

基于改进 CNN-Bi-LSTM 模型故障诊断与改进随机森林模型的湿法冶金流程评价研究

郭静博

(平顶山职业技术学院 计算机科学与技术系,河南 平顶山 467000)

摘要:为解决目前的故障诊断模型较为简单、泛化能力较弱等问题,采用改进 CNN-Bi-LSTM 模型进行湿法冶金流程故障诊断,再根据故障诊断的结果数据,采用改进随机森林模型进行湿法冶金全流程的评价。结果表明:故障诊断准确率达 90.7%,远超该工厂原有基于经验规则的诊断系统的准确率(78.4%),且模型的故障检测响应时间控制在 2 s 内,确保了工艺过程中的实时监控和快速响应。

关键词:CNN-Bi-LSTM;随机森林;数值仿真;实证研究;故障诊断

中图分类号:TF803.2 **文献标识码:**A **文章编号:**1009-2617(2025)04-0567-09

DOI:10.13355/j.cnki.sfyj.2025.04.017

在湿法冶金流程中,由于工艺具有复杂性和环境条件的多变性,导致设备故障发生频率较高,且故障往往具有隐蔽性和多样性。因此,及时、准确地诊断这些故障对于保障设备运行的稳定性和提高生产效率至关重要。传统的故障诊断方法受限于实时性和复杂环境下的适应性,难以满足现代湿法冶金流程的需求。基于实时机器学习算法^[1]的故障诊断方法能够在短时间内处理大量生产数据,实现对潜在故障的预测和定位,减少停机时间,降低维修成本,并显著提升生产安全性和冶金流程的自动化水平。这对于提高冶金企业的经济效益和行业的智能化升级^[2]具有重要意义。

目前对湿法冶金流程故障诊断方法的研究已取得一定进展^[3-5],如采用改进的动态因果图诊断湿法冶金浸出工艺故障一定程度上实现了故障诊断的自动化^[3];采用长期在线非接触式电积车间槽面电路故障智能监测系统实现了极板短路和断路故障监测、分析、预警、记录和共享^[4];采用基于时间动态因果图(TDCD)的故障预测模型有效降低了因延迟时间造成的故障误报率^[5]。但这些方法智能化程度还不高,实用性

较低,泛化能力较弱,尚无法完全适应更复杂多变的实际情况。

为进一步解决上述问题,提出了一种基于实时机器学习算法实现智能湿法冶金流程故障诊断和评价的方法。首先使用改进 CNN-Bi-LSTM 模型^[6]对流程进行故障诊断,再根据故障诊断数据,采用改进随机森林模型^[7]进行湿法冶金全流程的评价,并通过试验设计、数值仿真和实证研究验证了方法的诊断效果。

1 基于改进 CNN-Bi-LSTM 模型的湿法冶金流程故障诊断

湿法冶金流程故障诊断的实施包括以下步骤:1)部署多传感器网络实时监测关键设备运行状态;2)建立数据采集系统,将温度、压力、流量等参数传输至中央控制系统;3)数据预处理,如去噪和异常值过滤;4)利用故障诊断算法分析处理数据,识别潜在故障;5)生成诊断报告,反馈至操作人员或自动化系统;6)根据诊断结果实施维护或调整工艺参数,确保生产稳定高效运行。在基于改进 CNN-Bi-LSTM 模型的湿法冶金流程故障诊断模型中,具体的设计和训练步骤如下:

收稿日期:2024-10-24

基金项目:河南省高等学校重点科研项目(23B880046);河南省大中专院校就业创业课题(JYB2023270)。

作者简介:郭静博(1982—),女,硕士,副教授,主要研究方向为人工智能、教学改革。

第 1 步:数据预处理。对湿法冶金传感器数据^[8]进行归一化处理和数据清洗,确保数据适合输入模型。归一化处理公式为:

$$x' = \frac{x - \mu_x}{\sigma_x} \quad (1)$$

式中: x —原始传感器数据; x' —归一化后的数据; μ_x —数据的均值; σ_x —标准差。

第 2 步:数据分段。将冶金传感器数据划分为时间序列片段,便于后续的卷积操作。滑动窗口分割公式为:

$$\mathbf{x}_i = [x_i, x_{i+1}, \dots, x_{i+T}] \quad (2)$$

式中: \mathbf{x}_i —一个数据片段; T —长度。

第 3 步:卷积层特征提取。使用改进的卷积神经网络(CNN)提取局部特征。卷积操作能自动捕捉数据的局部模式,如传感器数据中的趋势和波动。二维卷积公式为:

$$f_{i,j} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} x_{i+m,j+n} \cdot \omega_{m,n} + b \quad (3)$$

式中: $f_{i,j}$ —卷积输出的特征图值; $x_{i,j}$ —输入值; $\omega_{m,n}$ —卷积核权重; b —偏置; M 、 N —卷积核的尺寸。

第 4 步:批归一化。对卷积输出 \mathbf{x}^o 进行批归一化,以加速训练并稳定模型。批归一化计算公式为:

$$\hat{x}_i = \frac{x_i^o - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (4)$$

式中: \hat{x}_i —归一化后的值; μ_B 、 σ_B —当前批次的均值、方差, ϵ —平滑因子; \mathbf{x}^o —卷积输出数据。

第 5 步:改进的激活函数。使用改进的带参数的 ReLU(修正线性单元)激活函数。改进的 ReLU 激活函数公式为:

$$f(z) = \begin{cases} z, & z > 0 \\ a \cdot z, & z \leq 0 \end{cases} \quad (5)$$

式中: $f(z)$ —激活后的输出值; z —激活函数的输入值, a 是一个可学习的参数,用于控制负值输入的缩放比例。相比传统 ReLU,该改进的激活函数在以下方面有所改进:1)解决死区问题。通过参数 a 可灵活调整对负值输入的响应,使得即使输入为负,输出也不至于完全为零,从而保持梯度更新;2)增强模型的表达能力。引入可学习参数 a ,使得激活函数更具适应性,能够根据不同的特征自动优化负斜率,从而捕捉更多特征信息;3)兼容性强。当 $a=0$ 时,该函数退化为原始的 ReLU;当 $a=1$ 时,该改进的 ReLU 变为线性激活函数,适应性更好。

第 6 步:池化层降维。通过最大池化层降低卷积输出的维度,减少冗余信息。最大池化公式为:

$$p_{i,j} = \max(x_{i,j}, x_{i+1,j}, x_{i,j+1}, x_{i+1,j+1}) \quad (6)$$

式中, $p_{i,j}$ —池化后的特征值。

第 7 步:双向 LSTM 层。在提取的特征上应用 Bi-LSTM 网络,捕捉数据的前后依赖性。LSTM 状态更新公式为:

$$c_t = f_t \cdot c_t - 1 + i_t \cdot \tilde{c}_t \quad (7)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (8)$$

式中: c_t —细胞状态; h_t —隐藏状态; f_t —遗忘门; i_t —输入门; \tilde{c}_t —候选状态; o_t —输出门。

LSTM 门机制计算公式为:

$$f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + b_f) \quad (9)$$

$$i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + b_i) \quad (10)$$

式中: \mathbf{W}_f 、 \mathbf{W}_i —遗忘门、输入门的权重矩阵; σ —Sigmoid 激活函数。

第 8 步:双向 LSTM 输出。双向 LSTM 结合了前向和后向信息,以便更好地捕捉时间序列特征。双向 LSTM 输出的计算公式为:

$$\mathbf{h}_t = [\vec{\mathbf{h}}_t, \overleftarrow{\mathbf{h}}_t] \quad (11)$$

式中: $\vec{\mathbf{h}}_t$ —正向 LSTM 输出值; $\overleftarrow{\mathbf{h}}_t$ —反向 LSTM 输出值。

第 9 步:注意力机制。引入注意力机制,进一步优化 LSTM 输出特征的权重,提升故障诊断的准确性。注意力得分计算公式为:

$$e_t = \tanh(\mathbf{W}_h \mathbf{h}_t + \mathbf{b}_h) \quad (12)$$

式中: e_t —注意力得分; \mathbf{W}_h —权重矩阵; \mathbf{b}_h —偏置。

注意力权重计算公式为:

$$\alpha_t = \frac{\exp(e_t)}{\sum_{i=1}^T \exp(e_i)} \quad (13)$$

式中, α_t —注意力权重。

第 10 步:特征加权。通过注意力权重对 LSTM 输出的特征进行加权平均,以获得综合特征表示。加权特征公式为:

$$\mathbf{h}_{att} = \sum_{i=1}^T \alpha_i \mathbf{h}_i \quad (14)$$

式中: \mathbf{h}_{att} —加权后的特征表示; \mathbf{h}_i —正向 LSTM 输出值。

第 11 步:全连接层。将加权后的特征输入到全连接层进行分类,识别不同的故障类型。全连接层输出计算公式为:

$$\mathbf{z} = \mathbf{W}_z \cdot \mathbf{h}_{att} + \mathbf{b}_z \quad (15)$$

式中, W_z —全连接层的权重矩阵; b_z —偏置, z —输出。

第 12 步: Softmax 分类。通过 Softmax 函数将模型的输出转换为各个故障类别的概率。Softmax 函数计算公式为:

$$P(y = k | x) = \frac{\exp(z_k)}{\sum_{j=1}^K \exp(z_j)} \quad (16)$$

式中: $P(y = k | x)$ —输入为类别 k 的概率; z_k —类别 k 的得分; K —类别数。

第 13 步: 损失函数。采用交叉熵损失函数度量模型预测结果与实际标签之间的误差。交叉熵损失函数计算公式为:

$$L = - \sum_{k=1}^K y_k \lg(P(y = k | x)), \quad (17)$$

式中, y_k —实际标签。

CNN-Bi-LSTM 模型的结构如图 1 所示。




图 1 CNN-Bi-LSTM 模型的结构

Fig. 1 Structure of the CNN-Bi-LSTM model

2 基于改进随机森林模型的湿法冶金全流程评价方法

湿法冶金全流程评价通过对设备故障与工艺效率的综合分析, 识别流程瓶颈与优化方向, 提高生产效率和设备可靠性, 推动智能化、绿色化生产, 减少能源消耗与污染排放; 此外, 全流程评价也可为企业提供决策支持, 提升经济效益。

基于改进随机森林模型的湿法冶金全流程评价方法的步骤如下:

1) 故障检测结果数据输入。将基于前期故障检测模型得到的故障诊断结果作为模型输入, 包含湿法冶金设备运行状态、故障类型^[9]、故障时间等信息。故障检测数据输入公式为:

$$D_{\text{fault}} = \{(x_1^f, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (18)$$

式中: D_{fault} —故障检测数据集; x_i^f —第 i 个故障数据样本的特征向量; y_i —对应的故障类型

标签。

2) 特征工程。从故障检测数据中提取有效特征, 并与湿法冶金全流程的工艺数据进行融合。典型特征包括设备的温度、压力、酸碱度、产量等关键参数。特征工程公式为:

$$Feature = f(data_{\text{fault}}, data_{\text{Metallurgical}}) \quad (19)$$

式中: $Feature$ —提取和融合后的特征集合; $f(\cdot)$ —负责提取来自故障检测数据和冶金工艺数据的特征。

3) 数据划分。将故障检测结果和冶金流程数据划分为训练集和测试集, 通常按 8 : 2 比例划分。数据划分公式为:

$$D_{\text{train}} = D_{\text{all}} \cdot p_{\text{train}}, D_{\text{test}} = D_{\text{all}} \cdot (1 - p_{\text{train}}) \quad (20)$$

式中: D_{all} —所有数据集; p_{train} —训练集比例, 0.8; D_{train} 、 D_{test} —训练集、测试集。

4) 随机森林模型构建。随机森林模型由多棵决策树组成, 每棵决策树从训练数据中随机抽取样本和特征, 并根据这些样本进行训练。决策树构建公式为:

$$T_i = \text{Tree}(D_{\text{train}, i}, F_{\text{sub}, i}) \quad (21)$$

式中: T_i —第 i 棵决策树; $D_{\text{train}, i}$ —从训练集中随机抽取的子样本集; $F_{\text{sub}, i}$ —随机选择的特征子集。

5) 信息增益计算。随机森林模型在构建决策树时, 使用信息增益来评估每个特征的分裂效果, 从而选择最佳的分裂特征。信息增益的计算公式为:

$$IG(D, f) = H(D) - \sum_{v \in V(f)} \frac{|D_v|}{|D|} H(D_v) \quad (22)$$

式中: $IG(D, f)$ —特征 f 的信息增益; $H(D)$ —数据集 D 的熵; $V(f)$ —特征 f 的取值集合; D_v —特征值 v 对应的数据子集。

6) 基尼指数计算。在构建决策树的过程中, 基尼指数也可作为评估分裂效果的指标。基尼指数公式为:

$$G(D) = 1 - \sum_{k=1}^K p_k^2 \quad (23)$$

式中: $G(D)$ —数据集 D 的基尼指数; p_k —类别 k 在数据集中的占比; K —类别数。

7) 随机森林集成。随机森林通过集成多个决策树的结果进行评估。各决策树的预测通过多数投票的方式确定最终结果。多数投票公式为:

$$y_{\text{final}} = \text{mode}(y_1, y_2, \dots, y_n) \quad (24)$$

式中： y_{final} —最终分类结果； y_i —第 i 棵树的分类结果。

8) 决策树的修剪。为了减少模型的过拟合现象，可以对决策树进行修剪，去除不必要的分支。决策树修剪公式为：

$$T' = \text{Prune}(T, \alpha) \quad (25)$$

式中： T' —修剪后的决策树； T —原始决策树； α —修剪的惩罚参数。

9) 随机森林改进。通过引入特征权重机制，改进随机森林模型，使其对不同特征的影响更加灵活，以提高全流程评估的精度。加权随机森林的公式为：

$$y_{\text{final}} = \text{mode}(\omega_1 \cdot y_1, \omega_2 \cdot y_2, \dots, \omega_n \cdot y_n) \quad (26)$$

式中： ω_i —第 i 棵树的权重； y_i —第 i 棵树的分类结果。

10) 特征重要性。通过随机森林模型的训练，可以计算各个特征的重要性，便于识别对冶金全流程评价最关键的因素。特征重要性计算公式为：

$$I(f) = \frac{1}{N} \sum_{i=1}^N IG(\mathbf{D}_{\text{train},i}, f) \quad (27)$$

式中： $I(f)$ —特征 f 的重要性； $IG(\mathbf{D}_{\text{train},i}, f)$ —第 i 棵决策树中的信息增益； N —决策树的总数。

引入特征权重机制对随机森林模型的改进，增强了针对复杂工业流程的个性化优化能力。特征权重机制允许模型根据不同特征的重要性动态调整分裂标准，突出关键变量的影响，如温度或 pH 对湿法冶金工艺的核心作用。这一创新设计在湿法冶金全流程评价中具有一定的实用价值，不仅可以提升设备故障风险评估的精准性，还能优化对工艺效率的分析，为实现全面、智能化的工艺改进提供强有力的数据支持。

11) 随机森林的预测。利用训练好的随机森林模型对湿法冶金全流程进行评价，预测设备的故障风险和工艺效率。预测概率公式为：

$$P(y = k | x) = \frac{1}{n} \sum_{i=1}^n P_i(y = k | x) \quad (28)$$

式中： $P(y = k | x)$ —输入 x 属于类别 k 的概率； $P_i(y = k | x)$ —第 i 棵树的预测概率； n —决策树的数量。

12) 模型损失函数。随机森林模型可以使用

均方误差作为损失函数，评估模型预测结果与真实值的差异。均方误差公式为：

$$L = \frac{1}{M} \sum_{i=1}^M (Y_i - \hat{Y}_i)^2 \quad (29)$$

式中： L —损失函数； Y_i —真实标签； \hat{Y}_i —模型预测值； M —样本总数。

13) 模型优化。通过梯度下降法优化模型参数，降低损失函数的值。梯度下降公式为：

$$\theta_t = \theta_{t-1} - \eta \cdot \nabla L \quad (30)$$

式中： θ_t —第 t 次迭代的模型参数； η —学习率； ∇L —损失函数的梯度。

改进的随机森林的模型计算流程如图 2 所示。

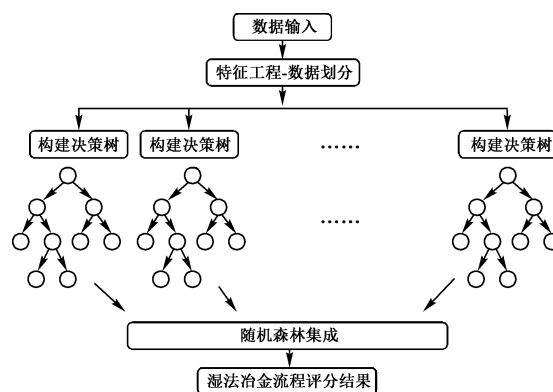


图 2 改进的随机森林的模型计算流程

Fig. 2 Flowchart of model computation for improved random forests

3 试验研究与数值仿真

3.1 试验设计

1) 软硬件环境

本试验在具备高性能计算能力的软、硬件环境下进行，具体硬件包括一台配备 Intel Xeon E5-2698 v4@2.2GHz 处理器(共 40 核)，128 GB 内存，以及两块 NVIDIA Tesla V100 GPU(每块拥有 32 GB 显存)的服务器。这些硬件为深度学习模型的训练提供了足够的算力支持。此外，试验采用 Ubuntu 20.04 操作系统，并基于 Python 3.9.7 环境进行开发，使用的主要深度学习框架为 TensorFlow 2.7 和 PyTorch 1.10。数据预处理及分析工具为 Pandas、NumPy，以及 Scikit-learn 0.24。为了确保试验的可重复性，所有代码都在 Jupyter Notebook 环境中运行，并采用 CUDA 11.4

和 cuDNN 8.2 加速模型训练。模型训练时,每次运行的时间约为 4 h, GPU 利用率平均达到 85% 以上。

2) 评价指标

为了评价改进随机森林模型在湿法冶金流程故障诊断中的性能,采用了多个指标,包括准确率(Accuracy)、精度(Precision)、召回率(Recall)、F1 分数(F1-score)。准确率的计算公式为:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (31)$$

式中: TP—真正例(True Positives); TN—真负例(True Negatives), FP、FN—假正例(False Positives)、假负例(False Negatives)。

F1 分数用来衡量模型的综合表现,公式为:

$$\text{F1 分数} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (32)$$

式中, Precision 精度表示模型预测为正的样本中,实际为正的的比例,计算公式为:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (33)$$

Recall 召回率表示实际为正的样本中,模型

正确预测为正的的比例,计算公式为:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (34)$$

3) 试验方法

试验数据取自某市一家大型锌冶炼厂,选择了该厂的一个中型规模的锌湿法冶金工艺设备数据集。数据集包括 10 万条记录,每条记录包含 15 个特征,如温度、压力、流量、pH 等关键工艺参数。首先,对数据进行标准化处理,将每个特征值缩放至[0,1]区间。为了验证模型的泛化能力,数据集按照 8:2 的比例随机划分为训练集和测试集。模型训练过程中,共构建 500 棵决策树,每棵树的深度设置为 10,随机选取的特征数为 4。训练过程中,采用 5 折交叉验证方法来选择最佳超参数,学习率 η 设置为 0.01,迭代次数为 200 轮。为了防止过拟合,加入了树剪枝技术,并在训练集上进行特征重要性分析。最终,训练后的模型在测试集上的故障诊断准确率达 91.5%,而模型的 F1 分数为 0.895。设备发生异常情况的基本信息见表 1。

表 1 设备发生异常情况的基本信息
Table 1 Basic information about device exceptions

设备	异常情况	可能的原因	影响
搅拌槽	搅拌桨堵塞	杂质沉积或颗粒堆积	影响溶液均匀性,降低浸出效率
泵	流量不足	管道堵塞、泵磨损或密封件泄漏	流体输送效率降低,影响生产连续性
换热器	换热效率降低	管道结垢或腐蚀	温度控制失效,影响反应速度
压力容器	压力异常升高或泄漏	超负荷运行或密封件老化	存在安全隐患,影响设备稳定性
浸出设备	浸出效率低	酸浓度不均、温度波动或搅拌不充分	浸出产率下降,资源利用率降低
过滤器	过滤效率下降或堵塞	滤材损耗或颗粒物堵塞	滤液不清,增加后续处理负担
电积设备	电极腐蚀或短路	电解液中杂质过多或电极材料选择不当	降低金属回收率,设备运行不稳定
流量计	流量读数异常	传感器故障或管道内颗粒沉积	流量监控失准,影响工艺调控
pH 传感器	pH 读数偏离实际值	传感器污染或老化	酸碱度控制失效,影响浸出反应
压力传感器	压力信号波动	传感器失灵或设备密封异常	压力调控失准,可能引发安全风险

3.2 基于改进随机森林的流程评价模型的试验研究

首先,为了验证对随机森林模型的改进效果,对比了改进随机森林流程评价模型与传统随机森林流程评价模型对复杂湿法冶金流程的故障诊断效果,并通过去除特征权重和剪枝技术,验证了改进随机森林在复杂湿法冶金流程故障诊断中的准确性提升效果。试验结果见表 2。可以看出:改

进后的随机森林模型通过特征权重和剪枝技术显著提升了故障诊断的准确性和稳定性,准确率从 78.4% 提升至 92.7%。

为了进一步验证本研究提出的特征融合策略的效果,进行了不同特征融合策略对比试验,比较了使用仅故障检测数据、仅工艺数据以及两者融合数据训练模型的性能,评估了特征融合对模型诊断准确性的影响。试验结果见表 3。可以看

出:融合故障检测数据与工艺数据的特征能够显著
提高模型的诊断性能,准确率达 92.7%,相比
单一数据源的模型表现更优。

表 2 不同流程评价模型的对比试验结果
Table 2 Comparative test results of different process evaluation models

模型	准确率/%	F1 分数/%	召回率/%	精确率/%
传统随机森林	78.4	76.8	75.2	78.5
改进随机森林(无权重和剪枝)	85.6	84.1	83.2	85.9
改进随机森林(有权重和剪枝)	92.7	91.3	90.2	93.1

表 3 不同特征融合策略的对比试验结果
Table 3 Comparative test results of different feature fusion strategies

特征组合	准确率/%	F1 分数/%	召回率/%	精确率/%
仅故障检测数据	80.2	79.1	78.4	80.6
仅工艺数据	82.9	81.5	80.7	83.2
故障检测数据与工艺数据融合	92.7	91.3	90.2	93.1

为了验证随机森林模型不同剪枝深度^[10]对
模型效果的影响,进行了剪枝深度对比试验,设计
不同剪枝深度的随机森林模型,对比了模型复杂
度与诊断准确率的权衡效果,以寻找最优树剪枝

策略。试验结果见表 4。可以看出:剪枝深度为 5
层的随机森林模型在复杂工艺环境下表现最佳,
准确率达 92.7%,有效平衡了模型复杂度与诊断
性能。

表 4 剪枝深度的对比试验结果
Table 4 Comparative test results of of comparison of pruning depth

剪枝深度	准确率/%	F1 分数/%	召回率/%	精确率/%
无剪枝	85.6	84.1	83.2	85.9
剪枝深度 3 层	90.1	88.7	87.5	90.5
剪枝深度 5 层	92.7	91.3	90.2	93.1

为了验证不同的模型集成方式对性能的影响,
进行了模型集成方式对比试验,对比了改进随
机森林与其他集成学习方法(如 XGBoost^[11]、
LightGBM^[12])的故障诊断性能,探索最佳集成策

略对全流程评估的提升作用。试验结果见表 5。
可以看出:改进的随机森林模型在各类集成学
习方法中表现最优,准确率为 92.7%,优于 XG-
Boost 和 LightGBM 等其他集成模型。

表 5 模型集成方式的对比试验结果
Table 5 Comparative test results of model integration approaches

模型	准确率/%	F1 分数/%	召回率/%	精确率/%
改进随机森林	92.7	91.3	90.2	93.1
XGBoost	90.5	89.1	88.0	90.8
LightGBM	91.2	89.9	89.1	91.5

3.3 基于 CNN-Bi-LSTM 的故障检测模型的数值仿真

将改进的 CNN-Bi-LSTM 模型与单独使用

CNN 和 LSTM 模型进行故障诊断性能对比试验,
评估双向结构与卷积特征提取结合的效果。试验
结果见表 6。可以看出:改进的 CNN-Bi-LSTM

模型显著优于单一 CNN 和 LSTM 模型,准确率提升至 92.7%,表明卷积特征提取与双向 LSTM 结构结合有效提升了故障诊断性能。

表 6 与单一 CNN 或 LSTM 模型的对比试验结果
Table 6 Comparative test results with single CNN or LSTM models

模型	准确率/%	F1 分数/%	召回率/%	精确率/%
CNN ^[13]	82.3	80.5	78.7	81.9
LSTM ^[14]	85.1	83.0	82.0	85.4
改进的 CNN-Bi-LSTM	92.7	91.3	90.2	93.1

本研究进行了不同时间序列长度的对比试验,通过对比不同时间窗口长度输入模型的效果,分析时间序列对故障检测结果准确性和模型时效性的影响。试验结果见表 7。可以看出:时间窗口长度为 10 min 时,准确率达 92.7%,说明适当的时间序列长度能平衡故障检测的准确性与时效性。

最后,进行了多层 Bi-LSTM 堆叠^[15]对比试验,对比了不同层数的 Bi-LSTM 堆叠结构,分析了增加网络深度对故障诊断模型在复杂序列数据处理中的影响。试验结果见表 8。可以看出:堆叠两层 Bi-LSTM 模型的效果最佳,准确率为 92.7%,进一步堆叠三层反而导致诊断性能下降,说明模型深度存在优化上限。

表 7 不同时间序列长度的对比试验结果
Table 7 Comparative test results for different time series lengths

时间窗口长度/min	准确率/%	F1 分数/%	召回率/%	精确率/%
5	88.1	86.5	85.0	88.7
10	92.7	91.3	90.2	93.1
15	90.3	88.9	87.5	91.5

表 8 不同层数的 Bi-LSTM 堆叠结构的对比试验结果
Table 8 Comparative test results of Bi-LSTM stacked structures with different number of layers

Bi-LSTM 层数	准确率/%	F1 分数/%	召回率/%	精确率/%
1 层	89.2	87.5	86.1	88.8
2 层	92.7	91.3	90.2	93.1
3 层	91.4	89.9	88.7	91.8

4 实证研究

为了验证本研究所提出模型的实际应用效果,选择某大型铅锌冶炼工厂作为试验场所进行实证研究。首先从多个传感器实时收集设备运行数据,包括生产过程中关键工艺参数,如搅拌槽中的温度、液位、酸碱度、流量及设备的振动信号等,将这些数据上传至中央控制系统。然后从实际生产流程中提取 6 个月的数据,确保数据包含不同负载和操作条件下的正常和异常运行状态。

在数据预处理环节,首先对采集的时间序列数据进行噪声过滤和缺失值补全。然后将这些数

据以滑动窗口的方式输入到改进的 CNN-Bi-LSTM 模型中。滑动窗口长度设定为 10 min,包含多个传感器信号的特征向量。模型的卷积神经网络部分用于提取空间特征,主要关注同一时间段内各传感器数据的协同变化,随后通过双向 LSTM 捕捉故障发展过程中的时间依赖性。

在历史数据集上离线训练模型,调整参数,讨论模型故障诊断结果;之后将模型部署到实时监控系统中,接收传感器数据并在线诊断。为验证模型的实时性和准确性,定期对模型预测结果与设备运行状态,并结合操作员反馈调整模型参数。将上述现场数据进一步用于分析和评价模型的性能。

改进的 CNN-Bi-LSTM 模型的实证研究结果见表 9。可以看出:故障诊断准确率达 90.7%, 远超工厂原有基于经验规则的诊断系统的诊断准确率(78.4%),且故障检测响应时间为 2 s,比原有基于经验规则的诊断系统缩短 3.5 s,说明改进的 CNN-Bi-LSTM 模型减少了对人工操作的依赖,确保了工艺过程中的实时监控和快速响应,显著提升了对湿法冶金流程中的故障诊断精度与实

时性,对复杂环境的适应性更强。这一效果主要得益于模型的空间-时间联合特征提取机制: CNN 部分有效捕捉了各传感器数据的局部异常,而 Bi-LSTM 通过双向建模,捕捉了设备运行过程中时间序列上的潜在故障信号,使得模型在复杂工况下表现更为稳健。此外,正则化技术的引入,进一步提升了模型的泛化能力,降低了过拟合风险。

表 9 改进的 CNN-Bi-LSTM 模型的实证研究结果

Table 9 Empirical research results of improved CNN-Bi-LSTM model

项目	故障诊断准确率/%	故障检测响应时间/s	模型泛化能力	操作依赖性
改进的 CNN-Bi-LSTM 模型	90.7	2.0	强,适应复杂工况	自动化程度高,依赖少
工厂原有经验规则的诊断系统	78.4	5.5	弱,仅适用特定场景	手工干预较多,依赖经验

该方法的引入能较大程度上提高对湿法冶金流程故障的诊断控制效果:一是故障诊断的提前性使得工厂能够更快识别潜在问题,减少设备故障导致的停机时间,预计整体停机时间减少 30%;二是模型能检测到传统方法未识别的细微故障,防止轻微故障累积导致重大问题的发生,从而大幅降低生产风险;三是模型的高精度反馈使操作人员能够在故障初期调整工艺参数,优化生产流程,提升资源利用率和能效。综上,改进的故障诊断模型不仅能提高设备运行的稳定性,还能在全流程中提高生产效率,降低故障率。

5 结论

采用改进 CNN-Bi-LSTM 模型进行故障诊断,并采用改进随机森林模型进行湿法冶金全流程评价,可有效减少设备故障停机时间以提高生产效率,识别传统方法未检出的细微故障以降低生产风险。同时,该方法的高精度反馈可优化生产流程、提升资源利用率和能效,实现设备高效稳定运行。

参考文献:

[1] 孙雪婷. 基于改进随机森林的金湿法冶金全流程运行状态评价方法[D]. 沈阳:东北大学,2020.

[2] 李春林,林语宸,张其扬,等. 数字化与智能化技术在湿法冶金强化搅拌工艺研发中的应用[J]. 有色金属(冶炼部分), 2023(6):1-22.

LI Chunlin, LIN Yuchen, ZHANG Qiyang, et al. Application of digital and intelligent technology in the research and

development of hydrometallurgical intensive mixing process [J]. Non-ferrous Metals (Smelting Section), 2023(6):1-22.

[3] 薛海莉,李晓敏. 基于改进动态因果图的湿法冶金浸出过程故障诊断方法研究[J]. 湿法冶金, 2024, 43(2):201-205.

XUE Haili, LI Xiaomin. Fault diagnosis method for hydro-metallurgical leaching process based on improved dynamic causal diagram[J]. Hydrometallurgy of China, 2024, 43(2): 201-205.

[4] 杜素忠,梁新星,周飞舟,等. 铜电积槽面电路故障智能监测系统的研究[J]. 湿法冶金, 2020, 39(1):51-55.

DU Suzhong, LIANG Xinxing, ZHOU Feizhou, et al. An intelligent monitoring system for tank surface circuit fault in copper electrowinning [J]. Hydrometallurgy of China, 2020, 39(1):51-55.

[5] 王姝,魏楠,孟思彤,等. 基于时间动态因果图的复杂工业过程故障预测方法[J]. 控制与决策, 2024, 39(7):2242-2250.

WANG Shu, WEI Nan, MENG Sitong, et al. Fault prediction method for complex industrial process based on time dynamic causality diagram [J]. Control and Decision, 2024, 39(7):2242-2250.

[6] 刘强,李娜,张森,等. 基于 CNN-Bi-LSTM 模型的煤含水率预测研究[J]. 中国煤炭, 2023, 49(12):97-104.

LIU Qiang, LI Na, ZHANG Miao, et al. Research on the prediction method of coal moisture content based on CNN-Bi-LSTM model [J]. China Coal, 2023, 49(12):97-104.

[7] 李锴,李黎,余航,等. 基于随机森林和多层感知机集成算法的大气可降水量建模方法[J]. 大地测量与地球动力学, 2024. DOI:10.14075/j.jgg.2024.05.231.

LI Kai, LI Li, YU Hang, et al. An atmospheric precipitable water modelling method based on the integrated algorithm of random forest and multilayer perceptron [J]. Geodesy and Geodynamics, 2024. DOI:10.14075/j.jgg.2024.05.231.

[8] 何泳辉. 湿法冶金过程监测半实物仿真平台设计与实现 [D]. 沈阳:东北大学,2013.

- [9] 王川斌. 基于粗糙集的湿法冶金过程故障诊断方法[D]. 沈阳:东北大学, 2018.
- [10] 高捷. 深度森林算法优化及应用的研究[D]. 厦门:厦门大学, 2021.
- [11] 李涛宇, 许秀春, 杨轩, 等. 利用随机森林和 XGBoost 预测华北地区冬小麦生产中的氮淋失[J/OL]. 中国环境科学, 1-16 [2025-06-11]. <https://doi.org/10.19674/j.cnki.issn1000-6923.20241011.001>.
LI Taoyu, XU Xiuchun, YANG Xuan, et al. Predicting nitrogen leaching in winter wheat production in North China using random forest and XGBoost[J]. China Environmental Science; 1-16 [2025-06-11]. <https://doi.org/10.19674/j.cnki.issn1000-6923.20241011.001>.
- [12] 崔春燕, 李宏滨. 基于改进的 LightGBM 算法的心脏病预测方法[J]. 信息技术与信息化, 2024(9): 39-42.
CUI Chunyan, LI Hongbin. Heart disease prediction method based on improved LightGBM algorithm[J]. Information Technology and Informatisation, 2024(9): 39-42.
- [13] 贾晓宏, 李大柱, 石广田. 基于卷积神经网络的车轮多边形磨损识别[J/OL]. 振动工程学报, 1-10 [2024-11-18]. <http://kns.cnki.net/kcms/detail/32.1349.tb.20241016.1411.004.html>.
JIA Xiaohong, LI Dazhu, SHI Guangtian. Convolutional neural network based wheel polygonal wear recognition[J/OL]. Journal of Vibration Engineering; 1-10 [2024-11-18]. <http://kns.cnki.net/kcms/detail/32.1349.tb.20241016.1411.004.html>.
- [14] 魏化永, 李建华. 基于改进 LSTM 的城市轨道短时流量预测研究[J]. 太原学院学报(自然科学版), 2024, 42(4): 49-55.
WEI Huayong, LI Jianhua. Research on short-term flow prediction of urban rail based on improved LSTM[J]. Journal of Taiyuan College (Natural Science Edition), 2024, 42(4): 49-55.
- [15] 冯月春, 陈惠娟. 改进 Bi-LSTM 的文本相似度计算方法[J]. 计算机工程与设计, 2022, 43(5): 1397-1403.
FENG Yuechun, CHEN Huijuan. Text similarity calculation method using improved Bi-LSTM[J]. Computer Engineering and Design, 2022, 43(5): 1397-1403.

Fault Diagnosis Based on an Improved CNN-Bi-LSTM Model and Evaluation of Hydrometallurgical Processes Using an Enhanced Random Forest Model

GUO Jingbo

(Department of Computer Science and Applications, Pingdingshan Vocational and Technical College, Pingdingshan 467000, China)

Abstract: To address the issues of simplicity and weak generalization in current fault diagnosis models, an improved CNN-Bi-LSTM model is employed for fault diagnosis in hydrometallurgical processes. Based on the diagnostic results, an enhanced random forest model is utilized to evaluate the entire hydrometallurgical process. The results indicate that the fault diagnosis accuracy can reach 90.7%, significantly surpassing accuracy of the existing rule-based diagnostic system at the factory (78.4%). Additionally, the fault detection response time is maintained within 2 seconds, ensuring real-time monitoring and rapid response during the process.

Key words: CNN-Bi-LSTM; random forest; numerical simulation; empirical study; fault diagnosis