

引文格式:张策,杨培宏,高乐乐,等. 基于混合神经网络模型的稀土熔盐电解槽状态诊断方法研究[J]. 中国有色冶金, 2025, 54(6):13-25.

ZHANG Ce, YANG Peihong, Gao Lele, et al. Research on state diagnosis method of rare earth molten salt electrolytic cell based on hybrid neural network model[J]. China Nonferrous Metallurgy, 2025, 54(6):13-25.

基于混合神经网络模型的稀土熔盐电解槽状态 诊断方法研究

张策¹, 杨培宏¹, 高乐乐², 吕东浩¹, 彭军³, 杨中峰¹

(1. 内蒙古科技大学 自动化与电气工程学院, 内蒙古 包头 014010;

2. 内蒙古北方稀土新材料技术创新有限公司, 内蒙古 包头 014030;

3. 内蒙古科技大学 稀土产业学院, 内蒙古 包头 014010)

[摘要] 针对稀土电解槽生产状态难以感知导致无法对其进行精确控制、影响稳定生产的问题, 本文提出了一种基于信号特征提取的混合神经网络诊断模型辨识电解槽运行状态的方法。首先, 通过槽电压与槽电流计算得到正常化槽电压信号, 并对其进行时频分析, 提取不同槽状态下各频段能量值、能量比与时域、频域特征, 构建特征数据集; 其次, 建立融合卷积神经网络 (Convolutional Neural Networks, CNN)、双向长短期记忆网络 (Bi-directional Long Short-Term Memory, BiLSTM) 与自注意力机制 (Self-Attention) 的槽状态诊断模型 (CNN-BiLSTM-SA), 通过 CNN 捕捉局部空间特征, BiLSTM 建模全局依赖关系以及自注意力机制强化特征关联性, 实现对电解槽状态诊断; 同时, 对河马算法进行改进, 加入佳点集初始化与交叉、变异操作, 以期提高算法的超参数寻优能力; 最后, 利用改进的河马算法对模型超参数进行寻优, 提升模型诊断精度。工业验证实验结果表明, 本文所提方法在槽状态诊断时诊断精度为 94.14%、Macro-F1 为 91.08%, 相比于未优化模型分别提高了 8.28% 和 14.19%, 在稀土熔盐电解槽状态诊断方面具有更高的准确率, 可为稀土熔盐电解过程优化控制与稳定运行提供依据。

[关键词] 稀土熔盐电解; 槽状态诊断; 混合神经网络; 改进河马算法; 过程优化控制; 稳定运行

[中图分类号] TF845; TP183 [文献标志码] A [文章编号] 1672-6103(2025)06-0013-13

DOI:10.19612/j.cnki.cn11-5066/tf.2025.06.002

0 引言

稀土因其独特的物理化学性能, 在现代工业体系中发挥着不可替代的功能性作用, 应用场景广泛覆盖国防建设、航空航天、新材料研发、电子信息等高新技术领域, 具有重要的战略地位和发

展前景^[1]。目前, 稀土冶炼的主要方法包括湿法冶金与火法冶金, 其中熔盐电解法作为火法冶金的一种, 凭借高效、连续且过程简单等优点, 在稀土生产领域内得到了广泛应用。然而, 稀土熔盐电解作为一个非线性、多变量耦合、时变和大时滞的复杂工业过程体系^[2], 其电解过程伴随着复杂的物理化学反应且电解槽内部具有高温、强腐蚀等特点, 导致现阶段稀土熔盐电解自动化程度较低、适用传感器较少^[3], 无法对电解槽内各工作参数进行实时在线采集并显示。其中电解槽状态变化的判断, 通常依赖操作人员对电解槽表面的观察和人工经验的综合分析, 存在一定的主观性缺陷, 同时随着经验丰富的工作人员减少和人员流

[收稿日期] 2025-08-16

[第一作者] 张策(2001—), 男, 河北石家庄人, 硕士研究生, 研究方向为稀土熔盐电解智能化。

[通信作者] 杨培宏(1980—), 男, 内蒙古呼和浩特人, 博士, 教授, 研究方向为智能控制。

[基金项目] 国家重点研发计划项目(2023YFB3506800); 内蒙古自治区“科技突围”项目(2024KJTW0002)。

动性加剧,导致槽状态判断的准确性难以得到保证。而稀土熔盐电解槽状态失稳则会引发一系列后果,轻则导致电解槽电流效率下降、产品纯度不达标,造成原料与能源浪费,重则引发槽体破损甚至停产,危及生产安全^[4]。因此,针对此类工业过程,准确判断电解槽运行状况是有效控制电解槽并确保稀土生产过程稳定运行的重要依据^[5]。

近年来,众多研究人员开始对电解槽的运行状态及其状态变化预测进行研究,以便能够及时针对各种电解槽状态进行调整并维护正常生产。文献[6]通过建立长短期记忆网络(Long Short-Term Memory, LSTM)模型分析生产数据与槽况变化的联系,进一步发现槽况变化规律,为预测电解槽状况提供依据。文献[7]通过采集不同槽况的生产数据,利用支持向量机将铝电解槽生产状态诊断为正常或异常,然后使用布谷鸟算法对其进行优化,实现数据监测与异常状态诊断。文献[8]提出了一种基于支持向量机的铝电解槽健康状态诊断模型,采用自适应推进算法将二分类问题转化为多分类问题,并利用粒子群算法对其超参数寻优,提高模型预测精度。文献[9]提出了一种基于综合指标评估模型的铝电解槽状态智能预测方法,从全局角度建立了槽状态综合指标模型,将槽状态分为优、良、差三类,实现24 h后的状态预测。然而,目前大多研究主要是将电解槽的健康状态划分为正常、异常等模糊的状态,并未对其展开进一步的分析与处理。

为提高工业设备健康状态估计与故障诊断的准确性,当前研究逐渐从单一神经网络模型转向混合神经网络模型^[10]。例如,文献[11]提出了一种基于CNN(Convolutional Neural Networks)混合模型的旋转机械故障诊断方法,该模型最大化发挥CNN自适应提取特征能力,减少了训练参数和计算时间。文献[12]提出了一种基于尺度自适应卷积神经网络和改进门控循环单元的故障诊断方法,该方法能够有效挖掘信号中所蕴含的故障信息,并准确识别故障类别。文献[13]结合CNN自动提取特征与LSTM(Long Short-Term Memory)处理序列数据的优点,提出了一种基于混合神经网络的电池健康状态估算方法,并与传统的LSTM、CNN方法进行对比,验证了文中模型的优越性。文献[14]提出了一种基于注意力机制的胶囊网络-双向门控循环单元的轮发动机故障模式识别模型,通过实验证明了模型

在故障诊断中的有效性。但需注意的是,随着模型复杂度的增加,其超参数也逐渐变多,而神经网络中超参数的设置高度依赖人工调节,导致模型在进行估计或诊断问题中存在一定的局限性。

针对上述问题,本文提出了一种基于信号特征提取的混合神经网络诊断模型辨识电解槽运行状态的方法。首先,对采集的原始信号进行预处理,得到不同槽状态下的样本信号。利用连续小波变换对其进行时频分析,提取不同槽状态下的时域、频域及时频域特征,通过相关性分析选取与槽状态关联显著的特征并作为混合神经网络模型的输入。该模型由卷积神经网络(Convolutional Neural Network, CNN)与双向长短期记忆神经网络(Bi-directional Long Short-Term Memory, BiLSTM)构成,能够有效捕捉数据的局部空间特征和全局依赖关系;随后,引入自注意力机制(Self-Attention),使模型能够动态聚焦于关键特征,减少冗余信息对诊断结果的影响。最后,利用改进的河马优化算法对混合神经网络模型的超参数进行全局寻优,以提高模型诊断精度,最终实现对稀土熔盐电解槽状态的精确诊断。

1 稀土熔盐电解槽状态分析及特征选取

槽电压作为稀土熔盐电解生产中为数不多可以在线实时采集的电解数据,其本身蕴含了丰富的槽况信息。比如,出金属或人工操作等对生产的影响、电流波动和阳极气体等引起的噪声、稀土氧化物浓度等状态信息都会包含在内,这些信息叠加在一起最终呈现出复杂的槽电压信号^[15]。因此,对槽电压信号中所蕴含的深层信息进行挖掘有利于诊断电解槽生产状况,以及更好调控稀土熔盐电解生产过程。

1.1 不同槽况下正常化槽电压能量谱分析

稀土电解槽槽电压一般主要由分解电压、熔盐电压降、阴极电压降、阳极电压降和结构压降等组成^[16]。生产过程中槽电压受氧化物浓度、电解温度、电解质成分和电流密度等多种因素影响,而这些因素都随电解过程而变化,且不能实时在线测量。一旦某因素成为槽电压变化的主导因素,其波动便会呈现出相应的表现形式。因此,通过分析不同槽状态与槽电压表现形式的对应关系,可为稀土电解槽状态诊断提供更加准确的依据。

稀土熔盐电解领域中主要将表观槽电阻作为主

要分析信号来对电解过程加以控制,其原因是采样槽电压受系列电流波动影响较大,而表观槽电阻在理论上并无影响,计算公式见式(1)。

$$R_0(k) = \frac{U(k) - B}{I(k)} \quad (1)$$

式中: $R_0(k)$ 为表观槽电阻, Ω ; $U(k)$ 为采样得到的槽电压, V ; $I(k)$ 为采样得到的系列电流, A ; B 为表观反电动势, V ; k 表示第 k 时刻。

由于电压的单位 (mV 或 V) 在工业生产中更加直观,且上式计算时受表观反电动势影响较大^[17]。因此本文使用与采样槽电阻具有相同内涵的“正常化槽电压”来作为解析信号,见式(2)。

$$U_0(k) = R_0(k)I_b + B = \frac{U(k) - B}{I(k)}I_b + B \quad (2)$$

式中: $U_0(k)$ 为电解槽的正常化槽电压, V ; $R_0(k)$ 为表观槽电阻, Ω ; I_b 为电解槽的基准系列电流, A ; $I(k)$ 为采样得到的系列电流, A ; B 为表观反电动势, V 。

本文以某稀土厂内 10 kA 电解槽采样频率为 1 Hz 的正常化槽电压信号为例,以 640 个数据为一个周期分段,结合生产现场情况分析正常槽况、出金属前以及系列电流异常波动时的正常化槽电压信号时频特性,其中正常槽况为电解槽正常生产情况,无出金属、换极等人工干预操作,该状态下电解槽内极距正常、电解质成分均匀,无明显的副反应发生,槽电压信号表现平稳,通常波动范围在 10 ~ 30 mV 内^[18],符合生产工艺控制指标;出金属前槽状态是指电解槽达到最佳出金属前的运行状态,即一个生产周期内所加入的稀土氧化物充分电解,电解过程中析出的稀土金属逐渐聚集在阴极,并沉入金属收集器中,使金属液面升高至预定高度。此状态下出金属可减少电能消耗。系列电流异常波动指在生产中(除出金属操作外),电流瞬时波动超出正常允许范围(5 ~ 10 A)的异常状态,该状态下电解槽内原有的能量与物料平衡会被打破,在槽电流信号中表现为电流值持续异常波动或波动峰值超出最大限定电流。图 1 分别展示了三种槽状态下正常化槽电压信号的时频图。其中图(a)为正常槽况下正常化槽电压的时频分布图,由于采样频率为 1 Hz,因此根据奈奎斯特采样定理可得有效频段为 $[0, 0.5]$ Hz;从图中可以看出,该状态下的能量主要集中在较低频段 $[0, 0.01]$ Hz,并连续分布在整个时间段内,其余

频段内的能量分布离散,总体能量密度均低于其余两种状态,反映出正常电解槽状态的平稳性。图(b)为出金属前的正常化槽电压时频分布图,随着电解过程的进行,金属收集器中的金属液面逐渐升高,导致时频图中能量波动随电解过程逐渐加剧。在临近出金属点时,能量强度达到峰值,且高能量区

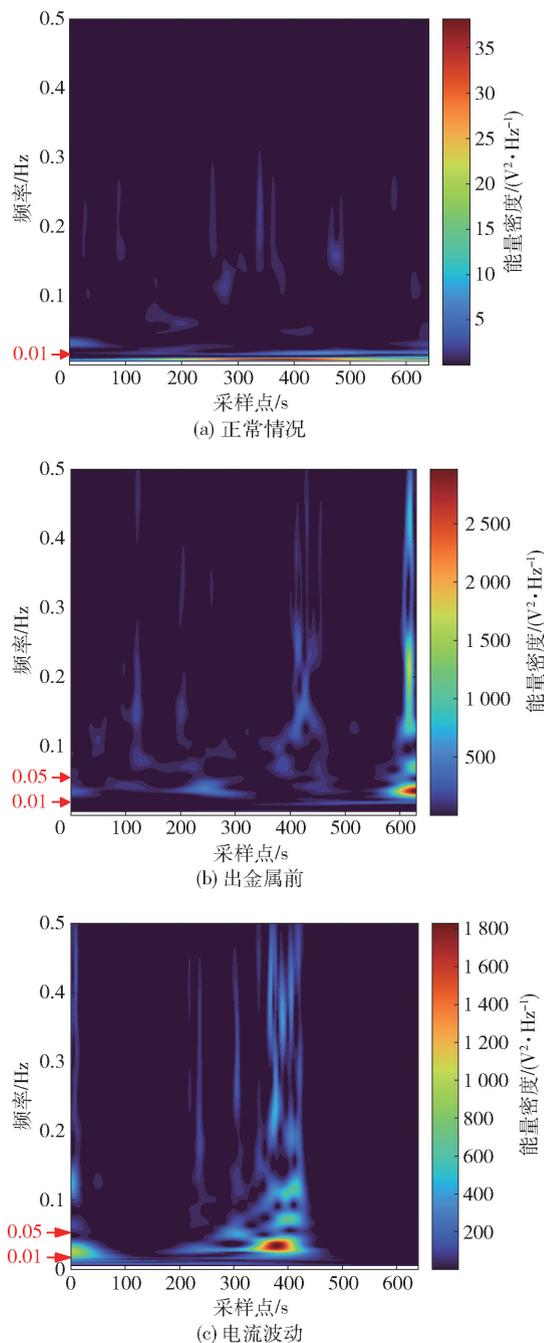


图 1 不同槽状态下时频图

Fig. 1 Time-frequency diagram under different slot states

域主要聚集于 $[0.01, 0.05]$ Hz 频段内^[19], 能量均高于其余两种状态。图(c)为系列电流波动槽状态下的正常化槽电压时频图, 此阶段在 200 ~ 450 s 内出现电流波动, 时频图中此阶段内能量起伏较大, 与金属阶段不同的是此阶段内能量波动主要集中在出现电流波动的时刻, 其余阶段能量密度无明显能量波动; 此阶段内只在电流波动时出现多条连续垂直能量带, 表明电流波动引发了正常化槽电压多频段的瞬时能量响应, 且能量主要集中在 $[0.01, 0.05]$ Hz 内^[20]。

由以上分析可知, 不同的电解槽状态会引起正常化槽电压时频域内各频段能量的变化, 且上述分析结果与其他学者^[21]研究正常化槽电压时频图中槽况分段结果比较相似, 说明提取不同槽状态下正常化槽电压信号中有效频段内的能量特征来对槽状态进行诊断是可行的。

1.2 电解槽状态诊断输入特征选取

小波包分解作为小波分解的改进, 其对信号的高、低频部分处理更加全面, 对原始信号的频带划分也更为详细^[22]。因此, 利用小波包分解在信号特征提取上的优势, 提取出不同槽状态下不同频段上的能量特征。为全面表征正常化槽电压信号在不同尺度下的特点, 选取 db5 作为基函数, 对正常化槽电压信号进行 3 层小波包分解, 计算得到 8 个子频带内的能量特征, 将每个子频带内的能量值与能量占比分别记作 E1 - E8 和 E9 - E16。此外, 在信号分析中还通常选用峭度、均方根频率、标准差频率等时域、频域特征, 因此文中共选取 46 个特征作为模型的可选特征集。

为减少模型输入特征维度并提高诊断效果, 需从可选特征集中筛选出与槽状态相关性较高的特征作为模型输入。为此, 本文采用斯皮尔曼相关系数法进行特征筛选。斯皮尔曼相关系数计算公式见式(3)。

$$p = \frac{\frac{1}{n} \sum_{i=1}^n ((R(x_i) - \bar{R}(x)) \cdot (R(y_i) - \bar{R}(y)))}{\sqrt{\left(\frac{1}{n} \sum_{i=1}^n (R(x_i) - \bar{R}(x))^2\right) \cdot \left(\frac{1}{n} \sum_{i=1}^n (R(y_i) - \bar{R}(y))^2\right)}} \quad (3)$$

式中: $R(x_i)$ 和 $R(y_i)$ 分别为第 i 个样本在变量 x 和变量 y 上的位次; $\bar{R}(x)$ 和 $\bar{R}(y)$ 分别表示平均位次; n 为总的观测样本数; i 为样本索引。

该方法通过计算输入特征与输出类别之间的非线性关联程度, 能够有效处理分类变量与非正态分布数据的统计关系。随后, 选取其中与电解槽状态相关系数大于 0.7 的特征, 共 24 个特征构建诊断模型数据集, 为后续模型诊断提供合适的输入。具体输入特征选取如图 2 所示。

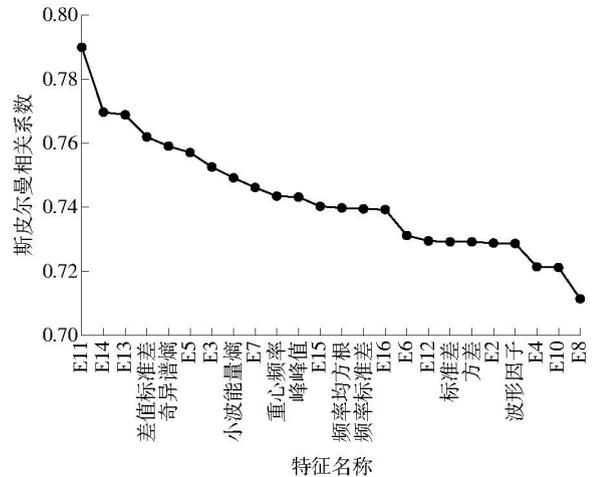


图 2 输入特征选取图

Fig. 2 Input feature selection diagram

2 稀土熔盐电解槽状态诊断模型构建

2.1 CNN-BiLSTM-SA 模型搭建

2.1.1 卷积神经网络

CNN 是一种受生物自然视觉认知机制启发而来的前馈性神经网络, 其主要由输入层、卷积层、池化层和全连接层组成。CNN 主要是利用卷积层通过局部感知和权值共享^[23], 对输入数据进行局部特征提取, 从而实现了对数据的识别与分类。

2.1.2 双向长短期记忆网络

BiLSTM (Bi-directional Long Short-Term Memory) 是在长短期记忆网络的基础上进行扩展的一种形式, 相比于 LSTM 的单向结构响应序列特征, BiLSTM 网络通过结合前向和后向两个 LSTM 层, 实现了信息双向传播的流动机制^[24], 从而得到更多的特征和上下文信息, 有效克服了传统单层 LSTM 处理序列数据的局限性。

2.1.3 自注意力机制

注意力机制是深度学习中一种模拟人类视觉或思维聚焦的重要技术, 用于解决长距离依赖的对齐问题。其核心机制是动态分配权重, 使模型更加关

注输入中与当前任务高度相关的部分。而自注意力机制作为注意力机制的变体,其更加关注不同输入向量之间的相关性,通过计算输入向量之间的相对重要程度,自适应地挖掘序列间的长期依赖关系,从而更好地理解全局关系。

2.1.4 稀土熔盐电解槽状态诊断模型搭建

建立稀土熔盐电解槽状态诊断模型,其结构

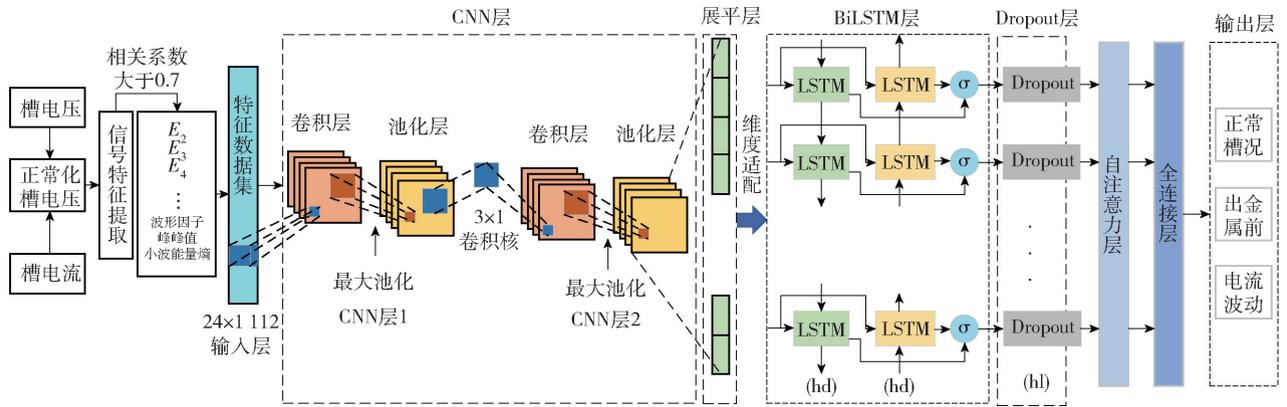


图3 CNN-BiLSTM-SA 模型结构图

Fig.3 CNN-BiLSTM-SA model structure diagram

该模型以构建的稀土熔盐电解槽状态特征样本作为输入,经卷积层进行特征提取,卷积层通过滑动卷积核对电解槽状态特征进行提取,重点捕捉各稀土熔盐电解槽状态下的局部特征信息;对提取的特征图进行批量归一化处理,可以加速模型收敛,还可缓解梯度消失问题;随后池化层对特征图进行降维和信息筛选,在保留显著特征的同时提升模型平移不变性;展平层能够将池化层的输出转换为适配BiLSTM层的输入结构。由于电解槽状态不仅取决于当前时刻的特征变化,更与过去和未来的趋势密切相关,因此,文中选取BiLSTM结构来进行双向信息传播,捕捉每个电解槽状态样本在序列上下文中的信息,充分学习输入特征与电解槽状态的长期依赖关系。随后,为进一步提升诊断模型对电解槽状态关键特征的聚焦能力,从而引入自注意力层,计算BiLSTM层输出的注意力权重,动态聚焦于对稀土电解槽状态诊断更关键的特征维度,通过输出层SoftMax函数实现权重归一化,以此强化输入特征与稀土电解槽状态的关联性,提升模型对不同电解槽状态的识别敏感度。

此外,为抑制模型复杂度和电解数据中难以避免的噪声所带来的过拟合风险,在自注意力层前加

如图3所示,其中该模型所需设置的超参数包括BiLSTM隐含层神经元个数 hd 、初始学习率 lr 、Dropout比率 hl 与正则化参数 $l2$ 。模型结构依次为输入层、CNN层、展开层,随后是BiLSTM层、Dropout层和自注意力层,最后是全连接输出层,其中CNN层数为2,其余层数都为1,以此进一步提高模型诊断精度。

入Dropout层。该机制在训练时随机丢弃部分神经元,防止模型过度拟合训练数据中的局部噪声,从而提升模型在实际生产环境中的泛化能力和诊断稳定性。最后,全连接层通过非线性映射建立自注意力层输出与稀土熔盐电解槽状态类别的关联,经输出层得到最终的稀土熔盐电解槽状态诊断结果。

2.2 改进河马优化算法

传统神经网络超参数依赖人工设置,存在耗时显著且经验依赖性强的问题,导致模型准确率难以得到保障。因此,文中采用改进的河马优化算法来对模型中的超参数进行寻优,在寻优过程中将模型超参数作为河马坐标,每只河马代表一组解,通过模拟河马群体的三种关键行为模式实现对解空间的探索,找到更优解。

河马优化算法(Hippopotamus Optimization Algorithm, HO)是Mohammad Hussein Amiri等人于2024年提出的一种新型元启发算法^[25],其灵感来源于河马生活中的行为模式。该算法可自适应调整搜索分辨率和搜索速度,具有搜索速度快、求解精度高的特点,但河马算法存在初始化随机性较强、后期迭代可能会陷入局部最优等问题。为弥补原始算法的不足,本文引入佳点集初始化与遗传算法中的交叉、变

异操作,来提高算法的寻优能力。

2.2.1 佳点集初始化

原始的河马优化算法在种群初始化时通常使用 rand 函数,这样可能会导致种群初始化随机性较强、分布过于集中等问题,从而影响初始解质量和算法的整体探索能力。对此,本文采用佳点集(Good Point Set)方法来对种群进行初始化,该方法相较于 rand 函数能够更加均匀地覆盖搜索空间,提高初始解质量、算法收敛速度与稳定性,且不依赖于大量随机性或复杂性计算过程。其基本定义如下,设 G_s 是 s 维欧氏几何空间中的单位立方体,如果 $r \in G_s$,则有公式(4)。

$$P_n(i) = \{(r_1^{(n)} \cdot i), (r_2^{(n)} \cdot i), \dots, (r_s^{(n)} \cdot i), 1 \leq i \leq n\} \quad (4)$$

式中: $P_n(i)$ 为佳点集; r 为佳点; n 为样本数量。

将佳点集映射到搜索空间,既得式(5)。

$$X_{ij} = \{r_j^{(i)} \cdot k\} \cdot (u_j - l_j) + l_j, 1 \leq k \leq i \quad (5)$$

式中: X_{ij} 为第 i 个个体在第 j 维变量的初始位置; u_j 和 l_j 为第 j 维变量的上下界。

2.2.2 引入交叉、变异操作

当面临复杂问题时,算法在迭代后期仍有陷入局部最优的可能,而遗传算法中的交叉、变异操作可以更好地帮助种群跳出局部最优,增强全局搜索能力^[26]。因此,在河马优化算法中引入交叉、变异操作,来增强该算法寻优能力,防止算法早熟收敛。交叉、变异操作公式分别见式(6)(7)。

交叉操作

$$\begin{cases} X_{c1} = X_{p1} \cdot mask + X_{p2} \cdot (1 - mask) \\ X_{c2} = X_{p2} \cdot mask + X_{p1} \cdot (1 - mask) \end{cases} \quad (6)$$

式中: $mask$ 为二进制掩码,用来决定那些基因需要进行操作; X_{c1} 和 X_{c2} 代表交叉后生成的子代个体; X_{p1} 和 X_{p2} 是两个随机选出的父辈个体;

变异操作

$$P' = P + mut \cdot (b_{uj} - b_{lj}) \cdot N(0,1) \quad (7)$$

式中: P' 为变异后的新个体; P 为原始个体的基因; b_{uj} 和 b_{lj} 分别为第 j 维的上下界; mut 是一个二进制掩码矩阵,该矩阵决定了每个基因位是否变异,从而对种群进行随机扰动,增强种群的全局搜索能力; $N(0,1)$ 是符合标准正态分布的随机数。

2.3 模型诊断流程

步骤一:对采集的槽电压与槽电流数据进行异常值处理、缺失值填补与降噪等预处理操作,并计算

出相应的正常化槽电压。

步骤二:对计算得到的正常化槽电压信号进行时频分析,利用小波包分解技术提取不同状态下各频段内能量特征与时域、频域特征构建可选特征集,并运用斯皮尔曼相关系数法筛选出与电解槽状态关联度显著的特征构建模型数据集。

步骤三:对标准河马优化算法进行改进,并利用改进河马优化算法(Improved Hippopotamus Optimization Algorithm, IHO)对 CNN-BiLSTM-SA 模型进行超参数寻优,得到模型的最优超参数。

步骤四:按照 8:2 的比例将数据集分为训练集和测试集,并将最优超参数带入诊断模型中进行训练,将测试样本集作为训练好的诊断模型的输入进行验证,最后利用评价指标对模型性能进行评价。

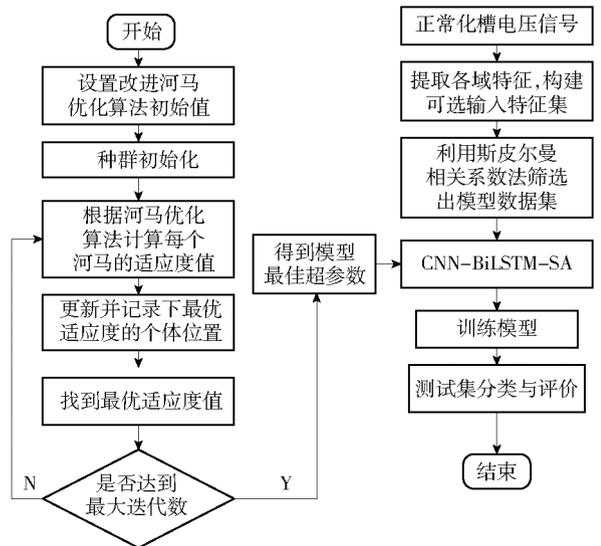


图4 IHO 优化 CNN-BiLSTM-SA 模型诊断流程图

Fig. 4 IHO optimized CNN-BiLSTM-SA model diagnosis flow chart

2.4 评价指标

本文选择在多分类模型中常用的准确率(Accuracy)和宏平均指标来对模型性能进行评判,通过对所有类别的精确率(Precision)、召回率(Recall)和两者的调和平均 F1-Score 计算平均值来得到 Macro-Precision、Macro-Recall 和 Macro-F1。各指标计算公式见式(8)——(11)。

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \times 100\% \quad (8)$$

$$Macro-Precision = \frac{1}{k} \sum_{i=1}^k \frac{TP}{TP + FP} \times 100\% \quad (9)$$

$$\text{Macro-Recall} = \frac{1}{k} \sum_{i=1}^k \frac{TP}{TP + FN} \times 100\% \quad (10)$$

$$\text{Macro-F1} = \frac{1}{k} \sum_{i=1}^k \text{F1-Score}_i =$$

$$2 \times \frac{\text{Macro-Precision} \times \text{Macro-Recall}}{\text{Macro-Precision} + \text{Macro-Recall}} \times 100\% \quad (11)$$

式中: TP 为正确识别为该类样本的数量; TN 为正确识别为该类样本的数量; FP 为错误识别为其他类样本的数量; FN 为错误识别为其他类样本的数量。

3 实验验证

3.1 改进河马优化算法有效性验证

为了验证改进后河马优化算法的有效性, 本文选取经典优化算法和新型算法, 包括遗传优化算法 (Genetic Algorithm, GA)、粒子群算法 (Particle Swarm Optimization, PSO)、鲸鱼优化算法 (Whale Optimization Algorithm, WOA)、鹈鹕优化算法 (Pelican Optimization Algorithm, POA)、灰狼优化算法 (Grey Wolf Optimizer, GWO)、HO (Hippopotamus Optimization Algorithm) 共 6 种算法与 IHO (Improved Hippopotamus Optimization Algorithm) 在 CEC2022 测试函数集上进行实验对比, CEC2022 测试函数集详情见表 1。

为充分体现改进后算法的性能, 将每个算法各自运行 30 次。实验选取参数为: 最大迭代次数为 500 次, 空间维度为 20, 种群规模为 50。图 5 为对比算法在 12 个测试函数上的平均收敛曲线。

3.2 工业验证实验对比与分析

3.2.1 数据获取与预处理

本文采用包头某稀土生产厂 10 kA 电解槽 2024 年 4 月生产的真实电解数据作为样本, 数据采样周期为 1 s, 通过收集电解槽生产系统中的槽电压与槽电流数据, 从而计算得到正常化槽电压样本信号。在实际生产中, 由于数据系统或传感器故障等原因导致采集得到的数据存在部分缺失或出现异常值。因此, 在进行训练之前需要对模型进行数据缺失值填补、异常值剔除以及降噪处理。此外, 在模型训练时为避免各输入量纲差异所带来的影响, 本文对数据进行归一化处理, 将其缩放到 $[0, 1]$ 范围内, 计算公式见式 (12)。

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (12)$$

表 1 CEC2022 测试函数集
Table 1 CEC2022 test function set

函数类型	编号	函数名	函数值
单峰函数	F1	Shifted and full Rotated Zakharov Function	300
	F2	Shifted and full Rotated Rosenbrock's Function	400
	F3	Shifted and full Rotated Expanded Schaffer's f6	600
		Shifted and full Rotated Non-Continuous Rastrigin's Function	800
	F5	Shifted and full Rotated Levy Function	900
混合函数	F6	Hybrid Function 1 ($N=3$)	1 800
	F7	Hybrid Function 2 ($N=6$)	2 000
	F8	Hybrid Function 3 ($N=5$)	2 200
组合函数	F9	Composition Function 1 ($N=5$)	2 300
	F10	Composition Function 2 ($N=4$)	2 400
	F11	Composition Function 3 ($N=5$)	2 600
	F12	Composition Function 4 ($N=6$)	2 700
搜索范围: $[-100, 100]^D$			

式中: x' 为归一化后的结果; x 为原始数据; $\max(x)$ 和 $\min(x)$ 分别为数据中的最大值与最小值。

3.2.2 模型参数设置

文中共构建 1 112 个样本, 其中类别 1 (正常槽状态)、类别 2 (出金属前) 和类别 3 (电流波动) 三种槽状态的样本数量分别为 685、191 和 236, 将其按照 8:2 的比例划分训练集与测试集, 训练集用于训练模型, 测试集用来评估模型的性能, 在训练时为避免出现数据严重不平衡, 而导致诊断结果不准确, 本文在训练集中应用合成少数过采样技术 (Synthetic Minority Oversampling Technique, SMOTE) 来平衡处理各类别的样本数量, 而测试集则保持原始数据类别分布不平衡, 以真实评估模型在实际应用中的性能。未优化模型的初始超参数通过参考其他文献后确定, 具体参数见表 2。

本文模型的初始学习率、隐含层神经元个数、Dropout 比率和正则化参数利用 IHO 对进行寻优, 其中将模型分类错误率作为目标函数, 寻得最优超参数组合中的学习率为 0.013 3, 隐藏层节点个数为 38, Dropout 比率为 0.379 5, 正则化参数为 0.000 1。模型其余参数设置如下: batch-size 为 148, 迭代次数

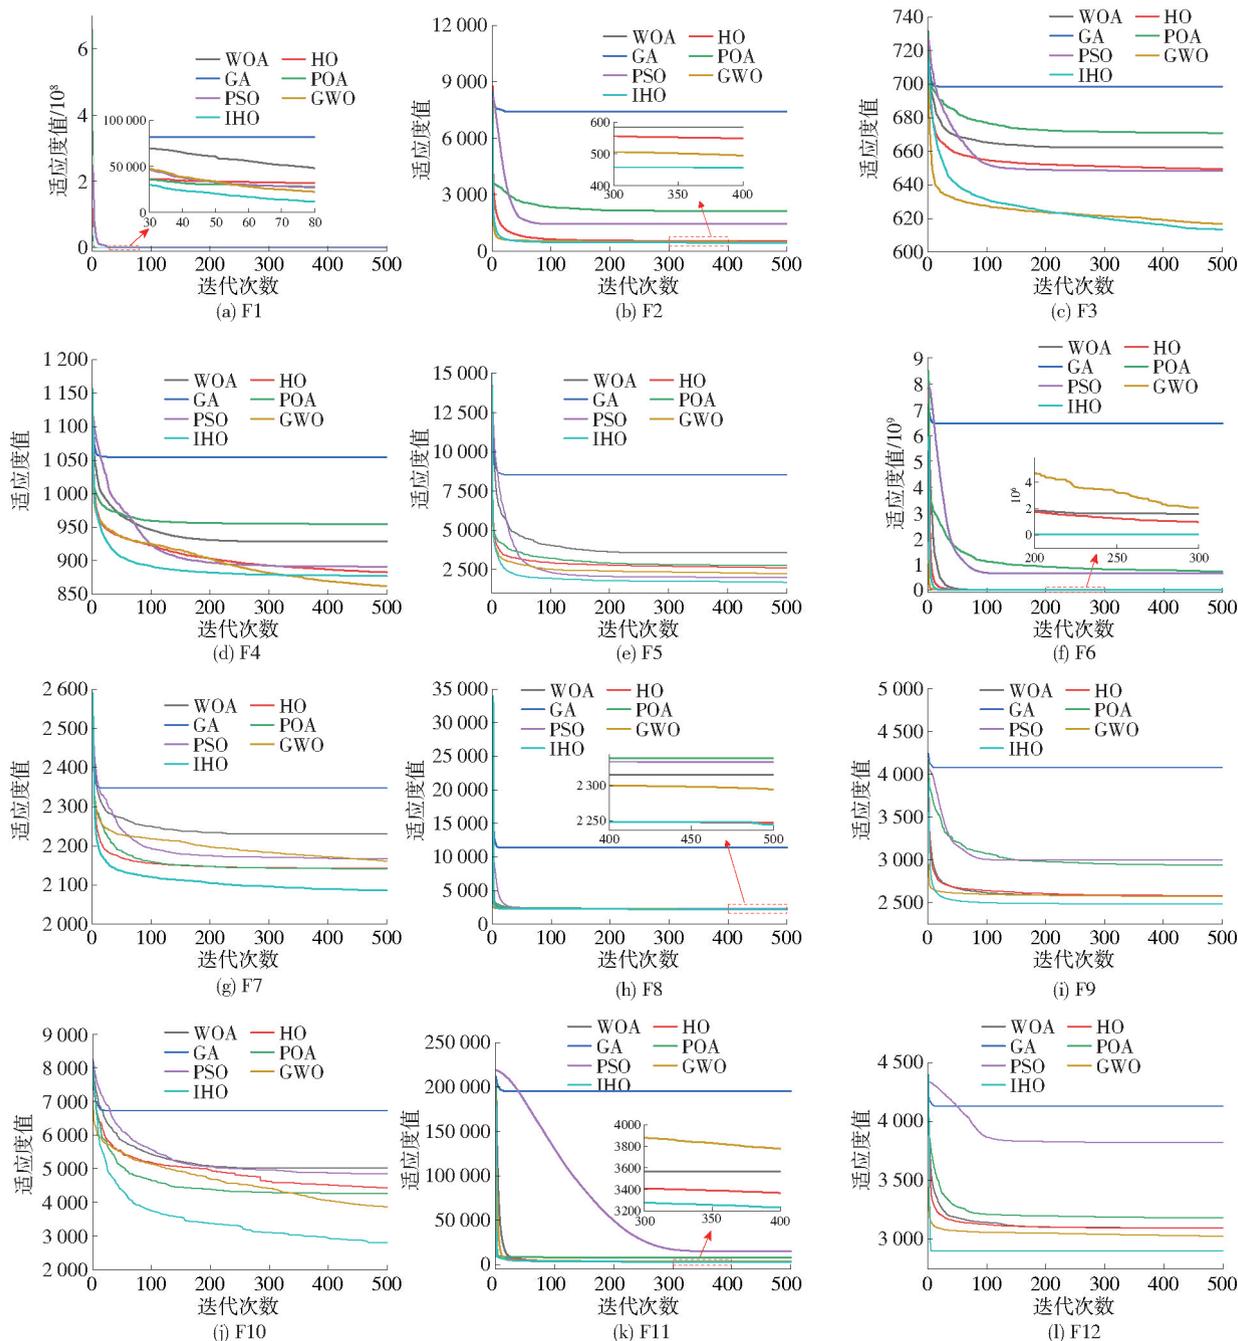


图5 各算法在12个测试函数中的平均收敛曲线

Fig. 5 The average convergence curves of each algorithm in 12 test functions

为100;优化算法中的交叉概率和变异概率分别设为0.8和0.15。

3.2.3 混合神经网络模型与单一模型对比

为验证本文所提出融合模型的有效性,文中对模型各层之间进行拆解,并在相同数据集和同一实验环境下进行性能对比。将本文模型分别与未优化模型、优化后的CNN模型、优化后的CNN-BiLSTM

模型以及优化后的BiLSTM-SA模型进行对比。图6为本文模型诊断结果,对比模型诊断结果如图7所示。图8为各模型指标对比图。

由图8中对比结果可知,本文提出的IHO优化CNN-BiLSTM-SA模型在4个指标上优势显著,其Accuracy、Macro-Precision、Macro-Recall和Macro-F1分别为94.14%、93.36%、89.44%和0.9108。其

表 2 初始超参数

Table 2 Initial hyperparameters

超参数	配置说明
优化器	Adam
卷积核大小、通道数、步长	$3 \times 1, 16, 1$
池化窗口大小、步长	$2 \times 1, 2$
BiLSTM 隐含层神经元个数	25
Dropout 比率	0.1
初始学习率	0.01
正则化参数	0.001

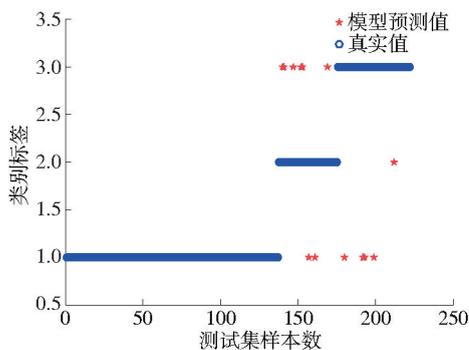


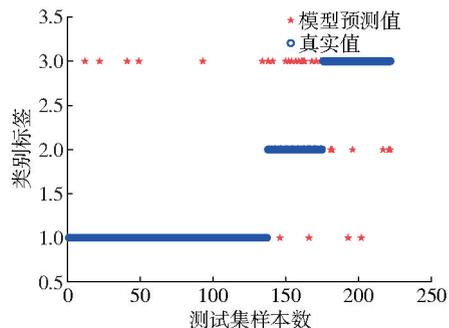
图 6 本文模型预测结果

Fig. 6 The model prediction results in this paper

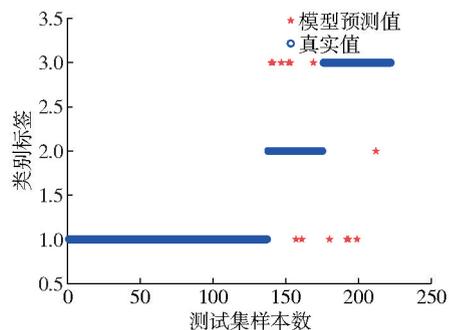
中,本文模型相比于 IHO-CNN 和 IHO-BiLSTM-SA 准确率分别提高了 5.55% 和 2.45%,证明了 CNN 与 BiLSTM-SA 的结合能够更有效地进行特征提取与长期依赖关系识别;同时,相较于 IHO-CNN-BiLSTM 模型,准确率提高了 3.46%,说明引入自注意力机制能够帮助模型聚焦关键特征,从而提高模型诊断的准确性;与此同时,加入 IHO 的诊断模型在各项指标上均优于未优化的 CNN-BiLSTM-SA 模型。上述结果说明文中提出的 CNN-BiLSTM 混合模型在加入 IHO 优化算法和自注意力机制后,能够有效提升模型对稀土电解槽状态的诊断能力。

3.2.4 不同分类模型对比

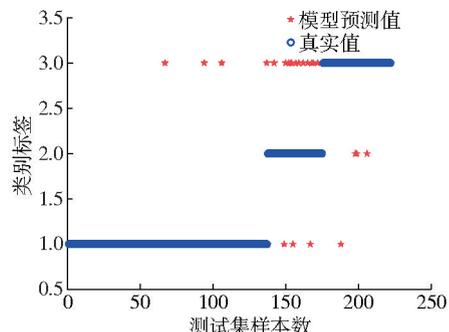
为进一步验证融合模型的性能,本文单独建立融合 Adaboost 和支持向量机 (Support Vector Machine, SVM) 的 Adaboost-SVM 模型、融合 CNN、LSTM 和注意力机制 (Attention) 的 CNN-LSTM-Attention 模型以及融合时间卷积网络 (Temporal Convolutional Network, TCN) 和门控循环单元 (Gate Recurrent Unit, GRU) 的 TCN-GRU 三种融合分类模型,并在同



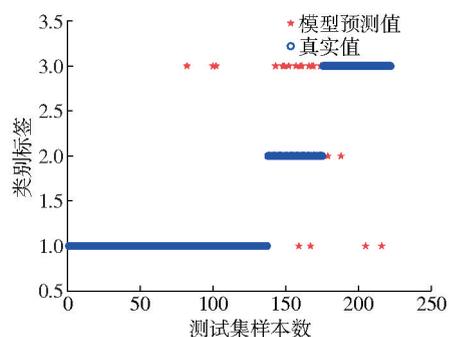
(a) CNN-BiLSTM-SA模型诊断结果



(b) IHO-BiLSTM-SA模型诊断结果



(c) IHO-CNN模型诊断结果



(d) IHO-CNN-BiLSTM模型诊断结果

图 7 对比模型诊断结果

Fig. 7 Comparison of model diagnostic results

一实验条件下进行实验对比。诊断结果如图 9 和图 10 所示。

由图 10 可知,本文模型相比于其他分类模型准确率分别提高了 11.17%、10.57%、9.99%; Macro-

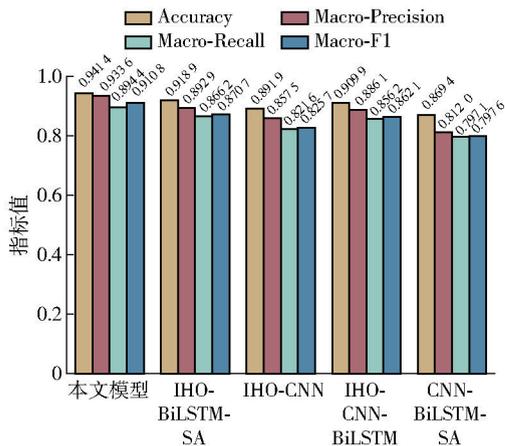


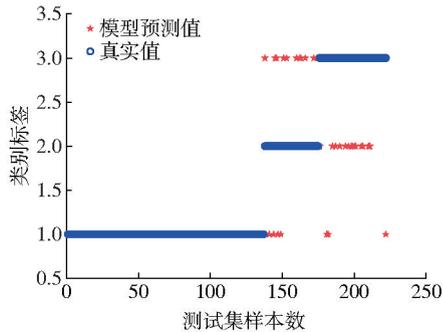
图 8 各模型指标对比图

Fig. 8 Comparison chart of indicators for each model. Precision 分别提高了 24.30%、14.03%、16.06%；Macro-Recall 分别提高了 22.19%、20.20%、18.01%；Macro-F1 分数分别提高了 23.03%、17.86%、19.21%。结合上述实验结果可知,所提出的 IHO 优化 CNN-BiLSTM-SA 模型在稀土熔盐电解槽状态诊断任务中各评价指标均优于其他混合分类模型,更能有效挖掘输入特征与槽状态之间的关系,从而验证了所提方法的有效性。

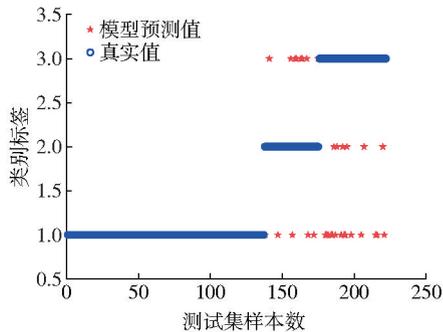
4 实际工程验证

为验证本文所提出的稀土熔盐电解槽状态诊断模型在实际生产场景中的有效性与工程实用性,文中通过现场采集包头某稀土冶炼厂内 10 kA 电解槽的现场生产数据,将其进行数据预处理作为稀土熔盐电解槽状态诊断模型的实际验证数据集,来对实际生产中槽状态进行诊断。考虑到诊断模型对实际生产的泛化性,数据采集阶段分别采集电解槽多个完整生产周期内的运行数据作为样本,确保能够覆盖典型生产工况,从而保障数据的代表性与场景覆盖性。实际生产数据诊断结果见表 3。

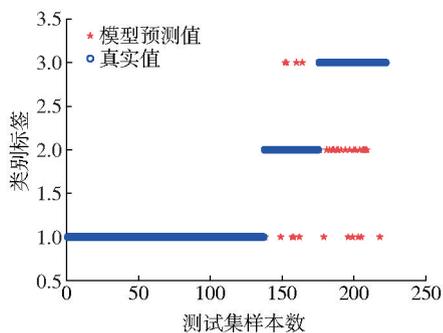
由表 3 可知,本文模型对稀土现场电解槽状态诊断准确率最高可达 93.08%,平均准确率为 91.57%,验证了模型的有效性。但在实际稀土电解生产中,由于电解槽多数时间处于正常电解状态,因此,现场所采集数据中电解槽状态类别占比并不均衡,从而导致诊断模型宏平均指标波动幅度相对较大。尽管如此,本文模型在实际生产数据测试中仍达到了 91.57% 的平均诊断准确率,显示出良好的



(a) Adaboost-SVM模型诊断结果



(b) CNN-LSTM-Attention模型诊断结果



(c) TCN-GRU模型诊断结果

图 9 不同分类模型预测结果

Fig. 9 Predicted results of different classification models

表 3 实际生产数据诊断结果

Table 3 Actual production data diagnosis result

不同生产周期	Accuracy	Macro-Precision	Macro-Recall	Macro-F1
生产周期 1	0.9308	0.9728	0.8589	0.8963
生产周期 2	0.9045	0.9045	0.9511	0.9179
生产周期 3	0.9119	0.7894	0.8258	0.8043

实用性和可靠性,证明该模型能够辅助生产人员监控电解槽状态,及时发现异常情况,为故障预警和决策维护提供有效支持,对保障稀土电解过程安全、稳定、高效运行具有重要实际意义。

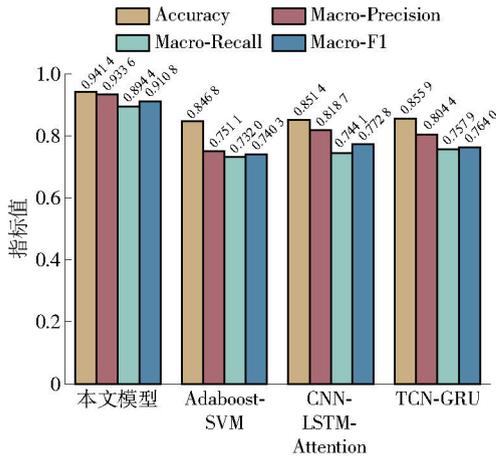


图 10 不同分类模型指标对比图

Fig. 10 Comparison of different classification model indicators

5 结论

为提高对稀土熔盐电解槽状态诊断精度以确保稳定生产,本文提出了一种基于混合神经网络模型的稀土熔盐电解槽状态诊断方法,利用 IHO 算法对 CNN-BiLSTM-SA 混合神经网络模型的超参数进行优化,并结合现场数据对电解槽状态进行诊断,得到以下主要结论。

1) 通过对比正常槽状态、出金属前槽状态和系列电流异常波动槽状态下的正常化槽电压时频图,发现不同状态下各频段能量分布存在显著差异。对此,提取不同槽状态下各频段内能量特征与时域、频域特征,构建了诊断模型数据集。

2) 提出改进河马算法,通过改变算法原始的初始化方式以及融合遗传算法的交叉、变异机制,弥补原始河马算法的不足,并在 CEC2022 测试集上验证了其寻优能力。

3) 构建了基于 IHO-CNN-BiLSTM-SA 的稀土熔盐电解槽状态诊断模型,并通过工业验证实验对其进行验证,结果表明在稀土电解槽状态诊断任务中,优化后模型准确率、Macro-Precision、Macro-Recall 和 Macro-F1 分别为 94.14%、93.36%、89.44% 和 0.9108,相较于未优化模型分别提升了 8.28%、14.98%、12.21% 和 14.19%,同时优于其他对比模型。

4) 通过实际生产数据测试结果,表明该模型在电解槽状态判断方面准确率可达 93.08%,平均准

确率为 91.57%,具有较高的准确性与客观性,降低了对人工经验的依赖,使工作人员能够针对当前电解槽状态采取最优调控策略,从而保障稀土生产平稳运行,为稀土冶炼智能化升级提供可行的诊断方案。

[参考文献]

- [1] 王春梅,刘玉柱,赵龙胜,等. 我国稀土材料与绿色制备技术现状与发展趋势[J]. 中国材料进展, 2018, 37(11):841-847, 879.
WANG Chunmei, LIU Yuzhu, ZHAO Longsheng, et al. Current situation and development tendency on rare earth materials and its green preparation technologies in China [J]. Materials China, 2018, 37(11):841-847, 879.
- [2] 许自豪,刘爱民,刘凤国,等. 熔盐电解制备稀土金属及其合金研究进展[J]. 中国有色冶金, 2025, 54(2):9-24.
XU Zihao, LIU Aiming, LIU Fengguo, et al. Research progress on the preparation of rare earth metals and their alloys by molten salt electrolysis [J]. China Nonferrous Metallurgy, 2025, 54(2):9-24.
- [3] 刘风琴,王胜楠,刘玉宝,等. 稀土电解槽数值模拟研究现状及发展趋势[J]. 有色金属(冶炼部分), 2024(11):225-239.
LIU Fengqin, WANG Shengnan, LIU Yubao, et al. Research status and developing trend of numerical simulation in rare earth electrolytic cell [J]. Nonferrous Metals (Extractive Metallurgy), 2024(11):225-239.
- [4] 丁立伟,聂婷,李婷. 基于 BP 网络和专家系统的铝电解槽分层故障诊断[J]. 计算机测量与控制, 2014, 22(11):3476-3479.
DING Liwei, NIE Ting, LI Ting. Aluminum cell hierarchical fault diagnosis method based on BP network and expert system [J]. Computer Measurement & Control, 2014, 22(11):3476-3479.
- [5] 谢政骞,曾凡锋. 基于注意力机制的铝电解槽辅助决策方法[J]. 轻金属, 2024(1):35-41.
XIE Zhengqian, ZENG Fanfeng. An aided decision method for aluminum electrolytic cells based on attention mechanism [J]. Light Metals, 2024(1):35-41.
- [6] 侯婕,田学法,孔淑麒. 基于 LSTM 的铝电解槽况预测[J]. 轻金属, 2021(1):33-37, 62.
HOU Jie, TIAN Xuefa, KONG Shuqi. Prediction of aluminum pot conditions based on LSTM [J]. Light Metals, 2021(1):33-37, 62.
- [7] 李界家,高天浩,纪昕洋. 基于布谷鸟-支持向量机和深度学习的铝电解异常状态诊断方法[J]. 轻金属, 2019(10):32-40.
LI Jiejia, GAO Tianhao, JI Xinyang. Aluminum electrolysis abnormal state diagnosis method based on cuckoo support vector machine and deep learning [J]. Light Metals, 2019(10):32-40.
- [8] 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 Gang, QIAN Zhongyou, CAO Wenqi, et al. Health state diagnosis of aluminum electrolytic cells based on Adaboost-PSO-SVM [J]. CIESC Journal, 2024, 75(1): 354-365.
- [9] 徐辰华, 谢春, 黄清宝, 等. 基于综合指标评估模型的铝电解槽状态智能预测[J]. 广西大学学报(自然科学版), 2019, 44(3): 677-684.
- XU Chenhua, XIE Chun, HUANG Qingbao, et al. Intelligent prediction of aluminum electrolysis cell state based on comprehensive index evaluation model [J]. Journal of Guangxi University (Natural Science Edition), 2019, 44(3): 677-684.
- [10] 宋晓承, 岑跃峰, 张宇来, 等. 基于双通道深度学习的轴承故障诊断研究[J]. 机电工程, 2023, 40(7): 988-998.
- SONG Xiaocheng, CEN Yuefeng, ZHANG Yulai, et al. Bearing fault diagnosis based on two-channel deep learning [J]. Journal of Mechanical & Electrical Engineering, 2023, 40(7): 988-998.
- [11] 崔灿, 陈林波, 张敏. CNN 混合模型的旋转机械故障诊断方法研究[J]. 现代电子技术, 2022, 45(13): 73-77.
- CUI Can, CHEN Linbo, ZHANG Min. Study on rotating machinery fault diagnosis method based on convolutional neural network hybrid model [J]. Modern Electronics Technique, 2022, 45(13): 73-77.
- [12] 杨端浩, 付文龙, 史慧彬. 基于 SACNN-MGRU 混合模型的滚动轴承故障诊断[J]. 电子测量技术, 2021, 44(22): 160-167.
- YANG Duanhao, FU Wenlong, SHI Huibin. Fault diagnosis of rolling bearing based on SACNN-MGRU hybrid model [J]. Electronic Measurement Technology. 2021, 44(22): 160-167.
- [13] 陈峥, 李金元, 舒星, 等. 基于混合神经网络的锂离子电池健康状态估算[J]. 昆明理工大学学报(自然科学版), 2022, 47(3): 87-95.
- XU Zheng, LI Jinyuan, SHU Xing, et al. State of health estimation for lithium-ion battery based on hybrid neural network [J]. Journal of Kunming University of Science and Technology (Natural Science), 2022, 47(3): 87-95.
- [14] 张振良, 毕俊喜, 何荣荣, 等. 基于 Caps-BiGRU-Attention 的直升机涡轮发动机健康管理方法[J/OL]. 航空动力学报, 1-14[2025-05-24]. <https://doi.org/10.13224/j.cnki.jasp.20240775>.
- ZHANG Zhenliang, BI Junxi, HE Rongrong, et al. The health management method of helicopter turbine engine based on Caps-BiGRU-Attention [J/OL]. Journal of Aerospace Power, 1-14 [2025-05-24]. <https://doi.org/10.13224/j.cnki.jasp.20240775>.
- [15] 闵定伟. 基于槽电压小波分析的铝电解非阳极效应过程 PFC 排放调控研究[D]. 江西理工大学, 2023.
- MIN Dingwei. Research on the regulation of PFC emission during the non-anode effect process of aluminum electrolysis base on wavelet analysis of the cell voltage [D]. Jiangxi University of Science and Technology, 2023.
- [16] 陈国华, 王小青, 张志宏, 等. 稀土熔盐电解槽的电压平衡计算[J]. 稀土, 2013, 34(1): 86-89.
- CHEN Guohua, WANG Xiaoqing, ZHANG Zhihong, et al. Calculation of voltage balance of rare earth electrolytic cell [J]. Chinese Rare Earths, 2013, 34(1): 86-89.
- [17] Schneller MC. In Situ alumina feed control [J]. JOM 2009, 61(11): 26-9.
- [18] 沈序章. 铝电解槽电压异常波动的机理及其防治[J]. 轻金属, 2008(9): 31-35.
- SHEN XuZhang. The mechanism of voltage fluctuation in aluminum reduction cell and its precautions [J]. Light Metals, 2008(9): 31-35.
- [19] 丁蕾. 350 kA 预焙铝电解槽故障诊断系统的研究[D]. 北方工业大学, 2006.
- DING Lei. The research of fault diagnosis system for 350 kA pre-baked aluminum reduction cell [D]. North China University of Technology, 2006.
- [20] 肖劲, 李吉力, 杨建红, 等. 系列电流波动对铝电解过程控制的影响[J]. 矿冶工程, 1999(3): 44-46.
- XIAO Jin, LI Jie, YANG Jianhong, et al. Effect of line current fluctuation on process control of aluminium electrolysis [J]. Mining and Metallurgical Engineering, 1999(3): 44-46.
- [21] ZENG Z H, GUI W H, CHEN X F, et al. A cell condition-sensitive frequency segmentation method based on the sub-band instantaneous energy spectrum of aluminum electrolysis cell voltage [J]. Engineering, 2021, 7(9): 190-212.
- [22] 柴立平, 孟壮壮, 石海峡, 等. 基于小波包分解和神经网络集成的滚动轴承故障诊断[J]. 合肥工业大学学报(自然科学版), 2025, 48(4): 447-454.
- CHAI Liping, MENG Zhuangzhuang, SHI Haixia, et al. Rolling bearing fault diagnosis based on wavelet packet decomposition and neural network integrated swarm [J]. Journal of Hefei University of Technology (Natural Science), 2025, 48(4): 447-454.
- [23] 赵国超, 刘崇德, 宋宇宁, 等. 基于特征交叉注意力机制融合的轴承故障诊断方法[J]. 振动与冲击, 2025, 44(12): 228-237.
- ZHAO Guochao, LU Chongde, SONG Yuning, et al. Bearing fault diagnosis method based on fusion of time-frequency features by cross-attention mechanism [J]. Journal of Vibration and Shock, 2025, 44(12): 228-237.
- [24] 谷宇, 苏怀智, 张帅, 等. 基于自适应时序分解筛选的大坝变形预测模型[J]. 水利学报, 2024, 55(9): 1045-1057, 1070.
- GU Yu, SU Huaizhi, ZHANG Shuai, et al. Dam deformation prediction model based on self-adaptive temporal decomposition screening [J]. Journal of Hydraulic Engineering, 2024, 55(9): 1045-1057, 1070.
- [25] AMIRI M H, HASHJIN N M, MONTAZEERI M, et al.

Hippopotamus optimization algorithm: a novel nature-inspired optimization algorithm [J]. *Sci. Rep.*, 2024, 14: 5032.

- [26] 张浩为, 谢军伟, 张昭建, 等. 基于混合遗传-粒子群算法的相控阵雷达调度方法[J]. *系统工程与电子技术*, 2017, 39(9): 1985 - 1991.

ZHANG Haowei, XIE Junwei, ZHANG Zhaojian, et al. Scheduling based on the hybrid genetic particle swarm algorithm for the phased array radar [J]. *Systems Engineering and Electronics*, 2017, 39(9): 1985 - 1991.

Research on state diagnosis method of rare earth molten salt electrolytic cell based on hybrid neural network model

ZHANG Ce¹, YANG Peihong¹, GAO Lele², LYU Donghao¹, PENG Jun³, YANG Zhongfeng¹

(1. School of Automation and Electrical Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China;

2. Inner Mongolia Northern Rare Earth Advanced Materials Technology Innovation Co., Ltd., Baotou 014030, China;

3. School of Rare Earth Industry, Inner Mongolia University of Science and Technology, Baotou 014010, China)

Abstract: Aiming at the problem that the production state of rare earth electrolytic cell is difficult to perceive, which leads to the inability to accurately control it and affects stable production, this study proposes a hybrid neural network diagnosis model based on signal feature extraction to identify the operation state of electrolytic cell. Firstly, the normalized cell voltage signal is obtained by calculating the cell voltage and cell current, and its time-frequency analysis is carried out to extract the energy values and energy ratios of each frequency band with the time-domain and frequency-domain features in different cell states, and to construct the feature data set. Secondly, a cell state diagnosis model (CNN-BiLSTM-SA) combining convolutional neural network (CNN), bidirectional long-term and short-term memory network (BiLSTM) and self-attention mechanism is established. The local spatial features are captured by CNN, the global dependency is modeled by BiLSTM, and the feature relevance is enhanced by the self-attention mechanism to realize the state diagnosis of the electrolytic cell. Simultaneously, improvements were made to the hippo algorithm by incorporating optimal point set initialization alongside crossover and mutation operations, aiming to enhance the algorithm's hyperparameter optimization capabilities. Finally, the improved hippo algorithm is used to optimize the hyperparameters of the model to improve the diagnostic accuracy of the model. Industrial validation experiments demonstrate that the proposed method achieves a diagnostic accuracy of 94.14% and a Macro-F1 score of 91.08% in cell condition diagnosis. Compared to the unoptimized model, these results represent improvements of 8.28% and 14.19%, respectively. It has advantages in diagnosing the state of rare earth molten salt electrolysis cell, and can provide a basis for optimal control and stable operation of rare earth molten salt electrolysis process.

Key words: rare-earth molten salt electrolysis; cell state diagnosis; hybrid neural network; improved hippo algorithm; process optimization control ; stable operation