a deep learning-based model for predicting the electrolysis temperature is proposed. Considering the complexity, nonlinearity, high

收稿日期: 2024-10-17 Received Date: 2024-10-17

* 基金项目: 重庆市自然科学基金创新发展联合基金项目(CSTB2024NSCQ-LZX0166)、重庆英才·创新创业示范团队项目(cstc2024ycjh-bgzxm0131)、科技转化重大项目(H20201555)资助

dimensionality, and temporal sequence of the process parameters, Convolutional Neural Networks (CNN) are employed to extract high-dimensional features from the data, while Long Short-Term Memory (LSTM) networks are used for modeling. Additionally, the Attention mechanism is introduced to capture the relationships between different parts of the input parameters and to weigh the data according to its importance. A PID-based Search Algorithm (PSA) is applied to optimize the CNN-Attention model for the aluminum electrolysis process, reducing training time and improving model performance. Experimental results demonstrate that the proposed temperature prediction model achieves a correlation index (R^2) of 0.963 7, with a Root Mean Square Error (RMSE) of 5.417 6 and a Mean Absolute Error (MAE) of 3.382 5. A comparison with single-model algorithms, other prediction models, and different optimization techniques shows that the proposed model significantly outperforms them. The model successfully predicts the electrolysis temperature of the aluminum electrolyzer, enabling real-time, online detection of the electrolysis temperature during production.

Keywords: aluminum electrolysis; algorithm; electrolysis temperature; deep learning; process control

0 引 言

铝电解槽是铝电解生产的主体设备^[1],由于铝电解生产环境受电场、磁场、流场、温度场、应力场、浓度场相互耦合影响,导致铝电解槽在生产过程中故障频繁发生。铝电解槽常发生的故障如阳极效应、冷热槽、漏槽大多都与电解温度异常有关,因此电解温度是影响铝电解槽正常运行的一个重要参数,直接影响铝电解槽寿命以及工艺的稳定性 and 生产效率。铝电解槽的电解温度,是指电解质溶体(包括冰晶石、氧化铝和添加剂)的温度,正常工作的电解温度一般为940℃~970℃。铝电解是高温下的熔盐电解过程,电解质温度不但是维持电解质熔融状态的必要条件,也直接影响熔盐中存在的离子结构,还是影响电流效率的最重要因素。铝电解过程中,电解质温度越高,电流效率下降得越迅速,而铝电解质的温度每降低10℃,电流效率可提高1%~2%^[2]。铝电解槽的电流效率越高,其电解性能越佳,生产运行状况也越理想^[3-4]。电解质温度如此重要,因此准确掌握铝电解质的温度实时变化情况非常必要。

目前,我国大部分铝厂仍是人工采用普通测温仪测量电解质的温度,由于铝电解槽内温度高且具有强烈腐蚀性,采用传统的热电偶测温方法存在设备使用寿命短、不能长期在线测量、使用和维护成本高等问题,这使得铝电解槽温度的实时在线难以实现^[5]。软测量技术的基本思想是根据某种最优准则,利用已知历史数据,选择一组与主导变量有密切关系的辅助变量,通过在计算原理之间建立某种关系来连接主导变量和辅助变量^[6-7]。因此,通过软测量技术建立铝电解槽的工艺参数和电解温度之间的关系,实现铝电解槽内部温度的预测。

软测量技术的建模方法按照建模机制分为基于过程反应机理的机理建模和数据驱动建模,目前基于数据驱动的软测量方法得到了广泛研究和应用。已有文献关于铝电解槽电解温度的预测主要有支持向量机、单层神经网络等方法。高钢等^[8]基于径向基(radical basis function, RBF)神经网络模型预测铝电解槽电解温度,构

建的模型只选定了槽电压、 AlF_3 添加量和铝水平3个参数作为预测模型的输入,模型的准确性有待提升。徐嵩等^[9]选择铝电解槽的输入电流、电压和下料速度作为输入变量,建立BP(back propagation)神经网络的铝电解槽温度测量模型,同样该模型的输入参数太少,没有考虑其他参数对温度的影响。王宇等^[10]建立了基于最小二乘支持向量机(least squares support vector machine, LSSVM)的铝电解槽电解温度的软测量模型。阎纲等^[11]利用粒子群优化算法对LSSVM进行优化,建立铝电解温度的软测量模型。韩婷等^[12]提出了基于极限学习机的铝电解温度软测量模型。目前建立的铝电解温度预测模型的输入变量都较少,模型的泛化性和精度较低,也未曾考虑铝电解槽生产过程中的时序数据对电解温度的影响,且未与其他模型进行对比验证。

深度学习是人工神经网络的一个分支,它在处理大规模数据和深层特征信息时展现出更强大的数据解析能力,对基于数据驱动的软测量也具有高度适应性^[13-15]。铝电解槽的生产数据具有多样性、非线性、高维度的特征,且数据之间的关联性很强,卷积神经网络(convolutional neural networks, CNN)具有强大的特征提取能力和处理高维数据的能力。Nirmal等^[16]将CNN和自适应推进算法(adaptive boosting, Adaboost)用于智能电网窃电检测。Shekar等^[17]将CNN和循环神经网络(recurrent neural network, RNN)模型用于模拟流域降雨径流,其模拟效果相比其他几种模型更为出色。Bai等^[18]提出了一种基于遗传算法优化的CNN土壤液化的预测方法。Mansour等^[19]利用CNN基于历史数据对未来光伏发电功率进行预测。闫宇楠等^[20]提出了一种基于混合域注意力机制和CNN的自适应温度解耦质量感知方法。曹帅^[21]建立了基于灰狼优化算法的CNN刮板输送机减速器故障诊断模型。Wang等^[22]利用麻雀优化算法优化后的CNN建立煤自燃温度预测模型。

铝电解槽的工艺参数具有时序性,而长短期记忆网络(long short-term memory networks, LSTM)常用于处理和预测时间序列数据。Li等^[23]构建了一种改进的飞蛾

火焰优化算法对 LSTM 风能预测系统进行优化。Dong 等^[24]构建了一种基于 LSTM 的金融市场趋势预测模型。尹刚等^[25]将 LSTM 应用于铝电解的阳极效应预测,大幅缩减了效应响应时间。Xu 等^[26]将条件学习和 LSTM 结合,对船舶在规则波中航行的横摇和横甩运动进行预测。Ma 等^[27]构建了一种基于改进的经验模态分解和 LSTM 的超临界机组中间点温度短期预测模型。狄俊豪等^[28]提出利用混沌麻雀搜索算法优化 LSTM 的神经网络的动态称重算法。Che 等^[29]利用多策略改进的鲸鱼优化算法优化 LSTM 对高速机器测试数据的预测。

注意力机制 (attention mechanism, Attention) 是一种提升深度学习网络性能的有效手段。在 CNN-LSTM 模型中引入 Attention, 可以提高模型的特征表示能力、捕捉长距离依赖关系的能力和长序列的能力。Zhang 等^[30]利用具有麻雀优化算法和注意力机制的居住者行为模型来进行建筑能耗预测。赵云亮等^[31]提出了一种基于深度可分离卷积融合池化网格窗口注意力机制的金属表面缺陷识别网络架构。罗强等^[32]构建注意力残差卷积自编码器,通过提取轴承振动信号的特征对轴承故障进行诊断。Wang 等^[33]提出了一种基于时间序列和分层多传感头自注意力的化工过程故障诊断方法。Hao 等^[34]提出一种基于对称双向的 LSTM-Attention 大气温度预测模型,有效提高了温度数据的预测精度。朱希等^[35]提出一种自注意力多尺度融合模型,对密集物料进行分类检测。

为了解决铝电解槽电解温度在线检测难以实现这一问题,通过理论分析和现场实验验证,得出铝电解槽电解温度与其工艺参数密切相关。基于深度学习的方法可以从海量运行数据中挖掘出铝电解槽电解温度的特征信息。鉴于铝电解槽生产数据的时序性、多样性、复杂性、强关联性和高维度特征,本文构建了一种基于 PID 搜索优化算法 (PID-based search algorithm, PSA) 的 CNN-LSTM-Attention 铝电解槽电解温度预测模型,利用 CNN 提取输入参数的高维特征,LSTM 处理输入铝电解生产数据的时间依赖关系,通过引入 Attention,进一步加强模型对不同时间步特征的关注度,使得模型能够更好地理解序列数据的特征,并采用 PSA 对 CNN-LSTM-Attention 模型的参数进行优化,提高建模效果和预测性能。该方法能够在线检测铝电解槽电解温度的变化,在发现设备故障或操作异常时及时调整工艺参数,提高生产过程的稳定性和产品质量,同时为铝电解智能化安全管理提供参考。

1 方法理论

1.1 卷积神经网络 (CNN)

CNN 是一类包含卷积计算且具有深度结构的前馈神经网络,是深度学习的代表算法之一^[36],其基本结构

由输入层、卷积层、池化层和全连接层组成。CNN 具有表征学习能力,能够按其阶层结构对输入信息进行平移不变分类。CNN 的核心思想是通过权重分享和局部连接的方式对输入序列进行特征提取,从而实现对数据的有效分类和识别,CNN 的基本结构如图 1 所示。




图 1 CNN 网络结构

Fig. 1 Network architecture diagram of CNN

卷积层通常包含多个可学习的卷积核,每个核对输入序列数据执行卷积操作,以获得一组新的特征序列^[37],如式(1)所示。

$$y^l = f(w^l \cdot x^{l-1} + b^l) \quad (1)$$

其中, x^{l-1} 是第 $l-1$ 层的输入,也是第 l 层的输出, w^l 是第 l 层的卷积核集合, b^l 是第 l 层的偏置向量, y^l 是第 l 层的输出, $f(\cdot)$ 是一个非线性激活函数。本模型中采用 ReLU 函数,ReLU 将负数部分都变成了 0,而保留了正数部分,如式(2)所示。

$$f_{\text{ReLU}}(x) = \max(0, x) \quad (2)$$

池化层可以有效减小特征图的空间大小,提取主要特征,从而降低模型复杂度,缓解过拟合。池化操作通常是选取输入特征图中每个小区域的统计值作为汇总特征,CNN 的池化层如式(3)所示。

$$y_k = \text{pooling}(x_{k:k+j-1}) \quad (3)$$

其中, x_k 表示输入的池化序列数据, y_k 表示池化层的输出, j 是池化窗口大小, k 是池化窗口的起始位置, $x_{k:k+j-1}$ 表示输入序列 x 中从位置 k 到位置 $k+j-1$ 的子序列。本研究采用最大池化运算,最大池化操作会从这个子序列中选取最大值作为输出 y_k 。全连接层接收来自先前卷积层和池化层的交替输出结果,对特征进行积分和提取,将它们重新排列成特征向量,并将它们传输到输出层,如式(4)所示。

$$y^r = f(w^r \cdot y^{r-1} + b^r) \quad (4)$$

其中, y^{r-1} 和 y^r 分别是 $r-1$ 和 r 的输出, $f(\cdot)$ 是激活函数, w^r 是权重矩阵, b^r 是第 r 层的偏置向量。

1.2 长短期记忆网络 (LSTM)

LSTM 是 RNN 的变体,可以处理长序列数据以及反向传播中的梯度消失和梯度爆炸问题,具有长期记忆的能力。相比传统的 RNN,LSTM 中引入了门控单元、遗忘门、

输入门和输出门,有效控制信息的流动,可以有效解决梯度消失或爆炸的问题。LSTM 中的每个单元都包含这 3 个门和 1 个记忆单元,遗忘门负责删减当前内容,输入门负责筛选候选记忆单元,输出门控制当前时刻的输出信息,每个 LSTM 单元共享参数,通过不断的循环实现对对应参数的学习^[38]。LSTM 的内部结构如图 2 所示。




图 2 LSTM 内部结构

Fig. 2 Internal structure diagram of LSTM

首先,输入门决定要更新候选记忆单元当前时刻的信息:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (5)$$

其中, \$f_t\$ 是遗忘门的输出, \$\sigma\$ 是 sigmoid 激活函数, \$W_f\$ 是遗忘门的权重矩阵, \$h_{t-1}\$ 是上一时刻的隐藏状态, \$x_t\$ 是当前时刻的输入, \$b_f\$ 是遗忘门的偏置。将 \$h_{t-1}\$ 和 \$x_t\$ 输入 \$\sigma\$ 函数中,输出介于 0~1 之间,0 表示完全丢弃该内容,1 表示保留。

输入门决定要更新候选记忆单元的哪些部分。

$$i_t = \sigma(i_f \cdot [h_{t-1}, x_t] + b_i) \quad (6)$$

其中, \$i_t\$ 是输入门的输出,控制着候选记忆单元的删减或保留, \$i_f\$ 是输入门的权重矩阵, \$b_i\$ 是输入门的偏置,其次更新候选记忆单元的状态:

$$g_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (7)$$

其中, \$W_c\$ 是候选记忆单元的权重矩阵, \$g_t\$ 是候选记忆单元, \$b_c\$ 是候选记忆单元的偏置。

然后决定输出候选记忆单元的哪一部分,最后利用遗忘门、输入门和候选细胞状态来更新候选记忆单元状态:

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (8)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot g_t \quad (9)$$

其中, \$O_t\$ 是输出门的输出, \$W_o\$ 是输出门的权重矩阵, \$C_t\$ 是当前时刻的记忆单元状态, \$C_{t-1}\$ 是上一时刻的记忆单元状态, \$b_o\$ 是输出门的偏置。

1.3 注意力机制(Attention)

Attention 是嵌入在神经网络模型中的一种结构,启发于人脑中注意力集中于特定情况的关注,通过获取特定情况信息,而忽略其他不重要信息^[39]。添加注意力机制,可以帮助模型学习到全局信息和局部信息之间的关

联,提高模型对整体信息的提取和理解能力,同时使模型集中注意力于与当前预测最相关的部分,提高模型的精度和泛化能力。注意力机制的实现包括 3 个步骤:计算注意力权重、归一化权重以及加权求和,其结构如图 3 所示。




图 3 Attention 网络结构

Fig. 3 Attention network structure diagram

首先计算注意力的权重,采用加性的方法可表示为:

$$S(q, x_i) = v^T \tanh(W_q q + W_x x_i + b) \quad (10)$$

其中, \$W_q\$ 和 \$W_x\$ 是学习的权重矩阵, \$v\$ 是另一个学习的权重向量, \$b\$ 是偏置向量, \$q\$ 是查询向量, \$x_i\$ 是输入数据, \$S(q, x_i)\$ 是注意力的得分函数。

其次归一化权重,即将权重归一化到 [0, 1] 范围内。

$$a_i = \frac{\exp(e_i)}{\sum_{i=1}^n \exp(e_i)} \quad (11)$$

其中, \$e_i\$ 表示相似度值, \$a_i\$ 表示第 \$i\$ 个输入向量的注意力权重。

最后将每个输入向量按照注意力权重加权求和:

$$Attention(x_i, q) = \sum_{i=1}^n a_i x_i \quad (12)$$

其中, \$Attention(x_i, q)\$ 就是根据查询向量 \$q\$ 对输入序列数据 \$x_i\$ 进行注意力加权求和后得到的表示。

1.4 PID 搜索优化算法(PSA)

PSA 是由一种新型的元启发式算法,灵感来源于增量 PID 算法,该算法通过连续调整系统偏差将整个种群收敛到最优状态^[40]。增量 PID 控制是一种比例积分微分控制,它使当前时刻的控制量与前一时刻的控制量差,差就是新的控制量,当设定目标值后,增量 PID 控制器将输出值提供给执行器,执行器根据输出值调节受控对象,调节后受控对象的实际值由传感器获取,并再次传递给增量 PID 控制器。

首先将种群初始化,优化问题由一组决策变量、约束条件和目标函数组成。可以假设该组中的决策变量的数量为 \$d\$,并且变量的上界和下界分别为 \$u\$ 和 \$v\$。PSA 的控制参数包括最大迭代次数 \$T\$ 和种群大小 \$N\$。然后初始种群可以表示为:

$$Xmi = (u_i - v_i) \cdot r_1 + v_i \tag{13}$$

其中, Xmi 表示第 m 个个体的第 i 个维度; u_i 和 v_i 分别是第 i 个变量(维度)的上界和下界; r_1 是从 0 到 1 的随机数。

其次计算系统偏差。对于最小化问题, 迭代次数 T 处的最佳个体 $X_{best}(T)$ 是对应于总体历史最小值的个体。多次迭代 T 的总体偏差 $e_k(T)$ 为:

$$e_k(T) = X_{best}(T - 1) - X(T - 1) \tag{14}$$

最后还要进行 PID 调节。在现实问题中, 比例、积分和微分因子会根据不同的情况和问题进行调整。则当迭代次数为 T 时, PID 调节的输出值 $\Delta u(T)$ 为:

$$\Delta u(T) = K_p \cdot r_2 \cdot [e_k(T) - e_{k-1}(T)] + K_i \cdot r_3 \cdot e_k(T) + K_d \cdot r_4 \cdot [e_k(T) - 2e_{k-1}(T) + e_{k-2}(T)] \tag{15}$$

其中, r_2 、 r_3 和 r_4 是从 0 到 1 的随机数的矢量, K_p 、 K_i 和 K_d 分别是比例、积分和微分的调整系数。

PSA 算法在优化 CNN-LSTM-Attention 模型的参数时, 依赖于反馈机制, 通过调节当前超参数值(学习率、正则化参数), 逐步逼近最优值。

2 铝电解槽电解温度预测模型框架

2.1 输入变量选择

铝电解温度是影响铝电解槽寿命、运行状态、生产效率以及铝产品质量的关键参数, 因此实现铝电解温度的在线检测与预测十分重要。铝电解槽内的工艺参数众多, 具有非线性、多样性、时序性、高维度等特征且参数之间关联性很强, 因此需要从铝电解槽的海量工艺参数中筛选出与电解温度有关的特征参数, 然后构建模型建立铝电解槽的工艺参数和电解温度之间的关系, 实现铝电解温度的预测。

根据铝电解工艺机理分析以及现场的实验结果, 得出在铝电解生产过程中, 影响电解温度的因素较多: 铝电解槽中氟化盐的添加量会导致电解温度降低; 槽电压和槽电流的大小直接影响铝电解槽中的热量, 引起电解温度的大小变化; 氧化铝的下料次数直接影响着铝电解槽内部的热平衡状态, 从而引起电解温度的变化; 出铝时带走铝液中的热量, 会使电解温度降低; 铝电解槽中铁的含量会影响阳极的导电性和耐高温性能, 从而影响槽内的整体温度; 电解质水平的变化会影响电解槽中的热量传递和散热过程; 分子比的变化会影响电解质的熔点、粘度和导电性等, 从而影响电解温度; 硅可以形成氧化硅膜层, 对稳定电解质有一定作用, 同时降低电解质的电导率, 进而影响铝电解槽内的温度; 槽龄的增加会影响电解液的流动方式和热传导性能, 进而影响电解温度。

根据上述分析讨论, 最终确定平均电压、铝水平、电解质水平、氟化盐添加量、氧化铝下料次数、分子比、出铝量、

铁含量、硅含量、槽电流、槽电压、槽龄这 12 个参数与铝电解质温度有较强的关联性, 因此选取这 12 个参数为模型的输入变量(如表 1 所示), 电解温度为输出, 以此构造 PSA-CNN-LSTM-Attention 铝电解槽电解温度的预测模型。

表 1 模型输入参数
Table 1 Input parameters of proposed model

序号	参数	描述
1	平均电压	单日平均电压
2	铝水平	铝电解槽中铝水高度
3	电解质水平	铝电解槽中电解质高度
4	氟化盐添加量	平均一天氟化盐添加的数量
5	氧化铝下料次数	平均一天氧化铝下料次数
6	分子比	电解质里氯化钠与氟化铝的比值
7	出铝量	平均一天槽中生产出的铝的数量
8	Fe 含量	铝水中 Fe 含量占比
9	Si 含量	铝水中 Si 含量占比
10	槽电流	铝电解槽电解电流
11	槽电压	铝电解槽阴极和阳极之间的电压
12	槽龄	铝电解槽的运行天数

2.2 模型框架

在构建基于 PSA-CNN-LSTM-Attention 的铝电解槽电解温度预测模型之前, 对采集到的铝电解槽日运行数据进行缺失值和归一化处理。首先输入 12 个参数, 进入 CNN 层提取输入参数的特征, 其中卷积层提取数据的局部和高维特征, 卷积核和池化层捕获关键特征并降低计算复杂度。其次将 CNN 提取的特征传递到 LSTM 层, 捕获输入数据中的时间依赖性和序列信息, 然后 Attention 机制将 LSTM 的输出进行加权, 通过概率分配权重, 更好地捕捉输入序列中不同部分的重要性, 进一步提高预测模型的准确性, 最后将 Attention 机制的输出通过全连接层映射到最终的目标值, 即输出电解温度。同时利用 PSA 对 CNN-LSTM-Attention 模型中的超参数进行寻优, 如学习率、正则化参数, 减少调参工作量和训练时间, 提升整个训练流程的效率。最终构建的模型结构如图 4 所示, PSA 优化模型的流程图如图 5 所示。




图 4 CNN-LSTM-Attention 结构
Fig. 4 CNN-LSTM-Attention structure diagram




图5 PSA 优化 CNN-LSTM-Attention 模型参数流程

Fig. 5 Flowchart of PSA optimization process for CNN-LSTM-Attention model parameters

CNN-LSTM-Attention 算法流程细节如算法 1 所示。

算法 1: CNN-LSTM-Attention 算法

输入

```
[data, labels] = loadData;
```

```
data = normalize(data);
```

CNN 层

```
imageInputLayer([inputSize(1), inputSize(2), 1], 'Name', 'input')
```

```
convolution2dLayer(3, 64, 'Padding', 'same', 'Name', 'conv1')
```

```
reluLayer('Name', 'relu1')
```

```
maxPooling2dLayer(2, 'Stride', 2, 'Name', 'maxpool1')
```

```
convolution2dLayer(3, 128, 'Padding', 'same', 'Name', 'conv2')
```

```
reluLayer('Name', 'relu2')
```

```
maxPooling2dLayer(2, 'Stride', 2, 'Name', 'maxpool2')
```

```
flattenLayer('Name', 'flatten')
```

LSTM 层

```
lstmLayer(64, 'OutputMode', 'sequence', 'Name', 'lstm')
```

Attention 层

```
fullyConnectedLayer(1, 'Name', 'attention_fc')
```

```
softmaxLayer('Name', 'attention_softmax')
```

```
weightedSumLayer('Name', 'attention_weighted')
```

输出

```
fullyConnectedLayer(1, 'Name', 'output_fc')
```

```
regressionLayer('Name', 'output')
```

2.3 模型评价指标

铝电解槽电解温度的预测属于回归任务,对于回归任务,通常选取相关指数(R^2)、均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE)作为模型性能评价指标。

R^2 用于衡量模型对观测数据的拟合程度。其取值范围从 0 到 1,越接近 1 表示模型对数据的拟合越好。式(16)~(18)中, n 为样本个数, y_i 为真实值, $\hat{y}_i$ 为预测值。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

RMSE 是模型预测值与实际值之差的平方之和与样本个数 n 比值的平方根,用于衡量预测值与真实值之间的差异程度。RMSE 的取值范围是 0 到正无穷大,数值越小表示模型预测的效果越好。

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

MAE 是模型预测值与真实观测值之差的绝对值求均值。MAE 的取值范围是 0 到正无穷大,数值小说明模型的预测准确性越高。MAE 不考虑预测值的正负,更加关注绝对误差的大小,可以直观地看出模型预测值与真实值之间的差距大小。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

3 实验验证与讨论

3.1 数据采集与预处理

通过对铝电解工艺和现场实验结果进行分析,确定了与铝电解槽电解温度相关的工艺参数。本文采集某铝厂 400 kA 系列铝电解槽 47 天的运行数据,共采集了 10763 个样本,数据样本包括平均电压(x_1)、铝水平(x_2)、电解质水平(x_3)、氟化盐添加量(x_4)、氧化铝下料次数(x_5)、分子比(x_6)、出铝量(x_7)、铁含量(x_8)、硅含量(x_9)、槽电流(x_{10})、槽电压(x_{11})、槽龄(x_{12}) 12 个输入参数,以及电解温度 1 个输出。所有样本均匀分布,将样本按照 8:2 随机划分为两部分,以减少选择偏差,确保样本的代表性。其中 80% 作为训练集,剩余 20% 作为测试集,具体实验设置如表 2 所示。

对采集到的所有样本数据进行缺失值和归一化处理。首先对所采集的数据中存在的缺失值进行处理。缺失值处理有两种方法:删除含有缺失值的特征参数或样本数据对缺失值进行填充。直接删除含有缺失值的样本数据会减少样本容量,因此采用填充的方法对缺失数

表 2 实验采集的数据信息

Table 2 Information of experimental collected data	
参数	数值
数据产生时间	2023 年 2 月 1 日至 3 月 19 日
电解槽数量/台	38
特征数量/种	12
实验数据样本数/个	10 763
训练集/测试集占比	8:2

据进行处理。针对铝电解生产过程中的数据特点和采集方法,并根据现场经验,采用均值填充法对数据集进行处理。

铝电解槽不同特征参数具有不同的量纲,使用未经处理的数据直接进行铝电解槽电解温度预测会削弱数据分析效果,影响最终预测结果。对铝电解槽的生产数据归一化处理,是将每个特征参数的量纲转化到同一范围,旨在消除不同量纲带来的影响,提高模型预测的准确性。因此,采用 Min-Max 方法将数据缩放到 $[0,1]$ 之间,实现数据的归一化处理。

通过缺失值和归一化处理,使得数据中的特征信息不丢失,保证数据完整且消除不同量纲带来的影响,从而提高预测模型的准确性,提升计算速度。

3.2 模型参数设置

选择 PSA-CNN-LSTM-Attention 模型参数时,主要针对 CNN 的卷积层、LSTM 的隐藏层进行参数设置。CNN 可以包含多个卷积层,每个卷积层可以有不同的卷积核大小和数量,LSTM 层中可以包含不同的隐藏单元数。为获取更有效的模型参数,本文测试了不同卷积层个数、不同卷积核大小以及不同 LSTM 层隐藏单元个数的 CNN-LSTM-Attention 模型的预测性能。不同卷积层个数下的多次实验平均 R^2 如图 6 所示,不同卷积核大小下的多次实验平均 R^2 如图 7 所示,不同 LSTM 层隐藏单元个数的多次实验平均 R^2 如图 8 所示。可以得出,当卷积层个数为 32,卷积核大小为 5×5 ,LSTM 层隐藏单元个数为 200 时,CNN-LSTM-Attention 模型达到最佳性能。回归预测模型的池化窗口大小通常为 2×2 ,移动步长通常为 2,经 PSA 优化后模型的最优初始学习率为 0.001,学习率调整因子为 0.1,正则化参数为 0.01,训练 1 000 次后开始调整学习率,最大迭代次数设置为 18 000,最终模型的参数设置如表 3 所示。

3.3 模型性能验证

本文共采集了 10 763 个样本,所有样本均匀分布,按 8:2 随机将其划分为训练集和测试集,其中 80% 作为训练集,用于模型的训练,剩余 20% 作为测试集,用于评估模型的性能。最终预测结果如图 9 所示,评价结果如表 4 所示。




图 6 卷积层个数与评价指标 R^2 的关系
Fig. 6 Relationship between the number of convolutional layers and the evaluation metric R^2




图 7 卷积核大小与评价指标 R^2 的关系
Fig. 7 Relationship between kernel size and evaluation metric R^2




图 8 LSTM 层隐藏单元个数与评价指标 R^2 的关系
Fig. 8 Relationship between the number of hidden units in the LSTM layer and the evaluation metric R^2

表 3 PSA-CNN-LSTM-Attention 模型参数设置
Table 3 Parameters of PSA-CNN-LSTM-Attention model

参数	值
卷积层	32
卷积核大小	5×5
移动步长	2
池化窗口大小	2×2
LSTM 层隐藏单元数	200
正则化参数	0.01
初始学习率	0.001
学习率调整因子	0.1
梯度阈值	1
最大迭代次数	18 000




图 9 PSA-CNN-LSTM-Attention 模型预测结果
Fig. 9 Prediction results of the PSA-CNN-LSTM-Attention model

表 4 PSA-CNN-LSTM-Attention 模型性能评价结果
Table 4 Performance evaluation results of the PSA-CNN-LSTM-Attention model

评价指标	值
MAE	3.862 5
RMSE	5.417 6
R^2	0.963 7

3.4 融合模型与单一模型的对比分析

为了验证 PSA-CNN-LSTM-Attention 模型的性能,在相同的数据集下分别建立 CNN、LSTM、CNN-LSTM、CNN-LSTM-Attention 模型来对比验证所构建模型的性能,将 R^2 、RMSE 以及 MAE 作为评估指标,单一模型与融合模型性能的对比如图 10 所示,各模型对电解温度的预测误差如图 11 所示,对比评价结果如表 5 所示。实验结果表明,本文构建的 PSA-CNN-LSTM-Attention 融合模型的 R^2

为 0.963 7,相比 CNN、LSTM、CNN-LSTM、CNN-LSTM-Attention 模型的 R^2 提高了 12.31%、30.11%、16.6%、1.74%。RMSE、MAE 分别为 5.417 6 和 3.862 5,相比 3 个单一模型和未经优化的 CNN-LSTM-Attention 模型 RMSE 分别降低了 45.01%、50.37%、28.17%、18.45%,MAE 分别降低了 48.67%、53.25%、38.95%、29.18%,PSA-CNN-LSTM-Attention 模型融合了单一模型的优势,更能准确预测铝电解槽电解温度。




图 10 单一模型与融合模型性能对比
Fig. 10 Performance comparison of single and fused models




图 11 单一模型与融合模型对电解温度预测误差
Fig. 11 Prediction error of electrolysis temperature by single and fused models

表 5 多模型评价结果
Table 5 Model performance evaluation results

算法模型	MAE	RMSE	R^2
CNN	7.525 3	9.852 7	0.858 1
LSTM	8.262 6	10.917 1	0.740 7
CNN-LSTM	6.327 2	7.542 3	0.826 5
CNN-LSTM-Attention	5.454 5	6.643 6	0.946 9
PSA-CNN-LSTM-Attention	3.862 5	5.417 6	0.963 7

3.5 不同预测方法的对比分析

常用的数据驱动软测量方法有 BP 神经网络、支持向量机(support vector machine, SVM)和 RBF 神经网络等等,因此在相同的数据集下单独建立 BP、SVM 和 RBF 模型来验证所构建模型的性能。采用测试集的 R^2 、RMSE、MAE 作为评估指标对 3 个模型进行对比验证。

在设置 BP、SVM 和 RBF 模型的参数时,采用 5 折交叉验证调整模型的超参数。将整个数据集随机划分为 5 个子集,在每次交叉验证中,选择其中 4 个子集作为训练集,剩余 1 个子集作为验证集,模型在每轮训练后会在验证集上进行评估。通过计算每组超参数在 5 折交叉验证中的平均评估结果,选择具有最佳性能的超参数组合。经过不断的调试以及交叉验证,得出 BP、SVM 和 RBF 模型的最优参数。BP 模型通常采用 Sigmoid 传递函数, SVM 模型中 RBF 核函数适合处理高维数据。

BP、SVM 和 RBF 模型的最终参数设置分别如表 6~8 所示,BP、SVM 和 RBF 与 PSA-CNN-LSTM-Attention 模型的预测对比结果如图 12 所示,各模型对电解温度的预测误差如图 13 所示,模型性能对比结果如表 9 所示, PSA-CNN-LSTM-Attention 模型的 R^2 比 BP、SVM、RBF 模型提高了 56.13%、31.33%、47.51%, RMSE 降低了 49.86%、57.76%、47.45%, MAE 降低了 52.82%、58.96%、50.27%。PSA-CNN-LSTM-Attention 模型相较于传统预测模型具有提取复杂的高维特征和处理处理时间序列数据的能力,因此 PSA-CNN-LSTM-Attention 模型在预测铝电解槽电解温度方面的能力更佳。

表 6 BP 模型参数设置
Table 6 Parameters of BP model

参数	值
输入层节点数	12
输出层节点数	1
隐含层层数	1
隐含层节点数	8
传递函数	Sigmoid
学习率	0.1
最大训练次数	1 000

表 7 SVM 模型参数设置
Table 7 Parameters of SVM model

参数	值
惩罚因子	4
核函数	RBF
核函数参数	0.8
学习率	0.1
最大训练次数	1 000

表 8 RBF 模型参数设置
Table 8 Parameters of RBF model

参数	值
RBF 函数的扩展速度	100
中心数目	10
宽度参数	0.5
学习率	0.1
最大训练次数	1 000




图 12 不同预测方法性能对比
Fig. 12 Performance comparison of different prediction methods




图 13 不同预测方法对电解温度预测误差
Fig. 13 Prediction error of electrolysis temperature by different prediction methods

表 9 不同预测方法评价结果
Table 9 Evaluation results of different prediction methods

算法模型	MAE	RMSE	R^2
BP	8.187 5	10.805 4	0.422 7
SVM	9.411 0	12.825 1	0.661 8
RBF	7.767 7	10.308 5	0.505 8
PSA-CNN-LSTM-Attention	3.862 5	5.417 6	0.963 7

3.6 不同优化算法的对比分析

为了验证 PSA 算法的优化性能,采用常见的麻雀搜索法 (sparrow search algorithm, SSA)、鲸鱼优化算法 (whale optimization algorithm, WOA) 和粒子群优化算法 (particle swarm optimization, PSO) 做对比实验,预测对比结果如图 14 所示,各优化算法对电解温度的预测误差如图 15 所示,各模型性能对比结果如表 10 所示。相较于 SSA-CNN-LSTM-Attention、WOA-CNN-LSTM-Attention 和 PSO-CNN-LSTM-Attention 模型,PSA-CNN-LSTM-Attention 模型的 R^2 分别提高了 1.10%、1.38%、1.65%,MAE 分别降低了 4.36%、14.68%、26.42%,RMSE 分别降低了 9.27%、20.62%、25.42%。PSA 算法不仅提升了模型的预测能力,还减少了模型训练时间和工作量,因此该方法更适用于铝电解槽电解温度预测模型的优化。




图 14 不同优化模型性能对比

Fig. 14 Performance comparison of different optimization models




图 15 不同优化模型对电解温度预测误差

Fig. 15 Prediction error of electrolysis temperature by different optimization models

表 10 不同优化模型评价结果

Table 10 Evaluation results of different optimization models

算法模型	MAE	RMSE	R^2
SSA-CNN-LSTM-Attention	4.038 6	5.971 4	0.953 2
WOA-CNN-LSTM-Attention	4.526 9	6.825 1	0.950 6
PSO-CNN-LSTM-Attention	5.249 1	7.264 5	0.948 1
PSA-CNN-LSTM-Attention	3.862 5	5.417 6	0.963 7

3.7 PSA-CNN-LSTM-Attention 模型的性能分析

PID 搜索优化算法的控制器可以根据误差自动调整超参数,并通过反馈机制,快速找到最优参数。虽然引入 PSA 优化算法增加了每次迭代的计算复杂性,但通过快速收敛,缩短了模型的整体训练时间。经实验验证得到:在较少的迭代次数内,模型的 R^2 达到较高的值,并在后续训练中保持稳定,说明模型收敛迅速。CNN、LSTM、CNN-LSTM 和未经优化的 CNN-LSTM-Attention 模型与 PSA-CNN-LSTM-Attention 模型的 R^2 指标曲线如图 16 所示。




图 16 单一模型与融合模型的指标曲线

Fig. 16 Indicator curves for single versus fusion models

4 结 论

本文针对铝电解槽电解温度难以在线检测的问题,通过铝电解工艺理论分析结合现场实验验证,得出铝电解槽电解温度与其工艺参数间存在密切相关性,在此基础上提出了一种基于 PID 搜索优化算法的 CNN-LSTM-Attention 铝电解槽电解温度预测模型,从铝电解槽历史运行工艺参数中挖掘出电解温度特征信息,实现了铝电解温度的预测,解决了铝电解生产过程中电解温度在线测量难以实现的技术难题,结论如下:

1) 根据铝电解工艺机理分析和现场的实验结果,对影响铝电解槽电解温度的因素进行了分析研究,并结合现场专家意见,最终选定槽电压、铝水平、电解质水平、氯化盐添加量、氧化铝的下料次数、分子比、出铝量、槽电流、槽龄、平均电压、铁含量、硅含量作为模型的输入特征参数。

2) 针对铝电解生产数据的复杂性、非线性、高维度、时序性等特点,提出了基于的 PID 搜索优化的 CNN-LSTM-Attention 铝电解温度预测方法,采用 CNN 提取输入数据的高维特征,输入 LSTM 中充分学习数据的时序特征,利用 Attention 对 LSTM 输出进行加权处理,并通过 PSA 优化算法对 CNN-LSTM-Attention 模型的参数进行优化,减少调参工作量的同时使模型性能达到最佳。

3) 构建了基于 PSA-CNN-LSTM-Attention 的铝电解槽电解温度预测模型,并利用铝电解企业的实际生产数据进行了对比实验验证,其结果为:模型的 R^2 达到 0.963 7, RMSE 和 MAE 分别达到 5.417 6 和 3.382 5,与单一模型 CNN、LSTM、CNN-LSTM 和未经优化的 CNN-LSTM-Attention 模型相比 R^2 提高了 12.31%、30.11%、16.6%、1.74%, RMSE 降低了 45.01%、50.37%、28.17%、18.45%, MAE 降低了 48.67%、53.25%、38.95%、29.18%;与其他预测模型 BP、SVM、RBF 相比 R^2 提高了 56.13%、31.33%、47.51%, RMSE 降低了 49.86%、57.76%、47.45%, MAE 降低了 52.82%、58.96%、50.27%;与其他优化模型 SSA-CNN-LSTM-Attention、WOA-CNN-LSTM-Attention 和 PSO-CNN-LSTM-Attention 相比, R^2 提高了 1.10%、1.38%、1.65%, RMSE 降低了 9.27%、20.62%、25.42%, MAE 降低了 4.36%、14.68%、26.42%, PSA-CNN-LSTM-Attention 模型更具有精确预测铝电解槽电解温度的能力。

4) 由于铝电解槽电解温度的变化是一个连续而缓慢的过程,且构建的 PSA-CNN-LSTM-Attention 模型运行时间较短,满足铝电解槽在运行时温度采集的速率,实现了铝电解槽电解温度的在线检测与预测,避免了铝电解生产中故障的频繁发生,提高生产的安全性和效率,提升铝产品的质量,延长了铝电解槽寿命,对于铝电解安全高效可持续生产具有现实意义。

参考文献

[1] 尹刚, 李伊惠, 何飞, 等. 基于 KPCA 和 SVM 的铝电解槽漏槽事故预警方法[J]. 化工学报, 2023, 74(8): 3419-3428, 3615.

YIN G, LI Y H, HE F, et al. An early warning method for aluminum electrolyzer leakage based on KPCA and

SVM[J]. CIESC Journal, 2023, 74(8): 3419-3428, 3615.

[2] 池清泉. 浅谈铝电解槽三度管理实践: 全国铝电解槽生产技术与操作技术学术报告和 经验交流会论文集[C]. 郑州: 中国铝业河南分公司电解厂, 2007.

CHI Q Q. Aluminum electrolyzer three degree management practice: Proceedings of the national conference on aluminum electrolyzer production technology and operation technology[C]. Zhengzhou: Electrolysis Plant, Aluminium Corporation of China, Henan Branch, Zhengzhou, China, 2007.

[3] 尹刚, 钱中友, 曹文琦, 等. 基于 Adaboost-PSO-SVM 的铝电解槽健康状态诊断方法研究[J]. 化工学报, 2024, 75(1): 354-365.

YIN G, QIAN ZH Y, CAO W Q, et al. Health state diagnosis of aluminum electrolytic cells based on Adaboost-PSO-SVM[J]. CIESC Journal, 2024, 75(1): 354-365.

[4] 尹刚, 向冬梅, 王民, 等. 基于数据驱动的铝电解槽剩余寿命预测方法研究[J]. 稀有金属, 2023, 47(2): 273-280.

YIN G, XIANG D M, WANG M, et al. Prediction method of remaining life of aluminium reduction cell based on data drive[J]. Rare Metals, 2023, 47(2): 273-280.

[5] 杨欣荣, 凌玉华. 软测量技术及其在铝电解槽温度测量中的应用[J]. 中南工业大学学报, 2003, 34(5): 551-554.

YANG X R, LING Y H. Soft measurement technique and its application in aluminum electrolyzer temperature measurement[J]. Journal of the Central South University of Technology, 2003, 34(5): 551-554.

[6] 杜宇浩, 阎高伟, 李荣, 等. 基于局部线性嵌入的测地线流式核多工况软测量建模方法[J]. 化工学报, 2020, 71(3): 1278-1287.

DU Y H, YAN G W, LI R, et al. A soft measurement modeling method for geodesic flow kernels with multiple operating conditions based on local linear embedding[J]. CIESC Journal, 2020, 71(3): 1278-1287.

[7] YANG Y T, XU L, HAN H, et al. Soft measurement and prediction of refrigerant leakage based on SVR-LSTM[J]. International Journal of Refrigeration, 2023, 152: 303-314.

- [8] 高钢, 曾水平. 基于神经网络的铝电解温度与分子比的预测研究: 中国计量协会冶金分会 2010 年会论文集[C]. 杭州:《冶金自动化》杂志社, 2010.
- GAO G, ZENG SH P. Neural network-based prediction of aluminum electrolysis temperature and mole ratio: Proceedings of the 2010 annual meeting of the Metallurgical Branch of China Metrology Association[C]. Hangzhou: Metallurgical Automation, 2010.
- [9] 徐嵩, 李攀, 潘峥嵘. BP 神经网络在铝电解槽温度测量中的研究[J]. 自动化与仪器仪表, 2011(5): 30-32.
- XU S, LI P, PAN ZH R. Research on BP neural network in aluminum electrolyzer temperature measurement[J]. Automation and Instrumentation, 2011(5): 30-32.
- [10] 王宇, 康全林. 基于 LS-SVM 的铝电解槽电解温度软测量[J]. 仪器仪表用户, 2012, 19(4): 51-53.
- WANG Y, KANG Q L. Soft measurement of electrolysis temperature in aluminum electrolyzer based on LS-SVM[J]. Instrumentation Users, 2012, 19(4): 51-53.
- [11] 阎纲, 梁昔明, 龙祖强, 等. 铝电解槽参数的最小二乘支持向量机软测量模型[J]. 小型微型计算机系统, 2011, 32(12): 2444-2448.
- YAN G, LIANG X M, LONG Z Q, et al. Least squares support vector machine soft measurement model for aluminum electrolyzer parameters[J]. Small Micro-computer Systems, 2011, 32(12): 2444-2448.
- [12] 韩婷, 负卫国. 基于极限学习机的铝电解过程参数软测量[J]. 传感器与微系统, 2020, 39(9): 132-134, 137.
- HAN T, YUN W G. Soft measurement of aluminum electrolysis process parameters based on extreme learning machines[J]. Sensors and Microsystems, 2020, 39(9): 132-134, 137.
- [13] YAO L, GE ZH Q. Deep learning of semisupervised process data with hierarchical extreme learning machine and soft sensor application[J]. IEEE Transactions on Industrial Electronics, 2018, 65(2): 1490-1498.
- [14] SUI L, SUN K, MA J X, et al. Input variable selection and structure optimization for LSTM-based soft sensor with a dual nonnegative garrote approach[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3537611.
- [15] 孙刘家, 韩庆邦, 靳琪琳, 等. 基于深度学习的兰姆波 SCF-TFM 超分辨率成像[J]. 仪器仪表学报, 2024, 45(6): 101-110.
- SUN L J, HAN Q B, JIN Q L, et al. Lamb wave SCF-TFM super-resolution imaging based on deep learning[J]. Chinese Journal of Scientific Instrument, 2024, 45(6): 101-110.
- [16] NIRMAL S, PATIL P, KUMAR J R R. CNN-AdaBoost based hybrid model for electricity theft detection in smart grid[J]. e-Prime-Advances in Electrical Engineering, Electronics and Energy, 2024, 7: 100452.
- [17] SHEKAR P R, MATHEW A, YESWANTH P V, et al. A combined deep CNN-RNN network for rainfall-runoff modelling in Bardha Watershed, India[J]. Artificial Intelligence in Geosciences, 2024, 5: 100073.
- [18] BAI R H, SHEN F, ZHAO Z H, et al. The analysis of the correlation between SPT and CPT based on CNN-GA and liquefaction discrimination research[J]. CMES-Computer Modeling in Engineering & Sciences, 2024, 138(2): 1159-1182.
- [19] MANSOUR A A, TILIOUA A, TOUZANI M. Bi-LSTM, GRU and 1D-CNN models for short-term photovoltaic panel efficiency forecasting case amorphous silicon grid-connected PV system[J]. Results in Engineering, 2024: 101886.
- [20] 闫宇楠, 刘智康, 徐佳文, 等. 基于 CBAM-CNN 和压电悬臂梁的温度解耦质量感知方法[J]. 仪器仪表学报, 2024, 45(4): 113-126.
- YAN Y N, LIU ZH K, XU J W, et al. Temperature decoupled mass sensing method based on CBAM-CNN and piezoelectric cantilever beam[J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 113-126.
- [21] 曹帅. 基于 GWO-CNN 的刮板输送机减速器故障诊断[J]. 煤矿机械, 2024, 45(5): 162-165.
- CAO SH. Fault diagnosis of scraper conveyor reducer based on GWO-CNN[J]. Coal Mine Machinery, 2024, 45(5): 162-165.
- [22] WANG K, LI K N, DU F, et al. Research on prediction model of coal spontaneous combustion temperature based on SSA-CNN[J]. Energy, 2024, 290: 130158.
- [23] LI R Z, WANG J ZH, LI J R, et al. Long, short, and medium terms wind speed prediction model based on LSTM optimized by improved moth flame optimization

- algorithm [J]. Environmental Science and Pollution Research, 2024, 31(25): 37256-37282.
- [24] DONG P L, WANG X Y, SHI ZH H. Financial market trend prediction model based on LSTM neural network algorithm [J]. Journal of Computational Methods in Sciences and Engineering, 2024, 24(2): 745-755.
- [25] 尹刚, 陈根, 何文, 等. 基于深度学习的 300 kA 铝电解槽阳极效应预测[J]. 中国有色金属学报, 2021, 31(1): 161-170.
- YIN G, CHEN G, HE W, et al. Deep learning based anode effect prediction for 300 kA aluminum electrolyzer[J]. Chinese Journal of Nonferrous Metals, 2021, 31(1): 161-170.
- [26] XU J, GONG J, LI Y, et al. Surf-riding and broaching prediction of ship sailing in regular waves by LSTM based on the data of ship motion and encounter wave [J]. Ocean Engineering, 2024, 297: 117010.
- [27] MA Q, YE R X. Short-term prediction of the intermediate point temperature of a supercritical unit based on the EEMD-LSTM method[J]. Energies, 2024, 17(4): 949.
- [28] 狄俊豪, 郭晨霞, 杨瑞峰. 基于 CSSA-LSTM 神经网络的动态称重算法的研究[J]. 电子测量技术, 2024, 47(11): 95-100.
- DI J H, GUO CH X, YANG R F. Research on dynamic weighing algorithm based on CSSA-LSTM neural network[J]. Electronic Measurement Technology, 2024, 47(11): 95-100.
- [29] CHE ZH Y, PENG CH, YUE CH X. Optimizing LSTM with multi-strategy improved WOA for robust prediction of high-speed machine tests data[J]. Chaos, Solitons & Fractals, 2024, 178: 114394.
- [30] ZHANG CH Y, LUO ZH W, REZGUI Y, et al. Enhancing building energy consumption prediction introducing novel occupant behavior models with sparrow search optimization and attention mechanisms: A case study for forty-five buildings in a university community[J]. Energy, 2024, 294: 130896.
- [31] 赵云亮, 唐东林, 何媛媛, 等. 基于 CNN 融合 PGW-Attention 的金属表面缺陷识别方法[J]. 电子测量与仪器学报, 2024, 38(8): 46-55.
- ZHAO Y L, TANG D L, HE Y Y, et al. A defect recognition method for metal surface based on CNN fusion PGW-Attention[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(8): 46-55.
- [32] 罗强, 傅顺军, 苗梦奇, 等. 基于注意力残差卷积自编码器的轴承故障诊断[J]. 机械制造, 2024, 62(5): 85-90, 96.
- LUO Q, FU SH J, MIAO M Q, et al. Bearing fault diagnosis based on attentional residual convolutional selfencoder [J]. Machinery Manufacturing, 2024, 62(5): 85-90, 96.
- [33] WANG CH T, SHI H B, SONG B, et al. Hierarchical multihead self-attention for time-series-based fault diagnosis[J]. Chinese Journal of Chemical Engineering, 2024, 70(6): 104-117.
- [34] HAO X L, LIU Y, PEI L L, et al. Atmospheric temperature prediction based on a BiLSTM-Attention model[J]. Symmetry, 2022, 14(11): 2470.
- [35] 朱希, 李燕, 施林枫. 基于深度学习的密集物料检测方法[J]. 国外电子测量技术, 2024, 43(1): 151-158.
- ZHU X, LI Y, SHI L F. Deep learning based dense material detection method[J]. Foreign Electronic Measurement Technology, 2024, 43(1): 151-158.
- [36] GU J X, WANG ZH H, KUEN J, et al. Recent advances in convolutional neural networks [J]. Pattern Recognition, 2018, 77: 354-377.
- [37] WANG J, CAO J X. Data-driven S-wave velocity prediction method via a deep-learning-based deep convolutional gated recurrent unit fusion network [J]. Geophysics, 2021, 86(6): 185-196.
- [38] 穆晨宇, 薛文斌, 穆羨瑛, 等. 基于 VMD-LSTM-Attention 模型的短期负荷预测研究[J]. 现代电子技术, 2023, 46(17): 174-178.
- MU CH Y, XUE W B, MU X Y, et al. Study on short-term load forecasting based on VMD-LSTM-Attention model[J]. Modern Electronic Technology, 2023, 46(17): 174-178.
- [39] CHAUDHARI S, MITHAL V, POLATKAN G, et al. An attentive survey of attention models[J]. ACM Transactions on Intelligent Systems and Technology (TIST), 2021, 12(5): 53, 1-32.
- [40] GAO Y SH. PID-based search algorithm: A novel metaheuristic algorithm based on PID algorithm [J]. Expert Systems with Applications, 2023, 232: 120886.

作者简介



尹刚 (通信作者), 分别在1985年和1992年获得重庆大学学士学位和硕士学位, 于2009年获得重庆大学博士学位, 现为重庆大学教授和博士生导师。主要研究方向为工业过程建模、智能优化和深度学习、安全控制技术、人工智能、铝电解冶炼检测与监测技术。

E-mail: yk115@cqu.edu.cn

Yin Gang (Corresponding author) received his B.Sc. and M.Sc. degrees both from Chongqing University in 1985 and 1992, respectively, and the Ph.D. degree from Chongqing University in 2009. He is currently a professor and a Ph.D. supervisor at Chongqing University. His research interests include industrial process modeling, intelligent optimization and deep learning, safety control technology, and artificial intelligence, and aluminum electrolytic smelting detection and monitoring technology.



朱森, 2022年于郑州大学获得学士学位, 现为重庆大学硕士研究生, 主要研究方向为机器学习、有色冶金与故障诊断。

E-mail: zm2000905@163.com

Zhu Miao received her B.Sc. degree from Zhengzhou University in 2022. Now she is a M.Sc. candidate at Chongqing University. Her main research interests include machine learning, non-ferrous metallurgy and fault diagnosis.



全鹏程, 2003年于山东轻工业学院获得学士学位, 现为阿坝铝厂高级工程师, 主要研究方向为有色冶金。

E-mail: 383945655@qq.com

Quan Pengcheng received his B.Sc. degree from Shandong Institute of Light Industry in 2003. Now he is a senior engineer at Aba Aluminium Factory, his main research interest includes non-ferrous metallurgy.



颜玥涵, 2023年于大连工业大学获得学士学位, 现为贵州大学硕士研究生, 主要研究方向为冶金过程电气控制及数据挖掘。

E-mail: yhyan1117@163.com

Yan Yuehan received her B.Sc. degree from Dalian Polytechnic University in 2023. Now she is a M.Sc. candidate at Guizhou University. Her main research interests include electrical control and information automation collection in metallurgical processes.



刘期烈, 1999年于河北工程大学获得学士学位, 2004年于西南交通大学获得硕士学位, 2012年于重庆大学获得博士学位, 现为重庆邮电大学教授, 主要研究方向为宽带无线接入技术、无线网络虚拟化和传感器网络。

E-mail: 31553753@qq.com

Liu Qilie received his B.Sc. degree from Hebei University of Engineering in 1999 and his M.Sc. degree from Southwest Jiaotong University in 2004, and his Ph.D. degree from Chongqing University in 2012. He is currently a professor at Chongqing University of Posts and Telecommunications. His research interests include broadband wireless access technology, wireless network virtualization, and sensor networks.