

引文格式:孙海东,段宏,王嵩岭. 基于改进 CNN 和 RIME-SVM 的小样本艾萨炉喷枪故障识别方法[J]. 中国有色冶金, 2025,54(6): 39-51.

SUN Haidong, DUAN Hong, WANG Songling. Few-shot fault identification method of Isasmelt furnace lance based on improved CNN and RIME-SVM[J]. China Nonferrous Metallurgy, 2025,54(6): 39-51.

基于改进 CNN 和 RIME-SVM 的小样本艾萨炉喷枪故障识别方法

孙海东,段宏,王嵩岭

(昆明理工大学机电工程学院,云南昆明 650500)

[摘要] 针对铜熔池熔炼过程中艾萨炉喷枪易出现故障,且小样本故障数据识别准确率较低问题,本文提出了一种基于指数线性单元(ELU)、全局平均池化(GAP)的卷积神经网络(EGCNN)和霜冰优化算法(RIME)优化支持向量机(SVM)的小样本艾萨炉喷枪故障识别方法。首先,采用 ELU 作为卷积神经网络(CNN)的激活函数,以提高对艾萨炉喷枪数据噪声和输入变化的鲁棒性,加快模型收敛;其次,为增强艾萨炉喷枪工艺参数与故障类别之间的相关性,减少模型参数,避免过拟合,采用 GAP 替代全连接(FC)层;最后,引入 SVM 替代传统的 Softmax 函数作为最终分类器,并通过 RIME 对 SVM 的惩罚因子和核函数参数寻优,进一步提高艾萨炉喷枪故障识别模型的准确率。结果表明,该方法在艾萨炉喷枪故障识别的准确率、精确率、召回率、 F_1 -score 和 Kappa 系数分别为 97.08%、97.08%、97.10%、97.07% 和 0.9611,因此,所提出的方法在故障识别性能上表现更为优越,准确率较高。

[关键词] 艾萨炉喷枪;故障识别;卷积神经网络;霜冰优化算法;支持向量机

[中图分类号] TF806.2; TP183 [文献标志码] A [文章编号] 1672-6103(2025)06-0039-13

DOI:10.19612/j.cnki.cn11-5066/tf.2025.06.004

艾萨炼铜法作为一种高效的顶吹浸没熔池熔炼技术,通过喷枪顶吹富氧空气来增强熔体混合,加速化学反应,借助铜精矿中铁、硫氧化放热实现高效熔炼^[1]。此方法建设投资低、生产率高、原料适应性广以及自动化程度高等优点,在铜冶炼工艺中有着广泛的应用^[2]。艾萨铜熔池熔炼过程中,艾萨炉喷枪作为核心设备之一,不仅负责输送富氧空气,还负责对熔渣层进行剧烈搅拌,增强熔炼过程的传质传热的效率^[3]。艾萨炉喷枪故障会严重影响艾萨炉的作业率,更换喷枪不仅导致停产时间增长,还会产生更高的维修费用,其稳定运行对产品质量的保障

至关重要^[4-5]。因此,降低故障的发生成为提高铜熔池熔炼作业率的核心因素之一,对艾萨炉喷枪故障进行精准识别尤为关键。

基于数据驱动的工业设备故障识别已成为主流研究方法。传统的机器学习故障识别方法有:随机森林^[6]、支持向量机^[7]、人工神经网络^[8]等。TAO Peng 等^[9]介绍了一种基于随机森林改进的光梯度提升机(LightGBM)算法,以解决智能电表稳定运行和故障分类问题,从而提高故障预测和分类的准确性和效率。XUE Feng 等^[10]提出了一种基于双流特征融合卷积神经网络(TSFFCNN)和粒子群优化支持向量机(PSO-SVM)的新型滚动轴承智能故障诊断方法,实现了高准确率、快速收敛和较低计算成本的故障识别。YANG Liyuan 等^[11]提出了一种基于主成分分析(PCA)优化的鲸鱼算法(WOA)优化支持向量机(SVM)方法,用于高压断路器的故障识别,显著提高了识别精度和效率。WEI Yanfang

[收稿日期] 2024-12-26 [修订日期] 2025-02-07

[录用日期] 2025-02-11 [出版日期] 2025-12-01

[第一作者] 孙海东(1998—),男,硕士研究生。研究方向为智能制造、故障识别、故障预测等。

[基金项目] 国家自然科学基金项目(52065033);云南省重大科技项目(202202AG050002)。

等^[12]针对柔性直流电网提出了一种基于完整集合经验模式分解与自适应噪声分析 (CEEMDAN) 多尺度熵 (MSE) 和遗传算法优化支持向量机 (GA-SVM) 的故障识别方法,显著提高了故障检测的准确性和抗干扰能力。

传统的机器学习方法是基于“浅层学习”的方法,表达能力有限,故障特征提取困难,且比较依赖于故障识别专家的经验 and 知识。而深度学习^[13]方法具有较强的表达能力,故障特征提取能力更强,可自动提取故障特征。卷积神经网络 (CNN)^[14]作为深度学习中的典型方法之一,能够直接处理原始数据,逐层提取复杂的非线性特征与细微特征,同时能在特征提取过程中保持信息完整性,具备高效的特征提取性能,被广泛应用在故障识别任务中。雷春雨等^[15]提出了一种基于自校正卷积神经网络 (SC-CNN) 的方法,通过引入 BN 算法、自校正卷积和通道自注意力机制,解决了小样本滚动轴承故障识别中的低识别准确率问题,提升了在强噪声和变工况条件下的鲁棒性与泛化性能。田鹏飞等^[16]介绍了一种集成了 CNN 和 SVM 的高压输电线路故障识别算法,旨在提高故障特征提取的准确性。李冬辉等^[17]将 CNN 与门控递归单元 (GRU) 相结合,优化了时间序列特征的提取和建模,显著提高了冷水机系统中传感器偏差故障识别的准确性。宋庭新等^[18]提出了一种结合离散小波变换 (DWT) 与二维卷积神经网络 (2D-CNN) 小样本下的齿轮故障识别方法,通过小波能量与神经网络分类标签的权值分配机制,以及信号增量和图像变换技术,有效解决了小样本数据中噪声干扰和数据不足的问题,提升了齿轮故障识别的准确性与泛化能力。CNN 在故障识别中表现出色,通常依赖于大量的数据集,然而,在工业设备故障识别领域,故障样本数量有限,会导致 CNN 模型训练时出现收敛缓慢、参数过多和过拟合的问题。此外,CNN 的 Softmax 分类器在处理非线性问题时效果并不理想,并会限制模型的泛化性能。

针对以上不足,本文提出了一种基于指数线性单元 (ELU)、全局平均池化 (GAP) 的卷积神经网络 (EGCNN) 和霜冰优化算法 (RIME) 优化 SVM 的小样本艾萨炉喷枪故障识别方法。在故障特征提取阶段,对 CNN 模型进行适应性改进和集成以更好提取小样本艾萨炉喷枪数据的故障特征。为加快模型的

收敛速度,提高对艾萨炉喷枪数据中噪声和输入变化的鲁棒性,使模型更加稳定,采用 ELU 作为激活函数;为增强艾萨炉喷枪工艺参数与故障类别之间的相关性,减少故障提取的模型参数,避免过拟合,使用全局平均池化层替代全连接层。在故障分类阶段,使用 SVM 取代 Softmax 分类器,并采用霜冰优化算法对 SVM 的惩罚因子 λ 和核参数 σ 寻优,进一步提高故障识别精度。实验结果表明,通过对 CNN 模型适应性改进和集成,并与 RIME 优化后的 SVM 模型相结合,解决了小样本艾萨炉喷枪故障识别准确率低的问题。

1 问题分析

艾萨铜熔池熔炼时,原料通过炉顶加入炉内,与喷枪顶吹的富氧空气混合,发生强烈的化学反应,生成冰铜和炉渣的混合熔体。艾萨炉及喷枪结构示意图如图 1 所示,其中,喷枪是整个工艺流程的核心组件,其头部浸入熔池中,由内部旋流器将气体动能高效传递至熔池内部,形成强烈的湍流搅拌,促进熔体混合和化学反应,加速精矿粉的熔化和硫化物的氧化。对艾萨炉喷枪进行故障识别是确保艾萨炉稳定运行、提高生产效率、保障安全、降低成本的重要措施。

为确保艾萨炉喷枪的稳定运行与高效作业,亟需对影响艾萨炉喷枪寿命的关键工艺参数进行深入分析以及故障类型进行准确识别。影响艾萨炉喷枪寿命的工艺参数包括喷枪供氧管压力、喷枪供氧管氧气流量、喷枪供氧管氧气温度等,这些数据可通过传感器进行采集,但采集到的大部分为正常状态数据,故障数据量比较少。由于传统的深度学习模型包含大量参数,会使模型训练不充分、模型训练时间长、过拟合及收敛速度慢,难以捕捉到足够的故障特征信息,影响识别准确率,因此本文提出 EGCNN-RIME-SVM 的小样本艾萨炉喷枪故障识别方法。

2 EGCNN-RIME-SVM 故障识别网络模型

2.1 EGCNN-RIME-SVM 网络结构

艾萨炉喷枪故障识别网络 EGCNN-RIME-SVM 分为两部分:首先,利用 EGCNN 网络对艾萨炉喷枪的工艺参数进行故障特征提取,充分发挥其较少参数、较低过拟合以及模型收敛快的优势;其次,采用




图 1 艾萨炉及喷枪结构示意图

Fig.1 Schematic diagram of the structure of Isasmelt furnace and Isasmelt furnace lance

RIME 优化算法对 SVM 中的惩罚因子 λ 和核参数 σ 进行寻优,以提高分类准确率,通过训练好的 SVM 模型实现对艾萨炉喷枪的故障识别,如图 2 所示。

2.2 EGCNN 故障特征提取

CNN 在故障特征提取方面具备出色的学习和表达能力,在大数据环境下的故障识别方面有较广泛的应用^[19-20]。该模型由输入层、隐藏层及输出层三部分组成,其中隐藏层包含卷积层、池化层和全连

接层^[21]。卷积层和池化层用于提取局部故障特征,激活函数引入非线性故障特征,多层堆叠可提高故障特征抽象程度,而全连接层将提取得到的高维故障特征进行扁平化处理展开为一维故障特征向量^[22-23]。

然而当前小样本艾萨炉喷枪故障识别面临两大挑战,首先,喷枪训练数据量不足,缺乏充分的故障样本,导致传统 CNN 模型无法有效学习并提取关键




图 2 EGCNN-RIME-SVM 艾萨炉喷枪故障识别模型结构

Fig.2 Model structure of fault identification for Isasmeltsmelt furnace lance based on EGCNN-RIME-SVM

特征,进而影响最终识别精度;其次,为提升故障特征提取能力,传统 CNN 模型中的全连接层因参数多以及训练数据不足出现过拟合训练数据,造成过拟合问题。为解决上述问题,本文提出了一种改进的卷积神经网络(EGCNN)对艾萨炉喷枪数据故障特征提取,其采用了 ELU 激活函数和全局平均池化策略。其基本结构如图 3 所示。EGCNN 模型利用四个卷积模块自适应提取艾萨炉喷枪故障特征,使

用 ELU 替代 ReLU 激活函数,提高对艾萨炉喷枪数据噪声和输入变化的适应能力,同时加快故障特征提取模型的收敛,有效提取小样本下喷枪故障关键特征。通过将全局平均池化层替代全连接层,可减少故障特征提取模型参数,避免过拟合,增强艾萨炉喷枪工艺参数与故障类别之间的相关性,实现艾萨炉喷枪的故障特征提取。从而提高 EGCNN 故障特征提取模型的准确率和稳定性。




图 3 EGCNN 网络结构图

Fig.3 EGCNN network structure diagram

2.2.1 指数线性单元 ELU

ELU 结合了 ReLU 和 Sigmoid 函数的优点^[24]。图 4 为 ELU 与 ReLU 激活函数的对比图,由图可看出,ELU 在负区间具有软饱和特性,提高了对艾萨炉喷枪输入变化和噪声的鲁棒性^[25],而正区间在模型训练时可缓解梯度消失;同时,ELU 的平均输出值接近于零,加快了艾萨炉喷枪故障特征提取模型的收敛速度。ELU 的表达式见式(1)。

$$ELU(x) = \begin{cases} \alpha(\exp(x) - 1), & x < 0 \\ x, & x \geq 0 \end{cases} \quad (1)$$

图 5 为在小样本下的艾萨炉喷枪数据上,CNN 模型分别采用 ELU、ReLU、Tanh 和 Sigmoid 四种激活函数时的训练准确率变化情况。由图 5 可见,Tanh 和 Sigmoid 的收敛速度相对较慢,并且训练效果显著低于 ReLU 和 ELU。使用 ELU 激活函数时,模型在 6 轮训练后准确率可达 100%;而使用 ReLU 激活函数则需 16 轮训练才能达到同样的准确率。表明 ELU 激活函数能够加快艾萨炉喷枪故障特征提取模型的收敛速度。

因此采用 ELU 作为激活函数来加快模型的收




图 4 ELU 与 ReLU 激活函数对比

Fig.4 Comparison between ELU and ReLU activation functions

敛速度,提高对小样本艾萨炉喷枪数据故障特征提取能力,使模型更加稳定。

2.2.2 全局平均池化 GAP

全连接层和全局平均池化层的结构图如图 6 所示,采用了 GAP 层对最后一个池化层的输出故障特征图进行了空间平均操作。相比于全连接层,GAP 层取代了 2~3 层的全连接层,减少了网络的参数数量和计算量,提升了模型的效率,在小样本艾萨炉喷




图 5 不同激活函数下模型的训练曲线

Fig. 5 Training curves of the model with different activation functions

枪数据下,有效避免了过拟合问题,使得学习到的故障特征更具有鲁棒性^[26]。此外,GAP层能够增强艾萨炉喷枪工艺参数与故障类别之间的相关性。因此采用 GAP 层代替全连接层。




图 6 全连接层和全局平均池化层结构图

Fig. 6 The structure diagram of the full connection layer and the global average pooling layer

2.3 RIME-SVM 故障识别模型

2.3.1 支持向量机 SVM

在传统 CNN 模型中,末端分类器采用的是 Softmax 函数,其本质是通过一次归一化输出将喷枪故障分类结果转化为概率分布,但其分类性能易受样本量和类别分布的影响,当面临小样本喷枪数据时,易产生类别不平衡问题,导致模型偏向于多数类,难

以进一步提升最终故障识别准确率。因此,采用 SVM 代替 Softmax 函数作为最终喷枪故障分类器。

SVM 是一种广泛应用于分类识别问题的监督算法,能够在有限的艾萨炉喷枪故障数据样本条件下获得最优解,通过在不同类样本的空间中建立分隔的超平面来完成喷枪数据样本的划分^[27]。因此,本文选择 SVM 对艾萨炉喷枪进行最终故障识别。

给出一个包含 N 个训练样本的集合 $S, S = \{(x_i, y_i), i = 1, 2, \dots, N\}$ 其超平面的分类表达式见式(2)。

$$f(x) = \omega \cdot \beta(x) + b \quad (2)$$

式中: ω 表示权重向量,决定超平面的方向; $\beta(x)$ 表示非线性函数; b 表示超平面的平移距离,决定了超平面与点之间的距离。

SVM 定义式(3)所示优化问题。

$$\min J = \frac{1}{2} \omega^T \omega + \frac{1}{2} \lambda \sum_{i=1}^N \xi_i^2, \lambda > 0 \quad (3)$$

式中: λ 表示惩罚因子。

约束条件见式(4)。

$$y_i = \omega \beta(x_i) + b + \xi_i, i = 1, 2, \dots, N \quad (4)$$

通过引入拉格朗日乘子和满足摩西条件的核函数后,得到最终的决策函数见式(5)。

$$f(x) = \omega \cdot \beta(x) + b = \sum_{i=1}^N \alpha_i y_i \beta^T(x_i) \beta(x_j) + b = \sum_{i=1}^N \alpha_i y_i K(x, x_i) + b \quad (5)$$

式中: N 表示训练集数量; α_i 表示拉格朗日乘子; y_i 表示训练集或测试集的输出; $K(x_i, x_j)$ 表示核函数。

高斯径向基函数(RBF)以其局部逼近能力,能够实现将艾萨炉喷枪样本变换至更高维度的特征空间,其表达式见式(6)。该核函数被广泛应用,并且在处理小样本数据时表现出良好的性能。此外,其还具有较强的抗干扰能力,能够有效应对故障数据中存在的噪声。本文选择 RBF 来构建 SVM。这一选择使得 RIME 优化的参数数量最小化,仅包括惩罚因子 λ 和核参数 σ 。

$$K(x_i, x_j) = \exp \left(-\frac{x_i - x_j^2}{2\sigma^2} \right), \sigma > 0 \quad (6)$$

2.3.2 霜冰优化算法 RIME

霜冰优化算法(RIME)是由 Su Hang 等^[28]在 2023 年提出的一种基于霜冻生长行为的元启发式优化算法,该算法具有快速收敛和高精度的优点,包

括软霜搜索策略、硬霜穿刺机制、贪婪选择机制三个阶段。

1) 软霜冰搜索策略。该算法通过模拟软霜粒子的运动,实现在大范围内的随机探索,有助于迅速发现潜在的最优解区域,同时降低陷入局部最优的风险。通过式(7)可以计算霜冰粒子的位置,参数 θ 、 β 、 E 的表达式见式(8)~(10)。

$$R_{ij}^{\text{new}} = R_{\text{best},j} + r_1 \cos \theta \times \beta \times (h \times (Ub_{ij} - Lb_{ij}) + Lb_{ij}), \quad r_2 < E \quad (7)$$

$$\theta = \pi \cdot \frac{t}{10 \cdot T_2} \quad (8)$$

$$\beta = 1 - \left[\frac{w \cdot t}{T_2} \right] / w \quad (9)$$

$$E = \sqrt{(t/T_2)} \quad (10)$$

式中: R_{ij}^{new} 是更新霜冰粒子的新位置; i 和 j 表示第 i 个霜冰晶体中的第 j 个粒子; $R_{\text{best},j}$ 是霜冰群体 R 中最佳霜冰晶体的第 j 个粒子;参数 r_1 是在 $(-1,1)$ 范围内的随机数; $\cos \theta$ 随着迭代次数而变化,如式(8)所示,其中 t 是当前迭代次数, T_2 是最大迭代次数; β 是环境因子(式(9)),其中 w 的值默认为5, $[]$ 表示舍入运算, h 表示粘附度,为 $(0,1)$ 范围内的随机数, Ub_{ij} 和 Lb_{ij} 分别是空间的上界和下界; E 是被附着的系数,随着迭代次数的增加而增加,如式(10)所示; r_2 是在 $(0,1)$ 范围内的随机数,其与 E 一起控制粒子位置是否更新。

2) 硬霜穿刺机制。该算法通过模拟硬霜粒子之间的交叉行为,实现维度间的信息交换,进一步提升解的精确度。霜冰粒子之间的置换公式如式(11)所示。

$$R_{ij}^{\text{new}} = R_{\text{best},j}, r_3 < F^{\text{normr}}(S_i) \quad (11)$$

式中: r_3 是 $(-1,1)$ 范围内的随机数; S_i 代表霜冰晶体; $F^{\text{normr}}(S_i)$ 表示当前霜冰晶体适合度值的归一化值。

3) 贪婪选择机制。算法比较霜冰晶体更新前后的适应度值,若更新后更优,则替换更新前的值。

2.3.3 RIME 优化 SVM 参数

采用 RIME 算法来寻找 SVM 的最佳惩罚因子和核参数 σ ,流程如图7所示。

3 实验验证

3.1 实验数据

本研究基于某冶炼厂铜熔池熔炼过程中的艾萨




图7 RIME 优化 SVM 参数流程图

Fig. 7 RIME optimization SVM parameters flow chart

炉喷枪故障数据进行分析,旨在深入研究喷枪的常见故障类型。通过长期的实践和观察,艾萨炉喷枪主要存在以下三种故障类型:喷枪端部烧损、喷枪端部管壁烧穿以及喷枪旋流器烧损。喷枪端部烧损的成因包括喷枪过度插入熔池、在冰铜层操作时间过长导致的侵蚀及高温环境下不锈钢材料性能的退化;喷枪端部管壁烧穿的成因则为油孔堵塞、炉温异常以及喷枪内壁燃烧不均匀;喷枪旋流器烧损通常由于喷枪下放速度过快、熔渣飞溅或熔渣温度过高所引发。研究中将这三种故障类型标注为1、2、3,正常数据标注为0。

在艾萨炉喷枪的故障分析中,选择影响艾萨炉

喷枪寿命的 18 个工艺参数,包括喷枪供氧管压力 (PT1211),喷枪供氧管氧气流量 (FT_1213),喷枪供风管空气温度 (TE1224),喷枪供氧管氧气温度 (TE1214),喷枪供风管供风流量 (FT_1223),喷枪供风管压力 (PT1222M),喷枪供风管流量调节 (FIC1223. MV),供风管排空压力调节 (PIC1222. MV),风机出口总管流量 (FT_1712),喷枪油管吹扫

压力 (PT1239),喷枪荷重 (HZ9),喷枪背压 (PT1229),燃油系统出口压力 (PT1721),回油总管压力调节 (PIC1721. MV),喷枪供油量调节 (FIC1233A. SV),喷枪距炉底位置 (PQWZ),喷枪反馈信号 (P_AI_B_1),喷枪顶部压力 (PT1249),部分参数的正常数据如表 1 所示。所有数据经过缺失值处理后作为模型的输入特征。

表 1 正常工况实验参数及数据

Table 1 Experimental parameters and data under normal working condition							
采样编号	喷枪供氧管 压力 (PT1211)	喷枪供氧管氧气 流量 (FT_1213)	喷枪供风管空气 温度 (TE1224)	喷枪供氧管氧气 温度 (TE1214)	喷枪供风管 压力 (PT1222M)	...	喷枪油管吹扫 压力 (PT1239)
No. 1	213. 308 9	4. 376 6	17. 826 6	129. 475 0	5. 707 0		621. 538 5
No. 2	218. 498 2	4. 109 9	17. 802 2	129. 426 1	5. 772 9		612. 747 3
No. 3	224. 297 9	4. 145 1	17. 826 6	129. 426 1	5. 809 5		616. 263 7
No. 4	244. 932 8	3. 970 7	17. 997 6	129. 426 1	5. 772 9		639. 707 0
No. 5	227. 838 8	3. 954 6	17. 851 0	129. 426 1	5. 765 6		657. 582 4
...							
No. 200	240. 170 9	3. 950 2	26. 202 7	136. 117 2	5. 621 5		700. 952 4

为构建数据集,本研究在 DCS 系统中提取了以下四组采样数据:2020 年 1 月在正常工况稳态下的连续 200 条采样数据;2020 年 1 月发生喷枪端部管壁烧穿故障时的连续 200 条采样数据;2020 年 4 月发生喷枪端部烧损故障时的连续 200 条采样数据;2020 年 6 月发生喷枪旋流器烧损故障时的连续 200 条采样数据。所有数据均按照 72 s 的采样周期获取,最终数据集包含 800 个样本,按 70% 用于训练集、30% 用于测试集,具体样本分配见表 2。

表 2 实验数据描述

Table 2 Description of experimental data		
故障标签	艾萨炉喷枪故障类型	训练集/测试集
0	正常数据	140/60
1	艾萨炉喷枪端部烧损	140/60
2	艾萨炉喷枪端部管壁烧穿	140/60
3	艾萨炉喷枪旋流器烧损	140/60

3.2 实验参数

为避免艾萨炉喷枪各工艺参数因量纲差异影响模型效果,首先对喷枪数据进行归一化处理,将其统一到[0,1]范围内,以便综合对比评价。具体计算方法见式(12)。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{12}$$

式中: x' 代表数据经归一化处理后的值; x 代表原始数据; $x'_{\max}$ 代表原始数据的最大值; $x_{\min}$ 代表原始数据的最小值。

3.2.1 EGCNN 参数

在故障识别模型中,采用 EGCNN 模型对艾萨铜熔炼中艾萨炉喷枪数据进行故障特征提取。卷积模块一到卷积模块四的维度变化情况设为 1 * 64、64 * 128、128 * 64、64 * 32,激活函数设为 ELU,学习率设为 0.000 1;ELU 激活函数中的参数 α 取 1.0, batch-size 设为 32,迭代次数设为 100 次,损失函数选择交叉熵损失函数,优化器选择 Adam。

3.2.2 RIME 与 SVM 参数

经 EGCNN 提取故障特征后,将数据输入到 RIME-SVM 进行最终的艾萨炉喷枪故障识别。在 RIME 中,霜冰群体的数量设为 20,迭代适应度曲线如图 8 所示,RIME 算法在第 89 次迭代时有最优适应度:准确率为 97.08%,此后准确率趋于稳定。因此设定最大迭代次数设为 100。需要优化的惩罚因子 λ 和核参数 σ 取值范围均为[0.1,100]。通过 RIME 来优化 SVM 的参数,得到最佳惩罚因子为

7.451 0 和核参数为 0.265 3。




图 8 RIME 算法适应度曲线

Fig. 8 RIME algorithm fitness curve

3.3 模型评价指标

为了衡量 EGCNN-RIME-SVM 故障识别模型对运行过程故障识别能力,采用准确率、精确率、召回率、 F_1 -score 和 Kappa 系数作为评价指标,一般情况下,这五个指标的值越接近 100%,则模型的故障识别效果越好。各个指标的计算公式见式(13)—(17)。

$$A = \frac{TP + TN}{TP + FP + TN + FN} \tag{13}$$

$$R = \frac{TP}{TP + FN} \tag{14}$$

表 3 艾萨炉喷枪故障识别消融实验

Table 3 Isasmelt furnace lance fault identification ablation experiment

模型	准确率	精确率	召回率	F_1 -score	Kappa 系数
CNN(ReLU + FC)	84.58%	90.46%	84.58%	82.96%	0.794 5
CNN(ReLU + GAP)	85.42%	90.11%	85.42%	84.40%	0.807 2
CNN(ELU + FC)	86.25%	91.13%	86.25%	85.13%	0.816 7
EGCNN	86.67%	91.30%	86.67%	85.65%	0.822 2
SVM	74.58%	57.64%	74.58%	64.53%	0.661 1
RIME-SVM	86.25%	86.25%	91.29%	85.13%	0.816 7
EGCNN-SVM	90.83%	90.83%	91.99%	90.30%	0.877 8
EGCNN-RIME-SVM	97.08%	97.08%	97.10%	97.07%	0.961 1

由表 3 中的实验结果进行比较,可知 CNN 模型采用 ReLU 激活函数和 GAP 层的准确率优于 CNN 模型采用 ReLU 激活函数和 FC 层,表明 GAP 层在小样本艾萨炉喷枪数据下有效的缓解了过拟合问题。与此同时,CNN 模型采用 ELU 激活函数和 FC 层的准确率优于 CNN 模型采用 ReLU 激活函数和 FC 层,表明 ELU 激活函数在小样本艾萨炉喷枪数

$$R = \frac{TP}{TP + FN} \tag{15}$$

$$F_1 = \frac{2 \cdot P \cdot R}{P + R} \tag{16}$$

$$K = \frac{P_o - P_e}{1 - P_e} \tag{17}$$

式中:TP 表示正确识别为某一类别的样本数量;TN 表示正确识别为其他类别样本的数量;FP 表示错误识别其他类别样本的数量;FN 表示错误识别某一类别样本的数量; P_o 为每一类预测正确的样本数量之和除以总样本数; P_e 为所有类别分别对应的实际样本数量与预测样本数量的乘积的总和除以样本总数的平方。

3.4 消融实验

为了验证 EGCNN-RIME-SVM 网络结构设计的合理性和有效性,共使用七种对比模型训练同一组数据,并将分类结果进行对比,七种模型为:CNN 网络一,采用 ReLU 激活函数和全连接层;CNN 网络二,采用采用 ReLU 激活函数和 GAP 层;CNN 网络三,采用 ELU 激活函数和全连接层;EGCNN 网络;SVM 网络;RIME-SVM 网络;EGCNN-SVM 网络。结果如表 3 和图 9 所示。

据下加快了模型的收敛速度。EGCNN 模型的故障识别准确率均优于三种 CNN 模型,说明 EGCNN 对处理小样本故障数据迅速收敛,使模型准确率和稳定性都有提高。RIME-SVM 模型的识别准确率优于 SVM 模型,说明经过 RIME 优化 SVM 参数,使模型的准确率有很大的提高。将 EGCNN 与 SVM 进行融合,模型的准确率也较高。因此考虑上述内容,本文




图 9 消融实验故障识别结果对比

Fig. 9 Comparison of fault identification results of ablation experiments

提出了 EGCNN-RIME-SVM 模型,通过实验可知 EGCNN-RIME-SVM 模型的故障识别效果优于其他网络模型,准确率达到了 97.08%。验证了本文 EGCNN-RIME-SVM 对于艾萨炉喷枪故障数据识别的优越性和网络结构的有效性。

3.5 对比实验

为了说明本文提出的模型对艾萨炉喷枪故障识别的优势,设计对比实验来验证本文提出的 EGCNN-RIME-SVM 模型的识别效果,对比模型分别为随机森林、WOA-SVM、GA-SVM、PSO-SVM 和 CNN-SVM 网络。

在随机森林模型中,设定决策树的数量为 500,最大树深度为 10,最小节点分裂样本数为 5,最小叶子节点样本数为 3;在 WOA-SVM 模型中,设定鲸鱼种群规模为 200,迭代次数为 50。在 GA-SVM 模型中,设定种群大小为 200,迭代次数为 50,变异概率

为 0.1;在 PSO-SVM 模型中,设定粒子群规模为 200,迭代次数为 50,惯性因子为 0.8,学习因子 C1 为 1.5,C2 为 1.5;在 CNN-SVM 模型中,CNN 模型采用 Relu 激活函数和全连接层,其余部分参数和 EGCNN 模型一致。故障识别结果的各评价指标见表 4,对比实验结果如图 10 所示。可见在使用 EGCNN-RIME-SVM 模型进行故障识别时,其准确率较其他五种模型均有明显提高,体现了本文模型在故障识别准确率方面的优势。

3.6 泛化实验

艾萨铜熔池熔炼过程工艺流程长,机理反应复杂,除艾萨炉喷枪易出现故障外,其他部位也容易出现故障,因此,模型需要具有较强的泛化能力,且该能力在工程实际应用中也是最重要的标准之一,为测试本文 EGCNN-RIME-SVM 的泛化能力,将模型应用于艾萨炉炉衬蚀损的故障识别。

表 4 艾萨炉喷枪故障识别对比实验

Table 4 Isasmelt furnace lance fault identification comparative experiment

模型	准确率	精确率	召回率	F ₁ -score	Kappa 系数
随机森林	50.42%	38.01%	50.42%	42.17%	0.338 9
GA-SVM	75.42%	85.04%	75.42%	74.53%	0.672 3
PSO-SVM	84.58%	88.99%	84.58%	82.95%	0.794 5
WOA-SVM	85.42%	89.67%	85.42%	83.68%	0.805 6
CNN-SVM	87.08%	87.08%	91.48%	86.16%	0.827 8
EGCNN-RIME-SVM	97.08%	97.08%	97.10%	97.07%	0.961 1




图 10 对比实验故障识别结果对比

Fig. 10 Comparison of experimental fault identification results

艾萨炉体设计为竖式圆筒形,内衬覆盖耐火材料衬里。在实际的铜熔池熔炼过程中,由于剧烈的化学反应会导致炉衬遭受侵蚀,从而使艾萨炉炉衬故障,可将其分为:浸蚀砖层渗透、浸蚀砖层腐蚀、浸蚀砖层崩裂及浸蚀砖层剥落 4 种故障类型进行研

究。关键工艺参数包括艾萨炉熔池温度、艾萨炉耐火砖温度、炉膛压力等 17 个工艺参数。每种故障类型及正常数据各取 200 条进行验证。本文提出的 EGCNN-RIME-SVM 在艾萨炉炉衬蚀损上的泛化能力验证结果和准确率如表 5 和图 11 所示。

表 5 艾萨炉喷枪故障识别泛化实验

Table 5 Isasmelt furnace lance fault identification generalization experiment

位置	准确率	精确率	召回率	F ₁ -score	Kappa 系数
艾萨炉炉衬	93.00%	93.00%	93.02%	93.00%	0.922 3

结果表明,EGCNN-RIME-SVM 模型在艾萨炉炉衬的故障识别准确率为 93.00%,说明该故障识别模型具有良好的泛化性能,能够适应对艾萨炉其他

部位的故障识别。
3.7 案例分析
在艾萨炉喷枪的故障识别中,各故障类型对应




图 11 泛化实验故障识别结果

Fig. 11 Fault identification results of generalization experiments

的关键参数范围显著不同。正常工作状态下,喷枪供氧管氧气温度 (TE1214) 的变化范围为 $[126.270\ 7, 135.775\ 3]^{\circ}\text{C}$, 喷枪背压 (PT1229) 的变化范围为 $[39.853\ 5, 85.750\ 9]\text{kPa}$, 喷枪反馈信号 (P_AI_B_1) 的变化范围为 $[10.002\ 4, 11.497\ 0]\text{kPa}$ 。当艾萨炉喷枪端部烧损时,喷枪供氧管氧气温度 (TE1214) 的变化范围为 $[95.921\ 9, 106.031\ 7]^{\circ}\text{C}$, 喷枪背压 (PT1229) 的变化范围为 $[0.476\ 2, 2.161\ 2]\text{kPa}$, 喷枪反馈信号 (P_AI_B_1) 的变化范围为 $[8, 10.002\ 4]\text{kPa}$ 。当艾萨炉喷枪端部管壁烧穿时,喷枪供氧管氧气温度 (TE1214) 的变化范围为 $[39.609\ 3, 95.921\ 9]^{\circ}\text{C}$, 喷枪背压 (PT1229) 的变化范围为 $[0, 0.476\ 2]\text{kPa}$, 喷枪反馈信号 (P_AI_B_1) 的变化范围为 $[11.497\ 0, 12.503\ 1]\text{kPa}$ 。当艾萨炉喷枪旋流器烧损时,喷枪供氧管氧气温度 (TE1214) 的变化范围为 $[106.031\ 7, 126.202\ 7]^{\circ}\text{C}$, 喷枪背压 (PT1229) 的变化范围为 $[2.161\ 2, 39.853\ 5]\text{kPa}$, 喷枪反馈信号 (P_AI_B_1) 的变化范围为 $[12.503\ 1, 15.003\ 7]\text{kPa}$ 。

通过对艾萨炉喷枪的各项工艺参数的实时监控,不仅能够迅速识别和处理故障,还为熔炼过程的优化和决策提供了科学依据,显著提升了生产的安全性和效率,并为设备维护及延长设备寿命提供了可靠的技术支持。

4 结 论

针对 CNN 模型处理艾萨炉喷枪小样本数据时,易产生参数多、过拟合以及收敛速度较慢等问题,本文提出 EGCNN 故障特征提取模型,并融合了 RIME-SVM 故障识别方法。EGCNN-RIME-SVM 模

型的准确率、精确率、召回率、 F_1 -score 和 Kappa 系数分别为 97.08%、97.08%、97.10%、97.07% 和 0.961 1,充分证明了该方法有效性和准确性。

1)EGCNN 模型采用 ELU 激活函数替代 ReLU 激活函数,以提高对艾萨炉喷枪数据噪声和输入变化的鲁棒性,并加快故障特征提取模型的收敛。

2)EGCNN 模型采用全局平均池化层替代全连接层不仅能增强艾萨炉喷枪工艺参数与故障类别之间的相关性,还可减少模型参数,避免过拟合,可更好实现艾萨炉喷枪的故障特征提取。

3)采用 SVM 作为最终故障识别模型,并通过 RIME 对 SVM 的核函数参数和惩罚因子寻优,以提高艾萨炉喷枪故障识别模型的分类准确率。

4)通过对 CNN 模型适应性改进和集成,并与 RIME 优化后的 SVM 模型相结合,有效解决了小样本艾萨炉喷枪故障识别准确率低的问题。

[参考文献]

[1] 张辉. 艾萨炉熔炼过程熔渣侵蚀特性及延长炉寿的应用研究 [D]. 昆明:昆明理工大学, 2022.
ZHANG Hui. A study on the slag corrosion characteristics and extending the furnace life in the Isasmelt smelting process [D]. Kunming: Kunming University of Science and Technology, 2022.

[2] 赵震宇. 顶吹浸没铜熔炼技术述评 [J]. 有色矿冶, 2004 (5): 33-36.
ZHAO Zhenyu. A review of top-blown immersion copper smelting technology [J]. Non-ferrous Minerals and Metallurgy, 2004 (5): 33-36.

[3] 杨小琴, 史谊峰, 张邦琪, 等. 艾萨炼铜技术的应用及创新 [J]. 中国有色冶金, 2006, 35 (4): 18-22, 43.
YANG Xiaoqin, SHI Yifeng, ZHANG Bangqi, et al. Application and innovation of Copper ISASMELT process [J]. China Nonferrous Metallurgy, 2006, 35 (4): 18-22, 43.

[4] 李江涛. 艾萨铜熔炼水淬渣磨浮贫化回收率的分析 [J]. 中国冶金, 2022, 32 (7): 122-128.
LI Jiangtao. Analysis of grinding flotation depleted recovery ratio of water quench slag from ISA copper smelting [J]. China Metallurgy, 2022, 32 (7): 122-128.

[5] ZHAO L, ZHU D F, LIU D F, et al. Prediction and optimization of matte grade in ISA furnace based on GA-BP neural network [J]. Applied Sciences, 2023, 13 (7): 4246.

[6] LE V, MILLER C, TSAO B, et al. Series arc fault identification in DC distribution based on random forest predicted probability [J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2022, 11 (6): 5636-5648.

[7] YANG C M, HOU J. Fed-batch fermentation penicillin process fault diagnosis and detection based on support vector machine [J]. Neurocomputing, 2016, 190: 117-123.

- [8] LIANG X B, YAO J Y, ZHANG W F, et al. A novel fault diagnosis of a rolling bearing method based on variational mode decomposition and an artificial neural network [J]. Applied Sciences, 2023, 13(6): 3413.
- [9] TAO P, SHEN H T, ZHANG Y R, et al. Status forecast and fault classification of smart meters using LightGBM algorithm improved by random forest [J]. Wireless Communications and Mobile Computing, 2022, 2022(1): 3846637.
- [10] XUE F, ZHANG W M, XUE F, et al. A novel intelligent fault diagnosis method of rolling bearing based on two-stream feature fusion convolutional neural network [J]. Measurement, 2021, 176: 109226.
- [11] YANG L Y, ZHANG K, CHEN Z H, et al. Fault diagnosis of WOA-SVM high voltage circuit breaker based on PCA Principal Component Analysis [J]. Energy Reports, 2023, 9: 628–634.
- [12] WEI Y F, ZHAO J W, YANG Z Y, et al. Fault detection method for flexible DC grid based on CEEMDAN multiscale entropy and GA-SVM [J]. Electrical Engineering, 2024: 1–13.
- [13] SAUFI S R, AHMAD Z A B, LEONG M S, et al. Challenges and opportunities of deep learning models for machinery fault detection and diagnosis: A review [J]. IEEE Access, 2019, 7: 122644–122662.
- [14] JIAO J Y, ZHAO M, LIN J, et al. A comprehensive review on convolutional neural network in machine fault diagnosis [J]. Neurocomputing, 2020, 417: 36–63.
- [15] 雷春丽, 夏奔锋, 薛林林, 等. 小样本下自校正卷积神经网络的滚动轴承故障识别方法 [J]. 仪器仪表学报, 2022, 43(9): 122–130.
- LEI Chunli, XIA Benfeng, XUE Linlin, et al. Fault identification for rolling bearing by self-calibrated convolutional neural network under small samples conditions [J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 122–130.
- [16] 田鹏飞, 于游, 董明, 等. 基于 CNN-SVM 的高压输电线路故障识别方法 [J]. 电力系统保护与控制, 2022, 50(13): 119–125.
- TIAN Pengfei, YU You, DONG Ming, et al. A CNN-SVM-based fault identification method for high-voltage transmission lines [J]. Power System Protection and Control, 2022, 50(13): 119–125.
- [17] 李冬辉, 赵墨刊, 高龙. 基于 CNN-GRU 的冷水机组传感器偏差故障诊断方法 [J]. 湖南大学学报 (自然科学版), 2022, 49(2): 74–82.
- LI Donghui, ZHAO Moxuan, GAO Long. Fault diagnosis method of chiller sensor deviation based on CNN-GRU [J]. Journal of Hunan University (Natural Sciences), 2022, 49(2): 74–82.
- [18] 宋庭新, 黄继承, 刘尚奇, 等. 小样本下基于 DWT 和 2D-CNN 的齿轮故障诊断方法 [J/OL]. 计算机集成制造系统, 1–15 [2024-11-12].
- SONG Tingxin, HUANG Jicheng, LIU Shangqi, et al. Gear fault diagnosis method based on DWT and 2D-CNN in small samples [J/OL]. Computer Integrated Manufacturing Systems, 1–15 [2024-11-12].
- [19] XIE W L, LI Z X, XU Y, et al. Evaluation of different bearing fault classifiers in utilizing CNN feature extraction ability [J]. Sensors, 2022, 22(9): 3314.
- [20] GAO X R, YANG F, FENG E. A process fault diagnosis method using multi-time scale dynamic feature extraction based on convolutional neural network [J]. The Canadian Journal of Chemical Engineering, 2020, 98(6): 1280–1292.
- [21] CHEGENI M K, RASHNO A, FADAEI S. Convolution-layer parameters optimization in convolutional neural networks [J]. Knowledge-Based Systems, 2023, 261: 110210.
- [22] CUI C, SHEN Z, HUANG J, et al. Adaptive feature aggregation in deep multi-task convolutional neural networks [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 32(4): 2133–2144.
- [23] 唐智川, 张克俊, 李超, 等. 基于深度卷积神经网络的运动想象分类及其在脑控外骨骼中的应用 [J]. 计算机学报, 2017, 40(6): 1367–1378.
- TANG Zhichuan, ZHANG Kejun, LI Chao, et al. Motor imagery classification based on deep convolutional neural network and its application in exoskeleton controlled by EEG [J]. Chinese Journal of Computers, 2017, 40(6): 1367–1378.
- [24] 段宇飞, 孙记委, 王焱清, 等. 基于改进卷积神经网络的油茶果壳籽分选方法 [J]. 农业工程学报, 2023, 39(3): 154–161.
- DUAN Yufei, SUN Jiwei, WANG Yanqing, et al. Sorting camellia oleifera husk and seed using an improved convolutional neural network [J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(3): 154–161.
- [25] CHAO Z Q, HAN T. A novel convolutional neural network with multiscale cascade midpoint residual for fault diagnosis of rolling bearings [J]. Neurocomputing, 2022, 506: 213–227.
- [26] LI Y X, WANG K S. Modified convolutional neural network with global average pooling for intelligent fault diagnosis of industrial gearbox [J]. Eksploatacja i Niezawodność, 2020, 22(1): 63–72.
- [27] DENG F, GUO S, ZHOU R, et al. Sensor multifault diagnosis with improved support vector machines [J]. IEEE transactions on automation science and engineering, 2015, 14(2): 1053–1063.
- [28] SU H, ZHAO D, HEIDARI A A, et al. RIME: A physics-based optimization [J]. Neurocomputing, 2023, 532: 183–214.

Few-shot fault identification method of Isasmelt furnace lance based on improved CNN and RIME-SVM

SUN Haidong, DUAN Hong, WANG Songling

(School of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: To mitigate the frequent failures of Isasmelt furnace lance during copper smelting process and enhance the identification accuracy of few-shot fault data, this study introduces a novel approach, integrating exponential linear unit (ELU), global average pooling (GAP) convolutional neural network (EGCNN) and rime-ice optimization algorithm (RIME) optimized support vector machine (SVM). Initially, ELU is employed as the activation function for the convolutional neural network (CNN), enhancing robustness against noise and input variations, thereby expediting model convergence. Subsequently, GAP replaces the full connect (FC) layer to strengthen the correlation between process parameters and fault categories, which reduces the number of model parameters and mitigates the risk of overfitting. Ultimately, SVM is implemented as the final classifier in lieu of the traditional Softmax function. RIME is employed to optimize the penalty factor and kernel parameter of the SVM, thereby further enhancing the accuracy of the model. The results indicate that the proposed method achieves an accuracy of 97.08%, precision of 97.08%, recall of 97.10%, F_1 -score of 97.07% and Kappa coefficient of 0.961 1 in identifying Isasmelt furnace lance faults. The proposed method exhibits superior fault identification performance.

Key words: Isasmelt furnace lance; fault identification; convolutional neural network; rime-ice optimization algorithm; support vector machine



中国恩菲主编的国际标准 《生活垃圾渗滤液处理回用系统运维指南》正式启动

11 月 28 日,中国恩菲工程技术有限公司组织召开国际标准《生活垃圾渗滤液处理回用系统运维指南》(ISO/WD 23623)启动会暨专题研讨会。中国恩菲副总经理万焱出席并致辞。

来自 ISO/TC282 国际秘书处的深圳市海川实业股份有限公司,ISO/TC282 国内技术对口单位中国标准化研究院、中冶长天、北京林业大学、光大环保(中国)有限公司、深圳能源等专家代表围绕标准草案的框架与核心技术内容进行了深入研讨。

该国际标准由中国恩菲主编,于 2025 年 2 月通过 ISO 立项,旨在促进垃圾渗沥液处理回用系统高效稳定运行,节省经济和能源成本,降低安全风险。标准将与中国恩菲主导的《生活垃圾焚烧发电渗滤液处理及回用技术导则》(ISO 24297)共同构建起渗滤液“处理—回用—运维”全链条标准体系,助力中国恩菲从“技术输出”向“标准引领”方向转型升级。

中国恩菲副总工程师刘海威,科技管理部、能建事业部相关负责人及人员,恩菲研究院相关人员参会。

(资料来源:中国恩菲)