

DOI: 10.19650/j.cnki.cjsi.J2514045

DMIFD: 一种基于深度学习的多模态工业故障诊断方法*

尹 刚^{1,2}, 朱 森^{1,2}, 颜玥涵³, 王怀江⁴, 江茂华⁵, 刘期烈⁶

(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. 贵州大学电气工程学院 贵阳 550025; 4. 中铝郑州研究院 郑州 450041; 5. 重庆高峰新材料科技有限公司
重庆 404160; 6. 重庆邮电大学 重庆 400065)

摘 要: 基于深度学习的故障诊断是当前工业安全智能化管理的重要研究方向。工业实际生产中故障时常发生, 导致生产效率下降, 严重时会造成停产甚至人员伤亡。由于生产环境复杂多变, 导致故障特征难以提取和识别, 且工业现场需要实时监测和快速诊断, 传统故障诊断方法通常依赖专家经验进行特征提取和模式识别, 难以适应复杂动态的工业环境。针对上述问题, 提出了一种基于深度学习的多模态工业故障诊断方法。采用极端梯度提升 (XGBoost) 筛选与工业故障相关的工艺参数, 以此作为模型输入的多模态数据。通过深度极限学习机 (DELIM) 提取生产工艺参数的非线性和高维特征, 识别出异常状态的工业设备, 并利用霜冰优化算法 (RIME) 优化 DELIM 的关键参数, 使模型达到最佳性能。RIME-DELIM 输出正常状态的设备样本, 异常设备样本则继续输入至深度置信网络 (DBN) 和最小二乘支持向量机 (LSSVM), 对异常样本进行故障类型的具体判别。将所提出的方法应用于铝电解生产过程, 验证了模型的有效性。经铝电解生产现场实验结果表明, 该模型的异常状态检测的准确率为 97.96%, F1-score 为 0.975 3, 故障类型诊断的准确率为 96.75%, Macro-F1 分数为 0.944 7, 通过消融实验、与常见深度学习模型对比, 本文构建的 DMIFD 模型诊断精度更高, 为实际工业生产的故障诊断提高了更准确、可靠的支持。

关键词: 深度学习; 故障诊断; 多模态融合; 神经网络; 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

DMIFD: A deep learning-based method for multimodal industrial fault diagnosis

Yin Gang^{1,2}, Zhu Miao^{1,2}, Yan Yuehan³, Wang Huaijiang⁴, Jiang Maohua⁵, Liu Qilie⁶

(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. School of Electrical Engineering, Guizhou University, Guiyang 550025, China; 4. Chinalco Zhengzhou Research Institute, Zhengzhou 450041, China;
5. Chongqing Gaofeng New Materials Technology Co., Ltd., Chongqing 404160, China;
6. Chongqing Post and Communications University, Chongqing 400065, China)

Abstract: Fault diagnosis based on deep learning is an important research direction in the intelligent management of industrial safety. Failures frequently occur in the actual industry production, leading to reduced production efficiency, and in severe cases, production stoppages or even casualties. Due to the complex and variable production environment, fault features are difficult to extract and recognize, and real-time monitoring and rapid diagnosis are required at industrial sites. Traditional fault diagnosis methods typically rely on expert experience for feature extraction and pattern recognition, which makes them difficult to adapt to the complex and dynamic industrial environments. To address these issues, a deep learning based multimodal industrial fault diagnosis (DMIFD) method is proposed. Extreme gradient boosting (XGBoost) is employed to select process parameters related to industrial faults, which are then used as the multimodal input data for the model. The deep extreme learning machine (DELIM) is used to extract nonlinear and high-

收稿日期: 2025-05-16 Received Date: 2025-05-16

* 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

dimensional features from the production process parameters to identify equipment in abnormal states. The key parameters of DELM are optimised using the frost and ice optimisation algorithm (FIOA) to achieve optimal model performance. The RIME-DELM module outputs equipment samples in normal states, while the samples of abnormal equipment are further input into a deep belief network (DBN) and a least minimal squares support vector machine (LSSVM) to perform specific fault type classification. The proposed method is applied to the aluminium electrolysis production process to validate its effectiveness. Field conducted in an aluminum electrolysis plant show that the model achieves an abnormal state detection accuracy of 97.96%, an F1-score of 0.975 3, a fault type diagnostic accuracy of 96.75%, and a Macro-F1 score of 0.944 7. Compared with common deep learning models and through ablation experiments, the DMIFD model demonstrates higher diagnostic accuracy and provides more accurate and reliable support for fault diagnosis in practical industrial production.

Keywords: deep learning; fault diagnosis; multimodal fusion; neural networks; process control

0 引言

工业生产环境通常受温度、湿度、粉尘、腐蚀性气体或强振动等恶劣条件的影响,加之设备长期处于超负荷状态,可能造成过热、疲劳或部件失效,这导致工业生产过程中故障频发,生产效率降低,严重时会造成环境污染和设备损坏,停产停业人员伤亡。工业设备的故障往往由多个因素共同作用,难以确定单一原因。传统方法依赖于专家经验进行故障特征,难以适应多种复杂故障模式和满足实时诊断的需求,且对非线性和动态故障特性捕捉能力有限。因此需要运用大数据挖掘技术对工业设备进行异常状态检测和故障诊断。

目前基于机器学习的工业故障诊断方法已经得到了深入研究^[1-3],通过分析大量实时数据,提高了故障诊断的准确性和效率。Afia等^[4]将最大重叠离散小波包变换、光谱本征正交分解和随机森林算法用于轴承故障诊断。Nambiar等^[5]在健康和不同故障状态下采集的振动信号作为研究的输入数据,并将K-近邻算法(K-nearest neighbors, KNN)、局部KNN、局部加权学习和随机子空间集成KNN用于空压机故障分类。Wei等^[6]提出了基于线性判别分析(linear discriminant analysis, LDA)的输电线路故障诊断方法。Khan等^[7]将主成分分析(principal component analysis, PCA)和核主成分分析(kernel principal components analysis, KPCA)与支持向量机(support vector machine, SVM)相结合,对工业化工过程(田纳西伊斯曼过程)进行故障诊断。

深度学习作为机器学习的分支,在处理大规模数据和深层特征信息时展现出强大的数据解析能力,在自然语言处理、金融预测和医疗等许多领域都取得了巨大成功^[8-10]。Yin等^[11]基于长短期记忆网络(long short term memory networks, LSTM)和堆叠降噪自编码器对铝电解的阳极效应故障进行预测。金姝等^[12]提出了一种将卷积神经网络(convolutional neural networks, CNN)与Transformer结合(T_CNN)的光纤微震信号识别方法。

Wu等^[13]提出了一种基于状态点分层排序的并行卷积神经网络,对航空发动机进行故障诊断。Gao等^[14]提出了一种双融合图卷积网络用于传动系统的多传感器多工况故障诊断。Feng等^[15]提出一种基于多模态网络和熵条件域对抗网络相结合的跨工况滚动轴承故障诊断方法。Song等^[16]利用减法平均优化器算法优化多通道CNN和SVM网络进行高压断路器故障诊断。Wei等^[17]提出了基于时域收缩可解释深度强化学习的齿轮箱故障诊断方法。

工业设备的生产数据通常具有多样性、非线性、高维度、关联性强的特征,传统的机器学习方法已不能满足工业设备故障的实时准确诊断需求。为了解决工业设备的异常状态检测和故障诊断困难这一问题,提出了一种基于深度学习的多模态工业故障诊断DMIFD(deep learning based multimodal industrial fault diagnosis)方法。采用极端梯度提升算法(extreme gradient boosting, XGBoost)筛选与工业设备故障相关的工艺参数,包括温度、电压、电流等多模态数据源,作为模型的输入。深度极限学习机(deep extreme learning machine, DELM)提取参数中的非线性和高维特征,识别出异常状态的设备,利用霜冰优化算法(rime optimization algorithm, RIME)优化DELM的超参数,RIME-DELM将正常样本结果直接输出,异常样本则传至下一级深度置信网络(deep belief network, DBN)和最小二乘支持向量机(least squares support vector machine, LSSVM),对异常状态类别做出具体的判断。DBN对高维数据进行有效降维和提取隐含特征,LSSVM计算复杂度较低,在小样本、多类别任务中具有优势,将二者结合用于故障类型的具体诊断,其较高计算效率可实现故障的实时分类。

1 相关工作

1.1 极端梯度提升算法

XGBoost是一种基于决策树的集成算法,以CART回归树为基础,在梯度提升决策树的基础上对目标函数引

入 L2 正则项和二阶导数,最小化损失函数,减少过拟合^[18]。其预测模型可表示为:

$$\hat{y}_i = \sum_{i=1}^K f_i(x_i), \quad f_i \in F \quad (1)$$

$$obj = \sum_{i=1}^m l(y_i, \hat{y}_i) + \sum_{j=1}^K \Omega(f_j), \quad f_j \in F \quad (2)$$

式中: y_i 表示样本真实值; $\sum_{i=1}^m l(y_i, \hat{y}_i)$ 为损失函数;

$\sum_{j=1}^K \Omega(f_j)$ 为正则项,具体表示为:

$$\Omega(f_j) = \tau T + \frac{1}{2} \mu \sum_{j=1}^T \omega_j^2 \quad (3)$$

式中: T 为决策树的叶子节点个数; ω 表示每棵决策树的叶子节点输出分数; μ 为叶子节点的系数; τ 为叶子权重惩罚正则项。

XGBoost 将前 $t-1$ 棵树组合而成的模型产生的误差作为参考,进行第 t 棵树的建立,使损失函数不断降低,因此可将目标函数改写为:

$$obj^t = \sum_{i=1}^m l(y_i, \hat{y}_i^{(t-1)} + f_i(x_i)) + \Omega(f_i) \quad (4)$$

利用二阶泰勒展开式对目标函数进行近似,即:

$$obj^t \approx \sum_{i=1}^m \left(g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i) \right) + \tau T + \frac{1}{2} \mu \sum_{j=1}^T \omega_j^2 \quad (5)$$

式中: $g_i = \frac{\partial l(y_i, \hat{y}_i^{(t-1)})}{\partial \hat{y}_i^{(t-1)}}$, $h_i = \frac{\partial^2 l(y_i, \hat{y}_i^{(t-1)})}{\partial^2 \hat{y}_i^{(t-1)}}$ 分别为目标函数的一阶导数和二阶导数。

在树的结构确定的情况下,通过优化每个叶子节点的权重 ω_j 来最小化这个损失函数,最佳权重为:

$$\omega_j^* = - \frac{G_j}{H_j + \mu} \quad (6)$$

将求得的权重代入目标函数,即可得到优化后的目标函数:

$$obj^t = - \frac{1}{2} \sum_{j=1}^T \left(\frac{G_j^2}{H_j + \mu} \right) + \mu T \quad (7)$$

式中: $G_j = \sum_{i \in I_j} g_i$; $H_j = \sum_{i \in I_j} h_i$; $I_i = \{i | q(x_i) = j\}$ 为落入叶子节点 j 的样本集合。

XGBoost 能够通过分裂节点时的信息增益自动计算特征的重要性,筛选出对目标变量影响最大的特征;决策树结构具有自动发现特征交互作用的能力,同时有效区分高度相关变量,确保关键特征的选择不会受到共线性影响;通过梯度提升决策树逐步迭代优化,自动降低冗余特征的重要性,优先选择信息增益更高的特征,同时能够适应工业数据中数据缺失和噪声干扰的问题。在处理工业数据的复杂特征时,XGBoost 作为特征选择工具可以有效降低数据维度、筛选关键变量,提高下游模型的准确性和计算效率。

1.2 深度置信网络

受限玻尔兹曼机 (restricted boltzmann machines, RBM) 由一层可见层和一层隐藏层组成。同层神经元独立,不同层神经元相互连接。深度置信网络 (deep belief network, DBN) 由多个 RBM 堆叠而成,每层 RBM 的隐藏层即为下一层 RBM 的输入层,通过逐层学习,能够自动提取工业数据的深层次特征,从而完成更加复杂的数据表示。

RBM 通过能量函数来定义输入层 (可见层) 和隐藏层之间的依赖关系。对于可见单元 v 和隐藏单元 h , RBM 的能量函数定义为:

$$E(v, h) = - \sum_i a_i v_i - \sum_j b_j h_j - \sum_{i,j} v_i W_{ij} h_j \quad (8)$$

式中: a_i 是可见单元的偏置; b_j 是隐藏单元的偏置; W_{ij} 是可见层和隐藏层之间的权重。

在 RBM 中,隐藏层和可见层的单元是条件独立的。给定可见层 v ,隐藏层 h 中第 j 个单元为 1 的概率为:

$$P(h_j = 1 | v) = \sigma(b_j + \sum_i W_{ij} v_i) \quad (9)$$

给定隐藏层 h ,可见层 v 中第 i 个单元为 1 的概率为:

$$P(v_i = 1 | h) = \sigma(a_i + \sum_j W_{ij} h_j) \quad (10)$$

式中: $\sigma(x) = \frac{1}{1 + e^{-x}}$ 是 sigmoid 函数。

DBN 的训练可分为逐层无监督预训练和有监督微调两个阶段。DBN 通过无监督训练层提取数据的深层特征,并且在无监督预训练过程中学习数据的主要模式,从而抑制噪声,提高模型在复杂工况下的稳健性。在预训练完成的 DBN 顶部添加输出层,并使用反向传播算法,通过有监督的方式对整个网络进行微调,从而达到最优解^[19]。DBN 通过多层神经元的非线性激活函数能够有效处理工业数据中的强非线性关系。Arif 等^[20]提出了一种基于鲸鱼优化算法 (whale optimization algorithm, WOA) 的 DBN 可穿戴心电信号监测汽车驾驶员健康状态的方法。Pan 等^[21]基于条件生成对抗网络和 DBN 对飞行学员认知负荷进行识别研究。Liu 等^[22]利用分解的 WOA-DBN 对通用型断路器进行故障诊断。鲁春燕等^[23]提出一种基于 DBN 的炼化空压机故障诊断方法。Wang 等^[24]提出了一种基于自回归集成移动平均模型和 DBN 的电力系统动态频率在线预测方法。

1.3 最小二乘支持向量机

传统支持向量机 (SVM) 通过求解二次规划问题确定支持向量,且 SVM 是二分类模型,处理多分类任务需构建多个分类器,增加模型的训练复杂度与时间,不适合用于多模态的工业复杂故障诊断;而 LSSVM 将目标函数改为最小二乘损失,将约束条件转化为等式约束,大大减少

了计算复杂度。

LSSVM 的目标是通过最小化误差和正则化项找到一个最佳超平面,使得数据在高维空间中可以线性分离。对于一个训练数据集 $(x_i, y_i), i=1, 2, \dots, n$, 其中 $x_i \in \mathbb{R}^d$, $y_i \in \{-1, 1\}$, 其目标函数为:

$$\min_{\mathbf{w}, \mathbf{b}, e} J(\mathbf{w}, e) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 \quad (11)$$

式中: $\mathbf{w}$ 是权重向量; $\mathbf{b}$ 是偏置; e_i 是误差变量; $\gamma > 0$ 是正则化参数, 用于控制模型复杂度与误差之间的权衡。

在分类问题中, 约束条件为:

$$y_i(\mathbf{w}^T \phi(x_i) + \mathbf{b}) = 1 - e_i, i = 1, 2, \dots, n \quad (12)$$

式中: $\phi(x)$ 是通过核函数将输入数据 x 映射到高维特征空间的映射函数, 将输入数据映射到高维空间以处理线性不可分问题。

LSSVM 使用拉格朗日乘子法和卡罗需·库恩·塔克 (Karush-Kuhn-Tucker Conditions, KKT) 条件来求解上述优化问题。首先构造拉格朗日函数:

$$L(\mathbf{w}, \mathbf{b}, \mathbf{e}, \boldsymbol{\alpha}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 -$$

$$\sum_{i=1}^n \alpha_i [y_i(\mathbf{w}^T \phi(x_i) + \mathbf{b}) - 1 + e_i] \quad (13)$$

式中: α_i 是拉格朗日乘子。

其次根据 KKT 条件, 分别对 $\mathbf{w}$ 、 $\mathbf{b}$ 、 e_i 、 α_i 求导并设置为 0, 得到:

$$\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \phi(x_i) \quad (14)$$

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (15)$$

$$\alpha_i = \gamma e_i \quad (16)$$

$$y_i(\mathbf{w}^T \phi(x_i) + \mathbf{b}) = 1 - e_i \quad (17)$$

并将上述结果代入, 消除 $\mathbf{w}$ 和 e_i , 得到一个线性方程组:

$$\begin{bmatrix} 0 & \mathbf{Y}^T \\ \mathbf{Y} & \Omega + \frac{1}{\gamma} \mathbf{I} \end{bmatrix} \begin{bmatrix} \mathbf{b} \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{1} \end{bmatrix} \quad (18)$$

式中: $\mathbf{Y} = [y_1, y_2, \dots, y_n]^T$, $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$, 是拉格朗日乘子向量; $\Omega_{ij} = y_i y_j K(x_i, x_j)$ 是核矩阵; $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ 是核函数。通过求解式 (18), 可以得到偏置 $\mathbf{b}$ 和拉格朗日乘子 $\boldsymbol{\alpha}$ 。

训练完成后, 利用 LSSVM 模型对新样本 x 的输出预测为 ω_j 。

$$f(x) = \sum_{i=1}^n \alpha_i y_i K(x, x_i) + \mathbf{b} \quad (19)$$

对于分类任务: 如果 $f(x) > 0$, 预测 $y = 1$; 否则预测 $y = -1$ 。

LSSVM 通过核函数映射和正则化处理非线性、高维和噪声数据, 在小样本情况下表现良好, 适合处理复杂工

况下的高维多分类任务。Xiao 等^[25]应用遗传优化算法优化的 LSSVM 模型预测露天矿中的粉尘浓度。Zhang 等^[26]基于改进粒子群优化算法的 LSSVM 模型对建筑能耗进行预测。Guan 等^[27]构建了一种基于改进灰狼优化算法的 LSSVM 变压器多分类故障诊断模型。Zhao 等^[28]提出了一种基于改进 WOA-LSSVM 的联合收割机装配质量检测方法。

2 模型建立及优化

2.1 深度极限学习机

DELM 将自动编码器 (auto encoders, AE) 引入极限学习机 (extreme learning machine, ELM) 模型, 并将 ELM 的结构扩展为多层架构, 通过多个隐藏层来提取数据的深层特征, 避免了 ELM 输入高维度数据时 ELM 的部分神经元失效和拟合不足等问题, 多层结构的引入使其能够更有效地表示复杂的非线性关系, 并捕捉工业数据的深层次特征^[29]。DELM 综合利用深度学习和极限学习机的特点实现对深层关系的挖掘, 不仅继承了极限学习机的优点, 如随机初始化输入权重和偏置、快速训练和良好的泛化性能等, 还具备了深度学习技术的强大学习能力, 从而获得比 ELM 更优异的分类性能。DELM 的深层结构和非线性激活函数能够捕获数据的非线性特征, 适合处理高维数据和复杂的非线性任务。Chen 等^[30]利用基于改进麻雀搜索算法的 DELM 对工程现场的岩体渗透系数进行预测。Dai 等^[31]提出了基于加权均值向量优化的 DELM 网络高速电主轴热误差预测模型。Zhou 等^[32]构建了基于改进灰狼优化算法的 DELM 模型, 实现锂离子电池剩余使用寿命预测及健康状态诊断。Reddy 等^[33]将象群优化算法的 DELM 模型用于天气预报中的太阳辐射预测。

假设输入样本集为 (X, Y) , 其中 $X \in \mathbb{R}^{N \times d}$ 是 N 个样本的输入数据, 维度为 d ; $Y \in \mathbb{R}^{N \times c}$ 是对应的输出标签, 维度为 c 。

首先设定网络的层数 L , 每层包含的神经元数量 $(n_1, n_2, \dots, n_L)$, 激活函数 ϕ (如 sigmoid 或 ReLU), 随机初始化每层的权重矩阵和偏置。其次 DELM 采用多层结构, 每层执行一次 ELM 的计算操作, 即固定随机权重并进行非线性激活。对于第 l 层的隐藏层进行计算:

$$\mathbf{H}^{(l)} = \phi(X^{(l)} \mathbf{W}^{(l)} + \mathbf{b}^{(l)}) \quad (20)$$

式中: $X^{(l)}$ 为第 l 层的输入数据, 初始输入 $X^{(0)} = X$; $\mathbf{W}^{(l)} \in \mathbb{R}^{n_{l-1} \times n_l}$ 是从第 $l-1$ 层到第 l 层的权重矩阵, 随机初始化且不更新; $\mathbf{b}^{(l)} \in \mathbb{R}^{n_l}$ 为偏置向量, 通常也随机初始化且固定; ϕ 为激活函数, 将线性组合转化为非线性输出; 每层输出的 $\mathbf{H}^{(l)}$ 被作为下一层的输入, 最终在第 l 层得到深度特征表示 $\mathbf{H}^{(l)}$ 。

在最顶层特征 $\mathbf{H}^{(l)}$ 之上, DELM 仅对输出层的权重进行求解, 使用最小二乘法以拟合目标输出 Y , 即:

$$\boldsymbol{\beta} = \mathbf{H}^{(l)+} Y \quad (21)$$

式中: $\boldsymbol{\beta} \in \mathbb{R}^{n \times c}$ 是输出层权重矩阵; $\mathbf{H}^{(l)+}$ 表示 $\mathbf{H}^{(l)}$ 的广义逆矩阵。

通过计算最终的输出层权重 $\boldsymbol{\beta}$, DELM 可以在预测阶段将输入样 X_{new} 的特征提取和预测结果表示为:

$$Y_{\text{pred}} = \mathbf{H}^{(l)} \boldsymbol{\beta} \quad (22)$$

式中: $\mathbf{H}^{(l)}$ 是输入样本通过多层非线性变换后的深度特征表示。

2.2 霜冰优化算法

RIME 是一种新型的群体智能优化算法, 灵感来源于自然界中的霜和冰晶形成过程^[34]。RIME 模拟了霜冰在特定环境下生成、聚集、分裂等动态过程, 通过个体之间的合作与竞争在解空间中寻找全局最优解。RIME 主要包括初始化、个体位置更新、适应度计算和最优解更新等步骤。

首先在解空间中随机生成一组候选解, 每个粒子的位置通常用一个向量表示。并初始化参数, 包括种群规模、最大迭代次数、霜冰粒子的生成速率、扩散因子等。假设种群包含多个霜冰粒子, 粒子的位置表示为向量 $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$, 其中 d 是问题的维度。

其次通过目标函数 $f(X_i)$ 计算每个霜冰粒子的适应度, 适应度越高的粒子代表解的质量越优。适应度函数定义为:

$$\text{fitness}(X_i) = f(X_i) \quad (23)$$

霜冰粒子向四周扩散, RIME 模拟霜冰生长的过程, 这一步通常会随机扰动粒子的位置, 霜冰粒子的位置会随着算法迭代而更新。位置更新如式 (24) 所示。

$$X_i^{t+1} = X_i^t + \lambda \times \text{rand} \times (X_{\text{best}}^t - X_i^t) \quad (24)$$

式中: X_i^{t+1} 是第 i 个粒子在 $t+1$ 代的位置; λ 是扩散因子, 通常为一个较小值, 用于更新步长; rand 是一个随机数, 通常在 $[0, 1]$ 范围内; X_{best}^t 是当前的最优解位置。

比较每个粒子的适应度值, 如果当前代的某个粒子优于全局最优解, 则更新全局最优解, 即:

$$X_{\text{best}}^{t+1} = \begin{cases} X_i^{t+1}, & f(X_i^{t+1}) < f(X_{\text{best}}^t) \\ X_{\text{best}}^t, & \text{其他} \end{cases} \quad (25)$$

式中: X_{best}^{t+1} 是更新后的全局最优位置; $f(X_{\text{best}}^t)$ 和 $f(X_i^{t+1})$ 分别是当前最优解和粒子的适应度值。当达到最大迭代次数或找到满足精度要求的最优解时, 算法终止并输出最优解位置 X_{best}^{t+1} 及其适应度。

RIME 具备强大的全局搜索能力, 能够在广泛的搜索空间中找到最优权重和超参数, 避免 DELM 受限于随机初始化; RIME 的自适应调整机制, 可以动态优化 DELM 的网络结构和超参数, 减少手动调参的难度。RIME 也有

助于 DELM 跳出局部最优, 减少 DELM 在复杂数据分布下的性能波动。

采用 RIME 优化算法对 DELM 的正则化系数、隐藏层数、隐藏节点数等参数进行寻优。首先初始化 RIME 的最大迭代次数、种群数量、搜索空间边界等, 并初始化 DELM 的正则化系数、隐藏层数和节点数。将 DELM 模型的性能即铝电解槽情况的异常状态分类错误率作为适应度指标, 对每个候选解在 RIME 优化算法中的适应度进行评估, 通过模拟霜冰的结晶和生长, 不断进行迭代并更新候选解的位置, 搜索全局最小适应度即为 DELM 分类器的最优参数配置, 此时的模型分类准确率最佳。RIME 对 DELM 进行优化, 提升了模型收敛速度, 避免了陷入局部最优解的情况, 提高了模型预测效果的稳定性与泛化能力。RIME-DELM 算法流程如图 1 所示。




图1 RIME-DELM 算法流程

Fig.1 RIME-DELM algorithm flow chart

2.3 模型诊断流程

为构建一种基于深度学习的多模态工业故障诊断模型, 首先采集工业设备的真实历史运行数据, 并对采集到的数据进行预处理, 利用 XGBoost 进行设备异常状态的特征选择, 通过有效降低数据维度、筛选关键变量, 得到与其异常状态相关性强的工艺参数, 以此作为模型的输入; 然后采用 DELM 提取多模态数据的复杂、高维和非线性特征, 并利用 RIME 优化 DELM 的参数, 提升模型的计算效率和稳定性, RIME-DELM 对输入的运行数据进行二分类选择, 实现对工业设备异常状态的检测; 样本通过 RIME-DELM 算法的判别后若无异常则直接输出结果, 若有异常则将信息传至下一级 DBN-LSSVM。DBN 通过逐层学习异常数据的分布特征, 捕捉其中的高维度、非线性等深层次信息, 同时降低数据维度, 去除冗余信息, 并将这些特征作信息为 LSSVM 的输入, LSSVM 基于这些高质量特征进行学习, 实现故障的精确分类, 最终建立多模态

工业故障诊断模型 DMIFD。DBN-LSSVM 结合了 DBN 的深层特征提取能力和 LSSVM 高效的小样本学习能力,在复杂工业环境、非线性建模以及多分类任务中具有明显

优势,能够有效避免传统方法在面对复杂数据时的性能下降问题,从而提高准确率和泛化能力。DMIFD 模型结构如图 2 所示,参数设置如表 1 所示。




图 2 DMIFD 模型结构

Fig. 2 DMIFD model structure diagram

表 1 DMIFD 模型参数设置

Table 1 Parameters of DMIFD model

模型	参数	值
RIME	种群数量	40
	最大迭代次数	30
	权值下边界	-1
	权值上边界	1
DELM	隐藏层数	8
	隐藏节点数	40
	正则化系数	0.01
DBN	隐藏层数	2
	隐藏层节点数	30
	学习率	0.001
	迭代次数	2 000
LSSVM	核函数参数	30
	惩罚参数	100
	正则化系数	0.01
	核函数	RBF

DMIFD 算法流程细节如算法 1 所示。

算法 1:DMIFD 算法

输入

$x = \text{load}('your_dataset_features.mat');$

$y = \text{load}('your_dataset_labels.mat');$

RIME

$\text{popsize} = 40; \text{Max_iteration} = 30; \text{lb} = -1; \text{ub} = 1;$

$\text{fobj} = @ (X) \text{fun} (X, p_train, t_train, \text{ELMAEhiddenLayer},$

$\text{ActivF}, C);$

$[\text{Best_score}, \text{Best_pos}, \text{Curve}] = \text{RIME}(\text{popsize}, \text{Max_iteration}, \text{lb}, \text{ub}, \text{dim}, \text{fobj});$

DELM

$\text{ELMAEhiddenLayer} = [8, 40]$

$\text{ActivF} = 'hardlim'$

$C = \text{inf};$

$\text{BestWeight} = \text{Best_pos};$

$\text{OutWeight} = \text{DELMTrainWithInitial}(\text{BestWeight}, p_train, t_train, \text{ELMAEhiddenLayer}, \text{ActivF}, C);$

$T_sim1 = \text{DELMPredict}(p_train, \text{OutWeight}, \text{ELMAEhiddenLayer});$

$T_sim2 = \text{DELMPredict}(p_test, \text{OutWeight}, \text{ELMAEhiddenLayer});$

$[\text{accuracy}, \text{f1score}] = \text{evaluate}(T_test, \text{ylabel});$

DBN-LSSVM

$f_ = \text{size}(p_train, 1);$

$\text{hidden} = [f_, 30, 30]$

$\text{lr_rbm} = 0.001;$

$\text{epoch_rbm} = 2\,000;$

$\text{type} = 'c';$

$\text{kernel_type} = 'RBF_kernel';$

$\text{codeftc} = 'code_OneVsOne'$

$g = 30;$

$c = 100;$

$\text{WI} = \text{stepdbn}(p_train, \text{hidden}, \text{lr_rbm}, \text{epoch_rbm});$

$\text{Feather_1} = \text{dbn_ff}(p_train, \text{hidden}, \text{WI});$

$\text{Feather_2} = \text{dbn_ff}(p_test, \text{hidden}, \text{WI});$

$\text{model} = \text{initlssvm}(\text{Feather_1}, t_train, \text{type}, c, g, \text{kernel_type}, \text{codeftc});$

$\text{model} = \text{trainlssvm}(\text{model});$

```
t_sim1 = simlssvm(model, Feather_1);  
t_sim2 = simlssvm(model, Feather_2);  
[accuracy, f1score] = evaluate(T_test, ylabel);
```

3 应用案例研究

为验证所提方法的有效性和泛化性,通过工业案例进行性能测试。铝电解的生产环境恶劣,受电场、磁场、流场、温度场、应力场等相互耦合影响,导致生产过程中故障频发^[35],铝电解槽内的反应过程是一个非线性、多变量耦合、时变和时滞的复杂工业过程体系,且铝电解工艺参数具有多模态、高维度和非线性等特点,因此选用铝电解生产过程作为本实验的工业案例。将所提出的多模态工业故障诊断方法应用于铝电解生产过程,建立铝电解的 DMIFD 模型,并利用铝电解实际生产数据进行现场实验。

现代铝电解工艺采用炭素阳极,由专门的阳极组装车间生产。铝电解所需的直流电来自动力车间,由交流电经变电所和整流所转换得到,再通过母线传输到铝电解槽用以电解反应。电解车间中的铝电解槽是发生铝电解反应的场所,在铝电解槽中反应生成的熔融铝液用真空抬包从铝电解槽内吸出,运往铸造车间制作铝锭。阳极发生的氧化反应会产生大量 CO₂,少量 CO、HF、SO₂ 等混合气体,产生的废气经烟气净化系统进行净化处理后排放,烟气中的氧化铝粉末则经过净化系统中的袋式除尘器过滤,得到载氟氧化铝,再将其作为原料送至铝电解槽参与电解反应。铝电解的生产工艺流程如图 3 所示。




图 3 铝电解工艺流程

Fig. 3 Aluminium electrolysis process flow chart

3.1 数据采集与预处理

采集某铝业公司 400 kA 系列铝电解槽 2023 年 10 月至 2025 年 3 月的真实历史运行数据,共采集了 6 552 个样本,其中正常状态样本 3 365 个,异常状态样本 3 187 个,DMIFD 模型诊断流程如图 4 所示,具体实验设置如表 2 所示。




图 4 DMIFD 模型诊断流程

Fig. 4 DMIFD model diagnosis process

表 2 数据采集信息

Table 2 Data acquisition information

实验参数	数值
数据获取时间	2023 年 10 月至 2025 年 03 月
铝电解槽数量	37(2075 [#] 槽-2111 [#] 槽)
样本数量	6 552
正常样本数量	3 365
异常样本数量	3 187
特征数量	12
训练集/测试集	7:3

首先对采集到的原始数据进行异常值的剔除,然后对数据中的缺失值进行填充,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。为了将每个特征参数的量纲转化到同一范围,消除不同量纲带来的影响,提高模型预测的准确性,采用 Min-Max 方法将数据缩放到 [0,1],实现数据的归一化处理。

为了客观评价模型的性能,采用机器学习中分类模型常用的评价指标准确率和 F1-score 作为铝电解槽况分级诊断模型的评价指标。准确率 (accuracy) 是指诊断正确的样本数与总样本数之比,F1-score 是精确率和召回率的调和平均值,F1-score 越接近 1 时,模型的性能更佳。针对铝电解槽具体故障诊断的多分类问题,引入宏平均 (macro average),通过计算出所有类别的精确率和召回率及其 F1-score,再通过求平均值得到在整个样本上的 Macro-F1 分数。

3.2 XGboost 特征选择

本研究共采集到 17 种输入参数,具体包括系列电流、系列电压、槽工作电压、槽平均电压、Al₂O₃ 加料量、Al₂O₃ 加料次数、噪声、阳极行程、电解温度、分子比、AlF₃ 下料量、铝水平、电解质水平、出铝量、Fe 含量、Si 含量、

阳极效应系数。由于铝电解生产现场电场、磁场、流场、热场、应力场和浓度场耦合性强,且铝电解槽的工艺参数复杂多样,具有非线性、高维度和强相关性等特点,只依靠铝电解工艺机理分析不能准确确定影响铝电解槽况的主要工艺特征参数,因此需要对输入变量进行筛选,剔除无关特征,提高模型的诊断效率和准确性。将采集到的 17 个工艺参数作为输入,利用 XGBoost 算法对输入变量进行铝电解槽异常状态的特征选择,各工艺参数重要度排序如图 5 所示。其中,与铝电解槽况相关性最强的是电解温度,重要度达 0.56。从中剔除了重要度较低的特征,包括加料次数、平均电压、系列电压、系列电流、AlF₃ 下料量,最终筛选出 12 个特征向量作为判断铝电解槽是否处于异常状态的最优特征子集,如表 3 所示。




图 5 工艺参数槽况特征重要度排序

Fig. 5 Importance ranking of cell condition features based on process parameters

表 3 铝电解槽况相关工艺参数

Table 3 Process parameters related to aluminium electrolytic cell conditions

序号	特征参数
X1	电解温度
X2	工作电压
X3	阳极效应次数
X4	铝水平
X5	阳极行程
X6	噪声
X7	出铝量
X8	Fe 含量
X9	电解质水平
X10	Si 含量
X11	分子比
X12	加料量

3.3 槽况分级评价指标

在铝电解生产过程中,铝电解槽发生故障时会引起相应工艺参数的变化,通过维持工艺参数在合理的范围内可以确保生产过程正常运行。在铝电解生产过程中,铝电解槽发生故障时会引起相应工艺参数的变化。例如高温导致氧化铝的溶解速度加快,槽内可能因氧化铝供给不足,引发阳极效应;发生阳极效应时,槽电压会急剧升高,铝液界面发生波动,电解温度随之上升。发生热槽故障时,电解温度很高,电解质水平升高,出铝量减少。发生冷槽故障时,电解温度显著降低,槽电压和氧化铝溶解速率下降。发生侧部漏槽时,电解温度会升高,侵蚀侧部耐火材料,使铝液中 Si 含量升高;发生底部漏槽时,阴极钢棒和底部内衬材料会被熔化,铝液中 Fe 含量和 Si 含量升高。发生滚铝故障时,铝液面和电解质液面会大幅波动,电流效率下降。根据上述分析以及铝电解生产现场的实验验证,确定铝电解槽槽况分类的评价指标如表 4 所示,将样本进行分类后得到状态标签及样本分布如表 5 所示。

表 4 铝电解槽况分级评价指标

Table 4 Aluminium electrolysis cell condition classification evaluation indicators

类别	评价指标	故障类型
1	电解温度>975℃	热槽
2	电解温度<950℃	冷槽
3	电解温度>970℃且槽电压>4.1 V	阳极效应
4	Fe 含量>0.2%或 Si 含量>0.08%	漏槽
5	铝水平变化量≥5 cm 或铝水平>30 cm 或铝水平<23 cm 或电解质水平变化量≥6 cm 或电解质水平>25 cm 或电解质水平<12 cm	滚铝

表 5 铝电解槽况标签及样本分布

Table 5 Aluminum electrolytic cell condition label and sample distribution

样本数	状态	标签
3 365	正常	0
740	热槽	1
433	冷槽	2
470	阳极效应	3
538	漏槽	4
147	滚铝	5
420	热槽+阳极效应	6
103	热槽+滚铝	7
180	热槽+漏槽	8
156	冷槽+漏槽	9

3.4 模型诊断结果

本研究共采集了 6 552 个样本,其中正常状态样本 3 365 个,异常状态样本 3 187 个,按 7:3 将其随机划分为训练集和测试集,训练集用于模型的训练,测试集用于评估模型的性能,最终 DMIFD 模型的铝电解槽异常状态检测结果如图 6 所示。测试集的 1 966 个数据样本中,基于 RIME-DELM 的异常状态检测模型正确的个数为 1 926 个,模型的 accuracy 为 97.96%, F1-score 为 0.975 3,模型运行时间为 54.82 s。




图6 DMIFD模型的异常状态检测结果

经第 1 级诊断为异常的样本输入第 2 级 DBN-LSSVM 做出具体的故障类型诊断,同样将 3187 个异常状态样本按照 7:3 随机划分为训练集和测试集,最终 DMIFD 模型的铝电解槽故障类型诊断结果如图 7 所示。测试集的 956 个数据样本中,基于 DBN-LSSVM 的铝电解槽故障类型模型诊断正确的个数为 925 个,模型的准确率为 96.75%, Macro-F1 分数为 0.944 7,模型运行时间为 67.34 s。




图7 DMIFD模型的故障类型诊断结果

Fig. 7 Fault type diagnosis results of DMIFD model

3.5 消融实验对比分析

为表明本研究所提模型优化点的有效性,进行了消融实验。在相同的数据集下,采用未经 RIME 优化的 DELM 对铝电解槽异常状态进行检测;在相同的异常状态铝电解槽数据集下,对比验证了 DBN-LSSVM 铝电解槽故障类型诊断模型的性能,DMIFD 模型消融实验性能对比结果如图 8 所示。




图8 DMIFD模型消融实验性能对比

Fig. 8 Comparison of the performance of DMIFD model ablation experiments

结果显示,RIME 优化后的 DELM 的准确率和 F1-score 分别提高了 6.42% 和 6.9%,RIME 通过全局搜索机制,优化 DELM 的隐藏层权重,使其分布更加合理;同时自适应调整超参数,提高了 DELM 训练的自动化程度,找到最佳参数配置,提升模型性能;此外,通过动态搜索机制,提高了 DELM 对不同数据分布的适应能力,增强其在复杂工业任务中的适用性。

DBN-LSSVM 相较于 DBN 和 LSSVM 在准确率上分别提高 3.07% 和 5.71%,在 Macro-F1 分数上分别提高了 3.31% 和 4.18%。实验数据充分证明,经过 DBN 深度层次提取铝电解工艺参数的高维和非线性特征,同时降低数据维度,去除冗余信息,配合 LSSVM 的高效计算能力和结构风险最小化能力,提升了模型的诊断准确率和稳定性,DBN-LSSVM 更适用于多模态的复杂工业建模。

3.6 不同分类算法对比分析

CNN 具有强大的特征提取能力和处理高维数据的能力,是目前应用最广泛的深度学习故障诊断方法之一。CNN 与 SVM 结合,CNN 用于提取深度特征,SVM 进行分类,适用于小样本、高精度和高维数据分类任务;CNN-LSTM 能够提取数据高维特征和时序性,适用于复杂工业设备状态预测;将 CNN 与随机森林 (random forest, RF) 结合,可以自动提取特征和特征选择,在小样

本下的泛化能力强。为了验证 DMIFD 模型的性能,在相同的数据集下单独建立 CNN-SVM、CNN-LSTM 和 CNN-RF 模型,并采用准确率和 F1-score 对 3 个模型性能进行对比验证。

铝电解槽异常状态检测实验结果如图 9 所示,铝电解槽故障类型诊断实验结果图 10 所示。通过对比实验验证,DMIFD 在准确率和 F1-score 方面具有更出色的性能,与 CNN-SVM、CNN-LSTM、CNN-RF 相比,DMIFD 模型的铝电解槽异常状态检测准确率和 F1-score 分别提高了 3.91% 和 4.99%、3.32% 和 4.18%、4.6% 和 5.85%。故障类型诊断的准确率和 Macro-F1 分数相较于 CNN-SVM、CNN-LSTM 和 CNN-RF 分别提高了 1.76% 和 0.65%、2.67% 和 1.05%、2.29% 和 1.4%。SVM 和 RF 无法处理时间序列数据;CNN-LSTM 的参数较多,训练时间长;CNN-SVM、CNN-LSTM、CNN-RF 难以处理多模态的复杂工业数据,实验证明 DMIFD 模型更能准确地进行多模态的工业故障诊断。




图 9 不同分类算法的异常状态检测性能对比

Fig. 9 Comparison of abnormal state detection performance of different classification algorithms




图 10 不同分类算法的故障类型诊断性能对比

Fig. 10 Comparison of fault type diagnosis performance of different classification algorithms

3.7 不同优化算法对比分析

为了验证 DMIFD 在铝电解槽异常状态检测模型上的适用性,采用常见的优化算法与 RIME 做对比实验。遗传算法 (genetic algorithm, GA) 通过选择、交叉、变异进行种群优化,适用于复杂的全局优化问题,但其计算复杂度高,收敛较缓慢。粒子群优化算法 (particle swarm optimization, PSO) 收敛速度快,计算复杂度低,但易陷入局部最优,不适合复杂的全局搜索问题。北方苍鹰优化算法 (northern goshawk optimization, NGO) 通过全局搜索和局部搜索结合的方式进行优化,避免陷入局部最优,适合高维优化问题。将测试集的分类测试错误率作为目标函数值,搜索目标函数的全局最小值 (适应度)。

如图 11 所示,RIME 的适应度最小为 0.020 4,即测试集的分类错误预测率为 2.04%。RIME 优化后 DELM 的准确率和 F1-score 相对于 GA-DELM、PSO-DELM 和 NGO-DELM,分别提高了 4.16% 和 4.41%、2.92% 和 3.48%、2.45% 和 2.85%。结果表明,RIME 通过优化 DELM 参数,提升了 DELM 多模态数据的学习能力,因此 RIME 对 DELM 的优化性能更佳。




图 11 不同优化算法的异常状态检测性能对比

Fig. 11 Comparison of abnormal state detection performance of different optimization algorithms

4 结 论

针对工业数据的非线性、高维度、强关联性、类别不平衡特征,以及存在冗余数据和异常值影响等问题,本文提出了一种基于深度学习的多模态工业故障诊断方法 DMIFD,并通过铝电解的实际生产运行数据进行测试,主要结论为:

1) 采用 XGBoost 筛选与工业设备故障相关的工艺参数,包括温度、电压、电流等多模态数据,作为模型的输入。面对复杂动态的工业环境,采用 DELM 提取工业数据的多模态和复杂非线性特征,RIME 优化后的 DELM

对不同数据分布的适应能力显著提升,能更好地处理数据间的复杂非线性关系,提升分类性能。构造的故障类型判别的模块,结合了 DBN 强大的特征提取能力和 LSSVM 高效的分类能力。在处理维度高、冗余多的工业数据时,DBN 通过逐层训练可以自动降维,提取最具代表性的特征,并通过多层网络自动学习数据的不同特征层,减少冗余信息,使 LSSVM 在多分类任务中更容易学习复杂的决策边界,能够有效避免传统方法在面对复杂数据时的性能下降问题,从而提高模型的准确率和泛化能力。

2) 将该方法应用于铝电解生产过程进行性能验证,实验结果表明,所提出的 DMIFD 模型在铝电解槽异常状态检测任务上的准确率为 97.96%,F1-score 为 0.975 3,在铝电解槽故障诊断任务上的 accuracy 为 96.75%,Macro-F1 分数为 0.944 7。通过消融实验、与其他深度学习算法 CNN-SVM、CNN-LSTM、CNN-RF 和优化算法 GA、PSO、NGO 进行的实验进一步证明了本模型在处理复杂高维数据中的优异性能。

3) 由于铝电解槽故障的发生是一个连续而缓慢的过程,且构建的 DMIFD 模型运行时间较短,满足铝电解槽在运行时故障诊断的速率,实现了铝电解槽早期槽况检测和实时故障诊断,因此该方法能够实现复杂工况下工业设备的异常状态检测与故障类型诊断。该方法有助于现场工人及时采取措施避免故障的发生,提高工业的安全生产和智能化管理水平。

参考文献

- [1] 曹源,宋迪,胡小溪,等. 基于改进时域多尺度散布熵与支持向量机的转辙机故障诊断[J]. 电子学报, 2023, 51(1): 117-127.
CAO Y, SONG D, HU X X, et al. Fault diagnosis of railway point machine based on improved time-domain multiscale dispersion entropy and support vector machine[J]. Acta Electronica Sinica, 2023, 51(1): 117-127.
- [2] JIA S X, SUN D Y, NOMAN K, et al. Lifting wavelet-informed hierarchical domain adaptation network: An interpretable digital twin-driven gearbox fault diagnosis method[J]. Reliability Engineering and System Safety, 2025, 254: 110660.
- [3] HOSSEINI S M, DIBAJI A, SULAIMANY S. Graph-based feature engineering for enhanced machine learning in rolling element bearing fault diagnosis[J]. Engineering Research Express, 2024, 6(4): 045234.
- [4] AFIA A, GOUGAM F, TOUZOUT W, et al. Spectral proper orthogonal decomposition and machine learning algorithms for bearing fault diagnosis[J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2023, 45(10): 550.
- [5] NAMBIAR A, ARAVINTH S, SUGUMARAN V, et al. Prediction of air compressor faults with feature fusion and machine learning[J]. Knowledge-Based Systems, 2024, 304: 112519.
- [6] WEI W, JIANG Y L, YIN J Y, et al. Research on fault diagnosis of transmission lines based on machine learning[J]. Academic Journal of Engineering and Technology Science, 2024, 7(3): 166-172.
- [7] KHAN M M, ISLAM I, RASHID A B. Fault diagnosis of an industrial chemical process using machine learning algorithms: Principal component analysis (PCA) and kernel principal component analysis (KPCA)[J]. IOP Conference Series: Materials Science and Engineering, 2024, 1305(1): 012037.
- [8] 吴选军,王超,曹子健,等. 数据与物理信息混合驱动固定床吸附穿透深度学习模型[J]. 化工学报, 2023, 74(3): 1145-1160.
WU X J, WANG CH, CAO Z J, et al. Deep learning model of fixed bed adsorption breakthrough curve hybrid-driven by data and physical information[J]. CIESC Journal, 2023, 74(3): 1145-1160.
- [9] 李婕,张新月,涂静敏,等. 基于多层注意力和度量学习的商品识别方法[J]. 电子测量技术, 2025, 48(1): 137-144.
LI J, ZHANG X Y, TU J M, et al. A commodity recognition method based on multi-layer attention and metric learning[J]. Electronic Measurement Technology, 2025, 48(1): 137-144.
- [10] 冷冰,冷敏,常智敏,等. 基于 Transformer 结构的深度学习模型用于外周血白细胞检测[J]. 仪器仪表学报, 2023, 44(5): 113-120.
LENG B, LENG M, CHANG ZH M, et al. Deep learning model based on Transformer architecture for peripheral blood leukocyte detection[J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 113-120.
- [11] YIN G, LI Y H, YAN F Y, et al. Deep learning for electrolysis process anode effect prediction based on long short-term memory network and stacked denoising autoencoder[J]. Rare Metals, 2024, 43(12): 6730-6741.
- [12] 金姝,罗家童,高雅,等. 基于深度学习的光纤微震信号分类识别的研究[J]. 电子测量与仪器学报, 2024, 38(6): 135-142.
JIN SH, LUO J T, GAO Y, et al. Deep learning-based classification and identification of fiber optic microseismic

- signals[J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(6): 135-142.
- [13] WU J L, LIN L, LIU D, et al. Deep hierarchical sorting networks for fault diagnosis of aero-engines[J]. *Computers in Industry*, 2025, 165: 104229.
- [14] GAO L, LIU ZH H, GAO Q H, et al. Dual data fusion fault diagnosis of transmission system based on entropy weighted multi-representation DS evidence theory and GCN[J]. *Measurement*, 2025, 243: 116308.
- [15] FENG Y P, LIU P, DU Y X, et al. Cross working condition bearing fault diagnosis based on the combination of multimodal network and entropy conditional domain adversarial network[J]. *Journal of Vibration and Control*, 2024, 30(23/24): 5375-5386.
- [16] SONG Q J, WANG J X, SONG Q H, et al. Fault diagnosis of HVCB via the subtraction average based optimizer algorithm optimized multi channel CNN-SABO-SVM network[J]. *Scientific Reports*, 2024, 14(1): 29507.
- [17] WEI Z Q, WANG H, ZHAO ZH B, et al. Gearbox fault diagnosis based on temporal shrinkage interpretable deep reinforcement learning under strong noise[J]. *Engineering Applications of Artificial Intelligence*, 2025, 139: 109644.
- [18] 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.
- [19] 张朝龙, 何怡刚, 杜博伦. 基于 DBN 特征提取的模拟电路早期故障诊断方法[J]. *仪器仪表学报*, 2019, 40(10): 112-119.
- ZHANG CH L, HE Y G, DU B L. Analog circuit incipient fault diagnosis method based on DBN feature extraction[J]. *Chinese Journal of Science Instrument*, 2019, 40(10): 112-119.
- [20] ARIF M K, KATHIRVELU K. Automated driver health monitoring system in automobile industry using WOA-DBN using ECG waveform[J]. *Optical Memory and Neural Networks*, 2024, 33(3): 308-325.
- [21] PAN T, WANG H B, SI H Q, et al. Research on identification of flight cadets' cognitive load based on multi-source physiological data and CGAN-DBN model[J]. *Ergonomics*, 2025, 68(5): 737-755.
- [22] LIU G R, CHENG X Y, DAI H L, et al. Fault diagnosis of universal circuit breakers based on variational mode decomposition and WOA-DBN[J]. *Applied Sciences*, 2024, 14(11): 4928.
- [23] 鲁春燕, 李炜. 基于深度置信网络的炼化空压机故障诊断方法[J]. *化工学报*, 2019, 70(2): 757-763.
- LU CH Y, LI W. Fault diagnosis method of refining air compressor based on deep trust network[J]. *CIESC Journal*, 2019, 70(2): 757-763.
- [24] WANG H M, LI Z S, PAN J, et al. Frequency prediction of a post-disturbance power system using a hybrid ARIMA and DBN model[J]. *Frontiers in Energy Research*, 2024, 12: 1363873.
- [25] XIAO SH SH, LIU J, MA Y J, et al. Combined prediction of dust concentration in opencast mine based on RF-GA-LSSVM[J]. *Applied Sciences*, 2024, 14(18): 8538.
- [26] ZHANG S L, CHANG Y T, LI H, et al. Research on building energy consumption prediction based on improved PSO fusion LSSVM model[J]. *Energies*, 2024, 17(17): 4329.
- [27] GUAN SH, WU Y T, YANG Q H. Research on transformer fault diagnosis method based on ACGAN and CGWO-LSSVM[J]. *Scientific Reports*, 2024, 14(1): 17676.
- [28] ZHAO S X, MA Y ZH, LIU M N, et al. Assembly quality inspection of combine harvester based on whale algorithm optimization LSSVM[J]. *Shock and Vibration*, 2022, 2022(1): 5181360.
- [29] 颜学龙, 马润平. 基于深度极限学习机的模拟电路故障诊断[J]. *计算机工程与科学*, 2019, 41(11): 1911-1918.
- YAN X L, MA R P. Analog circuit fault diagnosis based on deep limit learning machine[J]. *Computer Engineering and Science*, 2019, 41(11): 1911-1918.
- [30] CHEN X, YAO L H, WANG Y D. A Novel ISSA-DELM model for predicting rock mass permeability[J]. *Computer Modeling in Engineering & Sciences*, 2024, 140(3): 2825-2848.
- [31] DAI Y, PANG J, RUI X K, et al. Thermal error prediction model of high-speed motorized spindle based on DELM network optimized by weighted mean of vectors algorithm[J]. *Case Studies in Thermal Engineering*, 2023, 47: 103054.
- [32] ZHOU Y F, WANG SH L, XIE Y X, et al. Remaining useful life prediction and state of health diagnosis for lithium-ion batteries based on improved grey wolf optimization algorithm-deep extreme learning machine

algorithm[J]. Energy, 2023, 285: 128761.

- [33] REDDY K N, THILLAIKARASI M, KUMAR B S, et al. A novel elephant herd optimization model with a deep extreme learning machine for solar radiation prediction using weather forecasts [J]. The Journal of Supercomputing, 2022, 78(6): 8560-8576.
- [34] SU H, ZHAO D, HEIDARI A A, et al. RIME: A physics-based optimization[J]. Neurocomputing, 2023, 532: 183-214.
- [35] 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.

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, artificial intelligence, as well as detection and monitoring technologies for aluminum electrolytic smelting.



朱淼, 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.



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 data mining in metallurgical processes.



王怀江, 1995年于贵州工学院获得学士学位, 现为中铝郑州研究院正高级工程师, 主要研究方向为铝镁冶炼及炭素、智能装备及深度学习、人工智能、高纯铝。

E-mail: zyy_wanghj@rilm.com.cn

Wang Huaijiang received his B.Sc. degree from Guizhou Institute of Technology in 1995. Now he is a senior engineer of Chinalco Zhengzhou Research Institute. His research interests include aluminum-magnesium smelting and carbon, intelligent equipment and deep learning, artificial intelligence, and high-purity aluminum.



江茂华, 2000年于四川大学获得学士学位, 现为重庆高峰新材料科技有限公司高级工程师, 主要研究方向为铝及铝合金熔炼。

E-mail: jiang780110@sina.com

Jiang Maohua received his B.Sc. degree from Sichuan University in 2000. Now he is a senior engineer at Chongqing Gaofeng New Materials Technology Co., Ltd. His research interests include aluminum and aluminum alloy smelting.



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, M.Sc. degree from Southwest Jiaotong University in 2004, and 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.