

基于专家经验引导的浮选泡沫图像表征学习

张进¹ 黄嘉豪¹ 艾明曦² 唐朝晖³ 谢永芳³ 马军¹

摘要 矿浆品位等关键指标难以通过传感器在线直接测量, 研究利用易获取的过程运行数据与泡沫图像间接估计矿浆品位的软测量方法具有重要工程意义. 针对传统泡沫图像表征方法表征能力不足且泛化性差的问题, 提出专家经验引导的泡沫图像表征学习方法. 该方法由分布特征隔离网络与经验引导表征学习两部分构成: 前者将泡沫图像映射至尺寸、颜色、纹理等具有明确工艺解释意义的视觉属性子空间, 以及用于补充隐性判别信息的数据特征子空间, 实现结构化的视觉属性表征; 后者通过构造模拟人工视觉判断过程的对比学习机制, 引导模型在各子空间中学习与专家经验一致的判别特征, 建立视觉属性子空间与专家知识之间的显式对应关系. 基于中国某铅锌浮选厂的工业数据实验结果表明, 所提方法在锌、铅、铁底流品位软测量中的决定系数较近期提出的软测量模型 DEFIE 分别提升 3.97%、1.97% 和 2.40%.

关键词 泡沫浮选; 软测量; 表征学习; 知识嵌入

引用格式 张进, 黄嘉豪, 艾明曦, 唐朝晖, 谢永芳, 马军. 基于专家经验引导的浮选泡沫图像表征学习. 自动化学报, 2026, 52(6): 1245-1259

DOI 10.16383/j.aas.c250628 **CSTR** 32138.14.j.aas.c250628

Expert Experience Informed Flotation Froth Image Representation Learning

ZHANG Jin¹ HUANG Jia-Hao¹ AI Ming-Xi² TANG Zhao-Hui³ XIE Yong-Fang³ MA Jun¹

Abstract Key indicators, such as slurry grade, are difficult to measure directly online using sensors. Soft sensing approaches that indirectly estimate slurry grade by integrating easily obtainable process operation data with froth images are of considerable engineering importance. To address the limitations of insufficient representation and poor generalization of conventional froth image representation methods, this paper proposes an expert experience informed froth image representation learning method. It consists of distributed feature isolation network and experience informed representation learning. The former projects froth images into visual attribute subspaces with explicit kinetic meanings, including size, color, and texture, together with a data feature subspace that complements implicit discriminative information, thereby achieving structured visual attribute representations; The latter constructs a contrastive learning mechanism that mimics the human visual judgment process, which guides the model to learn discriminative features in each subspace that are consistent with expert experience, thus establishing explicit correspondence between visual attribute subspaces and expert knowledge. Experimental results based on industrial data from a lead-zinc flotation plant in China demonstrate that, compared to the latest proposed soft sensing DEFIE model, the proposed method improves the coefficient of determination for Zn, Pb, and Fe in tailing grade soft sensing by 3.97%, 1.97%, and 2.40%, respectively.

Keywords froth flotation; soft sensing; representation learning; knowledge embedding

Citation Zhang Jin, Huang Jia-Hao, Ai Ming-Xi, Tang Zhao-Hui, Xie Yong-Fang, Ma Jun. Expert experience informed flotation froth image representation learning. *Acta Automatica Sinica*, 2026, 52(6): 1245-1259

收稿日期 2025-11-13 录用日期 2026-01-28
Manuscript received November 13, 2025; accepted January 28, 2026

国家自然科学基金 (62303201, 62303404, 62171476, 62233018), 云南省基础研究计划项目 (202401CF070111, 202401CF070171, 202301BE070001-049) 资助

Supported by National Natural Science Foundation of China (62303201, 62303404, 62171476, 62233018) and Yunnan Fundamental Research Projects (202401CF070111, 202401CF070171, 202301BE070001-049)

本文责任编辑 赫然

Recommended by Associate Editor HE Ran

1. 昆明理工大学信息工程与自动化学院 昆明 650500 2. 云南大学信息学院 昆明 650500 3. 中南大学自动化学院 长沙 410083

1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500
2. School of Information Science and Engineering, Yunnan University, Kunming 650500
3. School of Automation, Central South University, Changsha 410083

泡沫浮选是一种广泛应用于有色金属、黑色金属及非金属等矿物分选的有效方法. 该方法基于表面物理化学原理, 利用浮选药剂使目标矿物颗粒产生疏水性, 附着于气泡表面并随气泡上浮形成泡沫层, 经刮板刮出获得精矿产品, 而亲水性脉石颗粒留在矿浆中并随其排出形成尾矿^[1-3]. 当前国内多数选矿厂仍以“人工观测、经验调控”为主, 存在决策随意性强、工况波动频繁、资源利用率低等问题^[4]. 因此, 浮选过程在线监测对提高矿物分选效率、提升企业综合经济效益至关重要. 然而, 矿浆品位等关键质量指标难以在线直接测量. 借助机器视觉技术, 利用易获取的过程运行数据与泡沫图像对矿

浆品位进行间接估计,可为浮选过程优化控制提供实时、客观的决策依据^[5-7].但在实际工业应用中,矿石来源复杂、矿物性质差异显著、生产工况多变,对泡沫图像表征的区分能力及模型泛化性提出更高要求^[8-9].

近年来,研究者提出特征工程与深度学习两类图像表征方法^[10].其中,特征工程通过提取手工特征量化专家经验,即操作人员在生产过程中总结的气泡尺寸、颜色及纹理等视觉模式与泡沫层含矿量之间的判别规律.具体而言,通过图像分割统计气泡尺寸以表征矿物附着率,利用颜色统计量反映泡沫层矿物附着类型,并通过纹理粗糙度间接揭示泡沫中疏水性杂质的含量^[11].然而,此类方法在充分刻画视觉模式方面存在局限:一方面,专家对泡沫状态的判断往往基于多属性、多视角的综合视觉感知,而现有手工特征多为低维统计量,难以刻画泡沫视觉模式的多属性关系;另一方面,部分关键视觉现象(如杂质粘附形成的非均匀纹理)缺乏明确的物理定义和可计算的统一描述子,导致手工特征难以稳定表达复杂泡沫图像中的高阶抽象信息^[12].相比之下,深度学习方法通过大规模标注图像数据自动学习与工况相关的视觉模式,在表征能力上具有显著优势.然而,其性能高度依赖训练数据的丰富性与代表性,当工况复杂多变且不同工段间数据分布差异较大时,难以保持稳定的泛化性,限制了其在工业场景中的应用^[8].

为克服上述两类方法的局限,研究者结合手工特征在工况演变下的强泛化性与深度学习的强表征能力,进一步提出数据与知识双驱动的图像表征策略^[13].例如,部分研究利用手工特征引导的蒸馏学习^[13]、自适应特征选择^[8]或分层工况感知^[14]等实现知识与数据的结合.然而,这些方法停留在特征层或决策层的简单融合,难以在模型结构和学习机制中深度注入专家经验.为此,本文提出基于专家经验引导的泡沫图像表征学习(experience informed froth image representation learning, EI-FIRL)方法.该方法包含分布特征隔离网络与经验引导表征学习两部分:分布特征隔离网络通过图像嵌入表征学习、视觉属性划分及多视角关联建模等模块,在嵌入空间中归纳泡沫图像的抽象视觉模式,并将其分解为尺寸、颜色和纹理等具有明确工艺解释意义的视觉属性子空间,以及用于承载难以明确归属于上述属性,但与品位变化密切相关的隐性判别信息的数据特征子空间,同时刻画各子空间内部的多视角关联关系;经验引导表征学习通过构造具有特定视觉属性差异的训练样例并引入对比学习机制,引

导表征模型在尺寸、颜色和纹理等关键视觉属性维度上形成与专家经验一致的判别性特征响应,从而以数据驱动的方式学习与领域专家观测逻辑一致、具有物理可解释性的泡沫图像表征.基于铅锌浮选工业数据的底流品位估计实验及钨浮选工况识别实验表明,所提 EI-FIRL 方法显著提升了浮选过程监测的准确性与泛化性.

本文贡献主要包含以下两方面:1) 提出分布特征隔离网络,将泡沫图像的复杂视觉模式分解到尺寸、颜色、纹理和数据四个结构化的特征子空间,各子空间侧重刻画某一主导视觉属性下的判别性变化特征,实现泡沫图像结构化表征;2) 从专家视觉判定逻辑出发,提出经验引导表征学习,使模型在各关键视觉属性维度上形成与人工判别过程一致的特征响应,为深度模型注入专家感知经验.

本文整体结构如下:第1节介绍相关工作;第2节介绍 EI-FIRL 算法,包括分布特征隔离网络与经验引导表征学习;第3节介绍铅锌浮选过程,并通过实验对比验证 EI-FIRL 的有效性 & 先进性;第4节对全文进行总结及展望.

1 相关工作

1) 表征模型

特征工程及深度学习是浮选泡沫图像表征的两大主流方法.在特征工程方面,研究者通常依据浮选操作人员的长期观测经验,设计与泡沫品位相关的手工特征.一般而言,泡沫品位越高,气泡间挤压形变越明显,表现为气泡尺寸减小、纹理粗糙度增加、泡沫破碎率降低等视觉特征变化.为此,文献^[15]基于标记分水岭算法分割气泡,并提取等效直径与形态特征.文献^[6]通过光照建模改进气泡尺寸分割精度并利用 LogNormal 拟合尺寸分布.文献^[16]采用 Gabor 小波建立泡沫图像在多尺度、多方向下的纹理统计分布模型.文献^[17]进一步利用 Copula 模型融合 Gabor 纹理的实部谱、虚部谱与幅度谱的关联关系.文献^[11]综合气泡尺寸、颜色、纹理与稳定性等多种特征实现浮选过程监测.尽管此类方法基于物理属性构建特征,在一定程度上体现人工观测规律,但特征表达能力依赖于气泡分割精度与人工描述子设计,特征区分能力受限.

在深度学习方面,部分研究通过构建深度神经网络,从图像数据中自动学习与专家观测经验一致的手工特征.例如,文献^[18]提出基于对抗神经网络的颜色特征提取方法.文献^[19]采用掩码卷积神经网络实现泡沫图像分割.文献^[20]提出面向泡沫形态特征的深度学习方法.这些方法虽可提高手工

特征提取准确性,但仍难以稳定表达复杂泡沫图像中的高阶抽象信息.为此,更多的研究者通过卷积神经网络直接从图像数据中学习抽象视觉模式.文献[21]通过自定义卷积神经网络进行泡沫图像表征.文献[5,9,22]利用多尺度卷积核并列的 GoogLeNet,增强对不同尺度气泡特征的提取能力.为表征泡沫图像序列的动静态特征,文献[2]构建双流网络,联合注意力机制与帧间光流矢量场提取动态信息,并通过 DenseNet 捕捉静态模式.尽管深度学习在特征表达上具有显著优势,但其性能高度依赖大规模标注样本,在实际工业过程监测下的泛化性有待提升.此外,文献[4]从泡沫层由不同矿化气泡群上浮聚合而成的视觉机理出发,提出一种融合全局视觉模式与气泡群间局部视觉模式关联的数据高效表征模型.该方法在一定程度上利用了泡沫视觉形成机理,但尚未显式引入浮选操作人员的观测经验.

2) 知识嵌入

近年来,研究者广泛探索如何将先验知识融入深度学习模型,形成数据与知识融合或知识引导的学习范式^[23].在知识融合方面,部分研究通过显式结合手工特征与学习特征以提升模型泛化性.例如,文献[24]通过拼接方式融合依据先验知识设计的手工特征与学习特征用于检测任务.文献[25]在多标签分类中以视觉与语义原型构建异构词嵌入先验,通过图卷积建模标签依赖关系.文献[26]利用基于先验知识的结构分析法做故障预分析,并以此构建邻接矩阵实现融合先验知识的图网络故障诊断.文献[27]根据浮选子工序物质关联关系及子工序样例标签一致性构建图网络.文献[28]将浮选动力学机理模型与泡沫图像特征相结合,构建多模态协同建模方法,并通过基于图像序列的数据模型对机理模型进行误差补偿,以适应工况变化.文献[14]提出分层工况感知方法,首先基于手工特征与模糊推理进行工况初判,再针对处于模糊决策边界的样本引入深度特征进行二次识别.文献[8]提出基于重构误差评价的自适应特征选择机制,在经验容许误差范围内采用深度特征,否则使用手工特征,以提升泡沫图像表征的可靠性.

在知识引导学习方面,研究者通过构造辅助目标或特征空间,使模型在训练过程中学习先验知识.文献[29]以故障频率为辅助预测目标,引导模型学习频率特征,实现滚动轴承故障诊断.文献[30–32]将域统计先验知识引入跨域故障诊断特征学习过程,利用其映射空间作为特征编码子空间,缓解域间差异对模型泛化性能的影响.文献[33]利用经验模型在状态空间中生成样本以增强数据驱动模型的

外推能力.在机器视觉领域,文献[34]针对超薄焊接质量监测提出专家知识引导的神经网络方法,通过构建上下文感知的类别层级结构,将专家逻辑规则以可微模糊约束的形式嵌入损失函数,引导判别性视觉特征学习.文献[35]针对烧结过程 FeO 含量预测,利用红外热像仪采集断面热图像,并结合烧结机理知识,基于温度阈值划分燃烧层、相变层及还原层,引导具有明确物理意义的特征提取.文献[36]基于雾线先验知识估计红外图像中的粉尘透射率场,实现对高炉铁口铁水温度场的在线检测.针对浮选工况识别问题,文献[13]以基于手工特征的软测量模型输出为软目标,引导深度模型学习符合专家观测经验的判别特征.

综上所述,现有知识嵌入方法主要通过显式融合多源特征或基于先验构造引导信号实现知识注入,尚缺乏一种能够直接从视觉层面出发,在特征表征学习过程中自主内化专家观测经验的方法.针对上述不足,本文提出一种专家经验引导的泡沫图像表征学习方法,通过分布特征隔离实现视觉属性结构化表征,并引入经验引导的对比学习机制,在不同视觉属性维度上约束特征学习过程,从而构建兼具物理可解释性与泛化能力的泡沫图像表征模型.

2 经验引导的表征学习

如图 1 所示, EI-FIRL 主要由分布特征隔离网络与经验引导表征学习两部分构成. 1) 分布特征隔离网络包含图像嵌入表征学习、视觉属性划分与多视角关联建模三个核心模块. 其中, 图像嵌入表征学习模块用于在嵌入空间中归纳泡沫图像的抽象视觉模式; 视觉属性划分模块通过基于软注意力的潜在属性聚合及子空间映射将嵌入特征划分为尺寸、颜色和纹理等具有明确工艺解释意义的视觉属性子空间, 以及用于承载难以明确归属于上述属性, 但与品位变化密切相关的隐性判别信息的数据特征子空间, 形成结构化、可解释的图像表征; 多视角关联建模模块进一步挖掘各视觉属性子空间及数据子空间的多视角关联关系. 2) 经验引导表征学习以浮选操作人员的长期观测经验为先验依据, 构造具有特定视觉属性差异的训练样例并引入对比学习机制, 引导分布特征隔离网络在不同视觉属性维度上学习区分性表征. 该过程使模型能够在尺寸、颜色和纹理等关键视觉属性上逐步形成与人工判别逻辑一致的特征响应.

2.1 分布特征隔离网络

分布特征隔离网络 (distributed feature isolation network, DFINet) 由图像嵌入表征学习、视觉

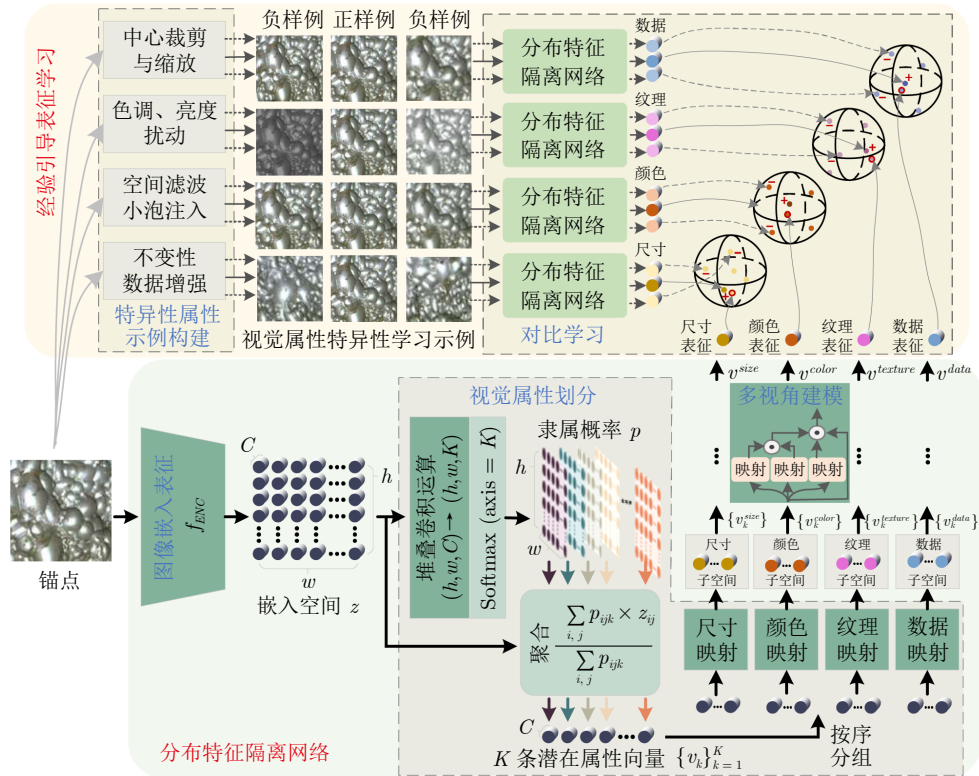


图 1 基于专家经验引导的泡沫图像表征学习框架, 包括分布特征隔离网络与经验引导表征学习机制

Fig.1 Framework of EI-FIRL, which consists of a distributed feature isolation network and experience informed representation learning mechanism

属性划分与多视角关联建模组成, 旨在从嵌入空间中分离出气泡尺寸、颜色与纹理等具有明确工艺解释意义的视觉属性, 实现泡沫图像表征的知识嵌入.

1) 图像嵌入表征学习

图像嵌入表征学习模块旨在将高为 H 、宽为 W 的原始泡沫图像 $x \in \mathbf{R}^{H \times W \times 3}$ 映射至视觉属性嵌入空间. 该模块使用多层卷积与短连接构成的编码结构

$$z = f_{ENC}(x) \quad (1)$$

其中, f_{ENC} 表示特征编码函数; $z \in \mathbf{R}^{h \times w \times C}$ 为 x 在高为 h 、宽为 w 、通道数为 C 的嵌入空间中的特征表示. 为兼顾特征抽象能力与训练稳定性, f_{ENC} 采用传统的 ResNet 结构.

2) 视觉属性划分

视觉属性划分模块依据气泡簇在尺寸、颜色与纹理等方面的视觉模式差异, 利用软注意力机制将嵌入特征 z 自适应地分配至 K 个潜在属性空间, 从而聚合典型视觉模式. 具体而言, 由带填充的堆叠卷积运算模块 g 将嵌入特征 z 映射到通道数为 K 的隶属空间, 经 Softmax 激活后获得嵌入元素属于各属性空间的隶属概率

$$p = \text{Softmax}(g(z)) \quad (2)$$

其中, $p \in \mathbf{R}^{h \times w \times K}$. 对每个属性空间 k 按元素隶属度进行加权聚合, 得到 K 条潜在属性向量 $\{v_1, \dots, v_K\} \in \mathbf{R}^{K \times C}$,

$$v_k = \frac{\sum_{i,j} p_{ijk} \times z_{ij}}{\sum_{i,j} p_{ijk}} \in \mathbf{R}^C, k = 1, \dots, K \quad (3)$$

其中, v_k 编码第 k 个潜在属性空间的显著视觉模式.

为进一步提高典型视觉模式的结构化聚合程度, 将 $\{v_1, \dots, v_K\}$ 分为四组, 每组包含 $K/4$ 条潜在属性向量, 用以刻画同一类视觉属性在不同空间位置或局部区域上的多视角响应特征. 然而, 上述潜在属性向量由嵌入特征的加权聚合得到, 其内部仍混合包含尺寸、颜色、纹理等多种视觉属性. 为此, 在分组基础上进一步引入全连接映射层, 将各组潜在属性向量分别映射至尺寸、颜色、纹理属性子空间及数据特征子空间. 其中, 尺寸、颜色和纹理子空间对应操作人员在实际生产中用于判断泡沫状态的三类核心视觉属性; 数据子空间用于承载难以明确归属于上述显性属性, 但与品位变化高度相关的隐性判别信息. 该设计旨在实现多属性、多视角

的结构化图像表征, 不注重对不同属性进行正交分离.

$$\begin{cases} v_k^{size} = h_{proj}^{size}(v_k) \in \mathbf{R}^{C'}, k \in \left\{1, \frac{K}{4}\right\} \\ v_k^{color} = h_{proj}^{color}(v_k) \in \mathbf{R}^{C'}, k \in \left\{\frac{K}{4}, \frac{K}{2}\right\} \\ v_k^{texture} = h_{proj}^{texture}(v_k) \in \mathbf{R}^{C'}, k \in \left\{\frac{K}{2}, \frac{3K}{4}\right\} \\ v_k^{data} = h_{proj}^{data}(v_k) \in \mathbf{R}^{C'}, k \in \left\{\frac{3K}{4}, K\right\} \end{cases} \quad (4)$$

其中, $h_{proj}^*(\cdot)$ 表示输入维度为 C 、输出维度为 C' 的全连接映射层, 用于从潜在属性向量中有针对性地提取与该表征子空间相关的判别性特征, 从而实现潜在属性向量向具备明确工艺解释意义的视觉属性的高层表征映射, 并增强模型表征与专家感知之间的一致性.

3) 多视角关联建模

获得子空间特征后, 需进一步挖掘其在 $K/4$ 个不同视角间的关联关系. 假设子空间表征集合为 $s \in \{size, color, texture, data\}$, 其中每个子空间特征 $V^s = \{v_k^s\}$ 分别对应尺寸、颜色、纹理属性及数据特征. 为捕获各子空间内部多视角间的关联关系, 引入自注意力机制

$$\bar{v}_i^s = \sum_{j=1}^{\frac{K}{4}} \alpha_{ij} W_v v_j^s \quad (5)$$

$$\alpha_{ij} = \frac{\exp\left((W_q v_i^s)^T (W_k v_j^s)\right)}{\sum_{t=1}^{\frac{K}{4}} \exp\left((W_q v_i^s)^T (W_k v_t^s)\right)} \quad (6)$$

其中, W_q 、 W_k 、 W_v 分别为查询、键、值映射矩阵; α_{ij} 表示第 i 个与第 j 个特征间的关联权重. 通过注意力聚合得到的特征表示, 实现了特征在子空间内的自适应关联建模. 在此基础上, 融合各子空间的特征表示, 获得 s 子空间的全局表征

$$\hat{v}^s = \text{Mean}\left(\{\bar{v}_i^s\}_{i=1}^{\frac{K}{4}}\right) \in \mathbf{R}^{C'} \quad (7)$$

2.2 经验引导表征学习

经验引导表征学习旨在建立 DFINet 中各个具有明确工艺解释意义的视觉属性子空间 (尺寸、颜色、纹理) 与专家经验的显式对应关系. 该机制中, 模型需在不同视觉属性表征上复现专家的观测规律: 例如, 尺寸子空间应准确表征泡沫图像间的气泡尺度差异, 颜色子空间应能区分色调及亮度变化,

而纹理子空间则反映泡沫层表面粗糙度的全局差异. 为实现此目标, 经验引导表征学习通过构造如图 2 所示具有特定视觉属性差异的多组学习示例, 利用对比学习框架引导 DFINet 在各属性子空间内形成与人工判别逻辑一致的判别性特征响应, 其基本损失函数定义为:

$$l_s = - \sum_i \log \frac{\exp\left(\frac{v_i^s \cdot v_i^{s,+}}{\tau}\right)}{\sum_j \exp\left(\frac{v_i^s \cdot v_j^{s,-}}{\tau}\right)} \quad (8)$$

其中, v_i^s 表示锚点图像的 s 属性特征; $v_i^{s,+}$ 为视觉属性一致的正样本特征; $v_i^{s,-}$ 为存在视觉属性差异的负样本特征; τ 为温度参数; “ \cdot ”表示点积操作.




图 2 经验引导表征学习示例 ((a) ~ (c) 分别对应尺寸、颜色、纹理特异性学习示例)

Fig.2 Instances for experience informed representation learning ((a) ~ (c) are the specificity learning instances corresponding to size, and texture, respectively)

1) 尺寸表征学习: 传统气泡尺寸分析依赖分水岭分割精度, 难以应对复杂泡沫图像中多高亮点并存及光照不均等情况. 为此, EI-FIRL 在不进行显式气泡分割的条件下, 借助无监督方式在尺寸属性子空间中学习气泡尺寸差异的判别特征. 如图 1 所示, 给定锚点图像 x_i , 通过多尺度中心裁剪并统一缩放, 构造一组如图 2(a) 所示整体视觉结构相似但气泡尺寸存在差异的样本集. 其中, 裁剪尺度与锚点图像一致的视为正样本 x_i^+ , 其余裁剪尺度差异

较大的样本视为负样本 x_i^- . 例如, 当锚点裁剪尺度为 300×300 像素时, 采用 280×280 像素或 320×320 像素尺度裁剪并缩放得到的图像视为负样本. 通过式 (8) 的对比约束, 尺寸属性子空间将最小化不同尺寸气泡的嵌入相似度, 实现无需分割的气泡尺寸表征学习. 需要指出的是, 图 2(a) 中不同尺度增强样本在视觉上仍存在较高相似度, 这与实际工业浮选过程中的泡沫特性一致: 不同工况下泡沫尺寸存在差异, 但该差异通常较为细微. 这种细微变化正是“人工观测”容易产生不确定性的主要原因, 也从侧面体现了采用表征学习方法刻画气泡尺寸差异的必要性.

2) 颜色表征学习: 传统颜色特征基于 HSV 或 Lab 空间统计量, 难以描述空间分布与光照变化下的稳定性. EI-FIRL 在无监督对比框架下, 从色调/亮度扰动一致性角度实现颜色表征的自适应学习. 如图 1 所示, 给定锚点图像 x_i , 对其施加不同色调与亮度扰动, 生成一组如图 2(b) 所示整体视觉结构一致但色调或亮度存在差异的样本集. 其中, 扰动幅度与锚点图像一致的视为正样本 x_i^+ , 其余扰动样本为负样本 x_i^- . 在颜色属性子空间进行式 (8) 的对比学习, 获得对光照与色调变化的表征能力. 与尺寸属性类似, 在同一浮选工艺条件下, 不同矿物组成与浓度所对应的泡沫颜色主要体现在亮度和色调上的细微差异, 这类差异难以通过人工阈值或简单统计量准确刻画, 而所提方法能够有效捕捉并表征上述细微但具有工艺判别意义的颜色变化特征.

3) 纹理表征学习: 传统纹理描述子 (如灰度共生矩阵、局部二值模式、Gabor 变换等) 是低层统计特征, 虽能刻画局部灰度变化与方向分布, 但对光照与尺度变化敏感, 难以表达泡沫表面多尺度、非均匀的杂质粘附纹理结构. EI-FIRL 在数据层面对原图施加多种纹理增强操作, 包括局部对比度扰动、噪声注入、空间滤波等, 以生成如图 2(c) 所示具有不同纹理分布差异的样本集. 扰动较小的样本作为正样本 x_i^+ , 其余扰动较大的样本作为负样本 x_i^- . 通过式 (8) 的对比约束, 在纹理属性子空间内最小化相似纹理样本的嵌入距离并扩大纹理差异样本间的特征间隔, 引导 DFINet 在该子空间感知泡沫表面粗糙度及杂质粘附.

此外, 泡沫图像是入矿与药剂共同作用的结果, 入矿条件及操作变量相似的多个样本, 其对应的泡沫图像也相似. 因此, 除尺寸、颜色与纹理等具有明确工艺解释意义的视觉属性外, 泡沫图像还隐含其他由入矿性质与药剂作用共同决定的高层抽象特征. 为实现泡沫图像的充分表征, 进一步通过式 (8)

的对比约束从数据层面学习这种隐含特征. 然而, 单纯增加正样本对的相似性、降低负样本对的相似性, 会不可避免地破坏相似操作条件下泡沫图像的一致性表征学习. 为此, 在式 (8) 的基础上提出一种工况相似约束的软对比数据特征学习方法, 其损失 l_{data} 定义为:

$$l_{data} = - \sum_i \log \frac{\exp\left(\frac{v_i^{data} \cdot v_i'^{data}}{\tau}\right)}{\Delta_1} - \sum_i \sum_j w_{ij} \log \frac{\exp\left(\frac{v_i^{data} \cdot v_j'^{data}}{\tau}\right)}{\Delta_2} \quad (9)$$

$$\Delta_1 = \exp\left(\frac{v_i^{data} \cdot v_i'^{data}}{\tau}\right) + \sum_{j \neq i} (1 - w_{ij}) \exp\left(\frac{v_i^{data} \cdot v_j'^{data}}{\tau}\right)$$

$$\Delta_2 = \exp\left(\frac{v_i^{data} \cdot v_j'^{data}}{\tau}\right) + \sum_{k \neq j} (1 - w_{ik}) \exp\left(\frac{v_i^{data} \cdot v_k'^{data}}{\tau}\right)$$

其中, v_i' 为第 i 个样例的强增强; w_{ij} 为工况差异指标

$$w_{ij} = \text{Sigmoid}(-\gamma(|c_i - c_j| - \kappa)) \quad (10)$$

其中, c_i 表示样例 i 对应的入矿性质与药剂剂量; γ 控制 w_{ij} 的变化率; κ 为中点. 式 (9) 第一项基于 InfoNCE 学习图像不变性, 但对负样本引入工况差异 $1 - w_{ij}$. 若样本 j 与锚点 i 工况差异小, 则 $1 - w_{ij}$ 小, 从而降低相似工况泡沫图像在负样本中的权重, 避免将相似工况图像表征强行拉远. 式 (9) 第二项中, 所有样本都可作为锚点 i 的候选正样本, 但按工况相似度加权, 强调工况相似样本在正样本池中的作用, 惩罚工况差异大的样本作为正样例对表征学习的不利影响.

3 实验

为验证 EI-FIRL 在工业浮选中的有效性, 选取中国南方某铅锌选矿厂 II 号系统作为实验对象. 该系统采用“先选铅、再选锌”的混合浮选工艺, 铅、锌浮选工段均由快粗选、粗选、精选与扫选等子工序构成. 如图 3 所示, 为实现泡沫状态的在线监测, 在浮选槽上方约 50 cm 位置架设由工业相机与高亮光源组成的图像采集装置, 实时捕获泡沫层表面动态演变特性. 针对工业现场中粉尘弥散、高温蒸汽

及光照波动等不利因素, 设计了封闭式防护外壳; 同时, 配套的高亮度稳定光源为成像区域提供相对恒定的照明条件, 提升图像采集的稳定性与一致性. 底流及精矿品位采用 X 射线荧光 (X-ray fluorescence, XRF) 分析仪测定, 全厂共设 18 个检测点, 每个检测点的采样周期约为 20 min, 单次检测耗时约 1 min. 由于 XRF 检测频率显著低于入矿条件波动频率, 难以及时反映工况变化. 为此, 以锌快粗选工段为研究对象, 构建融合泡沫图像与过程变量的底流品位软测量模型. 鉴于生产过程中多模态数据采样频率不一致, 以锌快粗选底流 XRF 检测时间为参考点, 向前回溯 1 min, 并选取与该回溯时间节点最接近的两段泡沫视频为标注样本, 以及该时间节点之前采集的工艺操作参数为模型输入, 对应的锌快粗底流中锌 (Zn)、铅 (Pb) 和铁 (Fe) 品位的 XRF 分析值作为模型期望输出.



图 3 铅锌浮选槽及数据采集

Fig. 3 Lead-zinc flotation bank and data collection

最终共采集到 32 971 组输入-输出样本对, 其中, 输入数据包括浮选过程中同步采集的泡沫视频帧图像以及对应时刻的工艺操作参数, 输出数据为与上述输入数据时间对齐的底流矿浆锌、铅和铁品位的 XRF 分析值. 所构建的数据集覆盖了丰富的入矿组成波动及操作工况变化范围, 其中原矿品位波动范围分别为: 锌 5.98% ~ 11.12%、铅 0.39% ~ 2.13%、铁 20.86% ~ 27.77%; 对应底流品位范围为: 锌 0.87% ~ 4.38%、铅 0.41% ~ 0.61%、铁 22.52% ~ 22.67%. 数据集经随机打乱后, 按 70%、15% 与 15% 的比例划分为训练集、验证集与测试集. 为确保不同模型在相同条件下的公平比较, 所有实验均在统一的软硬件环境中进行. 实验平台配置为: 2 块 Intel Xeon Gold 6430 CPU、2 块 NVIDIA RTX Pro 6000 GPU (192 GB 显存) 及 385 GB 内存.

为量化评估 EI-FIRL 模型在底流品位估计中的有效性与先进性, 首先, 引入平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE) 与决定系数 (coefficient of determination, R^2) 度量其软测量精度.

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (11)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (12)$$

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - y_{\text{mean}})^2} \quad (13)$$

其中, \hat{y}_i 是第 i 个样例的估计值; y_i 是参考真值; y_{mean} 是样本均值. 其次, 为评估软测量模型预测结果的不确定性, 从 Monte Carlo Dropout 多次前向传播预测区间可靠性角度, 计算预测区间覆盖率 (prediction interval coverage probability, PICP) 与平均预测区间宽度 (mean prediction interval width, MPIW) 指标, 分别用于反映预测区间的可靠性与紧凑性.

$$\text{PICP} = \frac{1}{N} \sum_{i=1}^N \mathbb{I}(y_i \in [\hat{y}_i^{\text{lower}}, \hat{y}_i^{\text{upper}}]) \quad (14)$$

$$\text{MPIW} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i^{\text{upper}} - \hat{y}_i^{\text{lower}}) \quad (15)$$

其中, \mathbb{I} 为指示函数; \hat{y}_i^{lower} 和 \hat{y}_i^{upper} 分别表示预测置信区间的下限与上限值. 最后, 为衡量模型对数据方差的解释能力, 引入可解释方差得分 (explained variance score, EVS) 指标

$$\text{EVS} = 1 - \frac{\text{Var}(y - \hat{y})}{\text{Var}(y)} \quad (16)$$

其中, Var 为方差. 该指标可直观反映模型所捕获的数据变化比例, 从而综合评价 EI-FIRL 在复杂工业环境下的预测稳定性与可靠性.

1) 泡沫图像表征模型对比

为验证 EI-FIRL 模型在浮选过程监测中的先进性, 选取五种近期发表的典型深度学习泡沫图像表征方法进行对比实验: 传统卷积网络 (traditional convolutional network, TCN)^[37]、多尺度特征提取网络 (multi-scale feature extraction network, MSFE)^[22]、残差学习网络 (residual learning network, RLN)^[38]、视觉 Transformer (vision Trans-

former, ViT)^[39]、基于泡沫视觉形成机理的数据高效表征网络 (data efficient froth image encoder, DEFIE)^[4]. 鉴于部分对比模型的原始设计目的并非用于软测量任务, 为确保结果的可比性与公平性, 仅保留上述模型的特征编码部分, 并在此基础上统一设计双层回归预测头: 第一层用于融合编码后的图像特征与同步采集的工艺参数输入, 第二层输出最终的底流品位预测值. 泡沫视频帧统一缩放至 300×300 像素, 并采用归一化与亮度均衡处理以减轻光照干扰. 由于 ViT 模型需要进行图像块划分, 其输入图像尺寸设置为 224×224 像素. 操作参数经

Z-score 标准化后与图像特征在回归层融合. 所有模型均采用 Adam 优化器, 初始学习率设为 $1e-4$, 批大小设置为 200, 最大训练轮数为 300.

图 4 展示了测试集中锌快粗选底流品位的预测值与真实值的散点对比图及残差分布图 (限于篇幅, 铅和铁元素的结果未展示). 由散点图可见, EI-FIRL 的散点分布相较于对比方法更为紧凑, 拟合线两侧的离散程度显著减小, 表明模型在复杂工况下具备更稳定的预测性能. 表 1 汇总了 EI-FIRL 与对比模型的预测性能指标, 包括 MAE、RMSE、 R^2 及模型复杂度等. 实验结果表明, EI-FIRL 在锌、铅

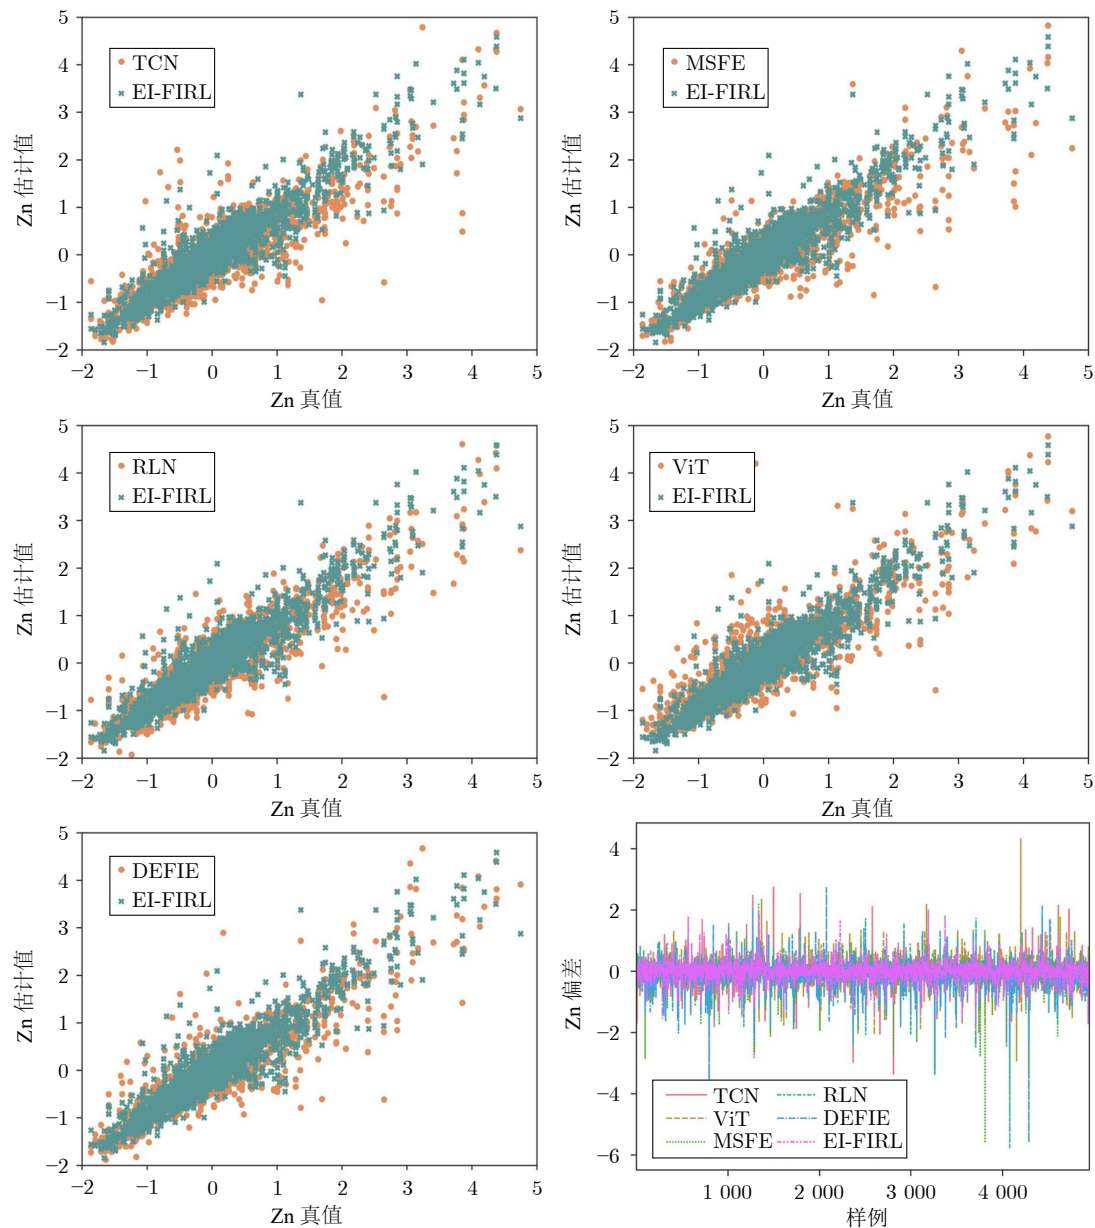


图 4 浮选监测模型对比实验结果散点图及残差图

Fig. 4 Comparison experiment results of flotation monitoring models shown by scatter plots and residual plots

表 1 浮选监测模型对比量化实验结果

Table 1 Quantitative comparison experiment results of flotation monitoring models

方法	成分	参数 (M)	MACs (G)	指标		
				MAE	RMSE	R ²
TCN ^[87]	Zn	20.2	3.5	0.2876	0.4394	0.8103
	Pb			0.2856	0.3969	0.8401
	Fe			0.2421	0.3706	0.8621
MSFE ^[22]	Zn	24.5	5.8	0.2415	0.4117	0.8335
	Pb			0.2704	0.3773	0.8555
	Fe			0.2365	0.3586	0.8709
RLN ^[88]	Zn	24.0	7.7	0.2535	0.4029	0.8366
	Pb			0.2686	0.3702	0.8609
	Fe			0.2149	0.3052	0.9065
ViT ^[89]	Zn	86.8	17.6	0.2716	0.4233	0.8240
	Pb			0.2756	0.3728	0.8589
	Fe			0.1991	0.2694	0.9202
DEFIE ^[4]	Zn	27.8	8.3	0.2349	0.3909	0.8499
	Pb			0.2489	0.3552	0.8720
	Fe			0.1842	0.2721	0.9257
EI-FIRL	Zn	35.9	14.8	0.2156	0.3488	0.8836
	Pb			0.2394	0.3338	0.8892
	Fe			0.1658	0.2281	0.9479

和铁底流品位估计中的 R² 分别达到 0.883 6、0.8892 和 0.9479, 对应的 MAE 分别为 0.2156、0.2394 和 0.1658, RMSE 分别为 0.3488、0.3338 和 0.2281, 整体预测精度优于各对比模型。在锌浮选过程中, 锌矿物主要富集于泡沫层, 而铅、铁及其他杂质多留存于矿浆底流中, 因此入矿与底流中铅、铁品位波动相对较小, 而锌品位变化更为显著。在此工况特性下, EI-FIRL 在锌底流品位预测中取得的显著性能提升尤为关键。与基于泡沫视觉形成机理的 DEFIE 模型相比, EI-FIRL 的锌、铅和铁 R² 指标分别提升了 3.97% (从 0.8499 到 0.8836)、1.97% (从 0.8720 到 0.8892) 和 2.40% (从 0.9257 到 0.9479)。

图 5 进一步比较了 EI-FIRL 与各对比算法在预测不确定性度量指标上的表现, 包括 PICP 和 MPIW。实验结果表明, 对比算法的 PICP 指标普遍集中在 0.60 左右, 而 EI-FIRL 达到 0.75, 表明该模型具备更高的软测量置信度。此外, EI-FIRL 的 MPIW 显著低于其他模型, 表明其在保持较高置信水平覆盖率的同时, 其预测区间更为紧凑。因此, EI-FIRL 不仅能够“命中更多真实值”, 还以更小的区间实现了对预测置信度的有效控制。

图 6 比较了 EI-FIRL 与各对比算法的 EVS 指标。实验结果表明, EI-FIRL 在锌、铅和铁三种底流

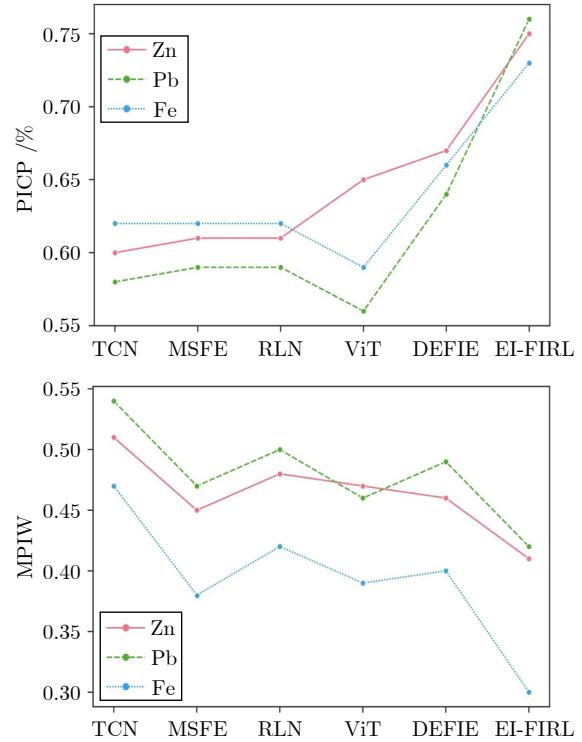


图 5 浮选监测模型预测不确定性度量

Fig. 5 Prediction uncertainty evaluation of flotation monitoring models

品位预测任务中均取得了最高的 EVS 值, 分别达到 0.891、0.897 和 0.949, 显著优于其他泡沫图像表征模型。该结果表明, EI-FIRL 能够捕获更大比例的样本方差, 表征能力更强。

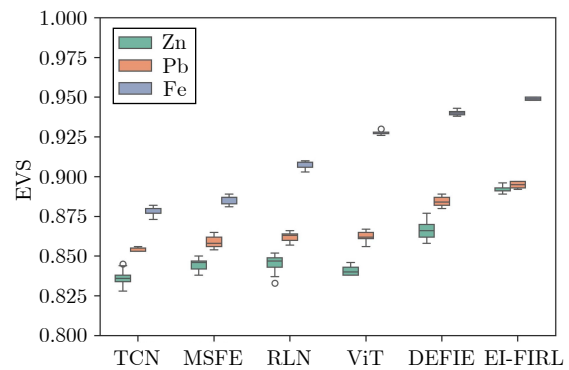


图 6 浮选监测模型可解释方差得分度量

Fig. 6 Explained variance score evaluation of flotation monitoring models

此外, 表 1 同时给出了各对比模型的参数规模与计算复杂度 (multiply-accumulate operations, MACs), 以评估不同方法在预测性能与计算代价之间的权衡关系。EI-FIRL 在引入分布特征隔离网络与经验引导表征学习机制后, 参数规模与计算量相较于传统卷积网络有所增加, 但仍显著低于 ViT 等

高复杂度模型. 在此复杂度水平下, EI-FIRL 在锌、铅和铁底流品位预测任务中取得了更高的预测精度、预测区间可靠性及数据方差解释能力, 表明其性能提升并非依赖于简单增加模型规模, 而主要得益于结构设计与知识引导机制的有效性.

2) 知识嵌入模型对比

为验证 EI-FIRL 模型在知识嵌入方面的先进性, 选取三种代表性的知识嵌入方法作为对比, 分别为拼接融合 (concatenation fusion, ConcatFus)^[24]、先验知识辅助预测目标 (prior knowledge informed auxiliary prediction target, PriKnoInfo)^[30-32] 及知识蒸馏 (prior knowledge distillation, PriKnoDisti)^[13]. 上述方法的原始设计目的并非针对机器视觉软测量任务, 因此, 为确保对比结果的可比性与公平性, 本研究对其进行适配性重构. 首先, 从泡沫图像中提取尺寸、颜色、纹理等手工特征, 并将每帧图像的手工特征汇总形成数据集. 三种知识嵌入方法均以 ResNet 作为图像编码网络, 并在其后接入双层回归预测头: 第一层用于融合编码后的图像特征与同步采集的工艺参数输入, 第二层输出底流品位预测值. 各方法的特异性设计如下:

ConcatFus: 将手工特征与 ResNet 编码得到的图像深层特征进行拼接融合, 形成知识增强型图像表示. 该表示与标准化后的工艺参数共同输入双层

回归预测头, 以产生底流品位估计结果.

PriKnoInfo: 在 ResNet 图像编码网络添加两条投影分支, 第一条分支用于产生手工特征 (知识先验) 的预测输出, 第二条分支的输出与工艺参数拼接后输入到双层回归预测头. 模型采用联合损失进行优化, 包括估计输出与底流品位真值之间的均方误差损失, 以及特征预测输出与离线提取手工特征之间的均方误差损失.

PriKnoDisti: 首先采用手工特征构建浅层前馈神经网络模型, 以获得底流品位的教师估计结果. 随后, 构建基于 ResNet 的深度学习学生模型. 浅层模型训练完成后, 将倒数第二层激活输出作为软目标, 用于指导学生模型学习. 优化过程中, 学生网络同时优化估计输出与底流品位真值之间的均方误差损失, 以及学生模型倒数第二层激活输出与教师模型激活值之间的均方误差损失.

数据预处理阶段, 所有泡沫图像统一缩放至 300×300 像素, 并经归一化与亮度均衡处理以减轻光照的干扰. 离线提取泡沫图像的尺寸、颜色、纹理等手工特征后, 采用 Z-score 进行标准化处理. 所有模型均采用 Adam 优化器, 初始学习率设为 $1e-4$, 批大小设置为 200, 最大训练轮数为 300.

图 7 展示了测试集中锌快粗选底流品位的预测值与真实值的散点对比图及残差分布图 (限于篇幅,

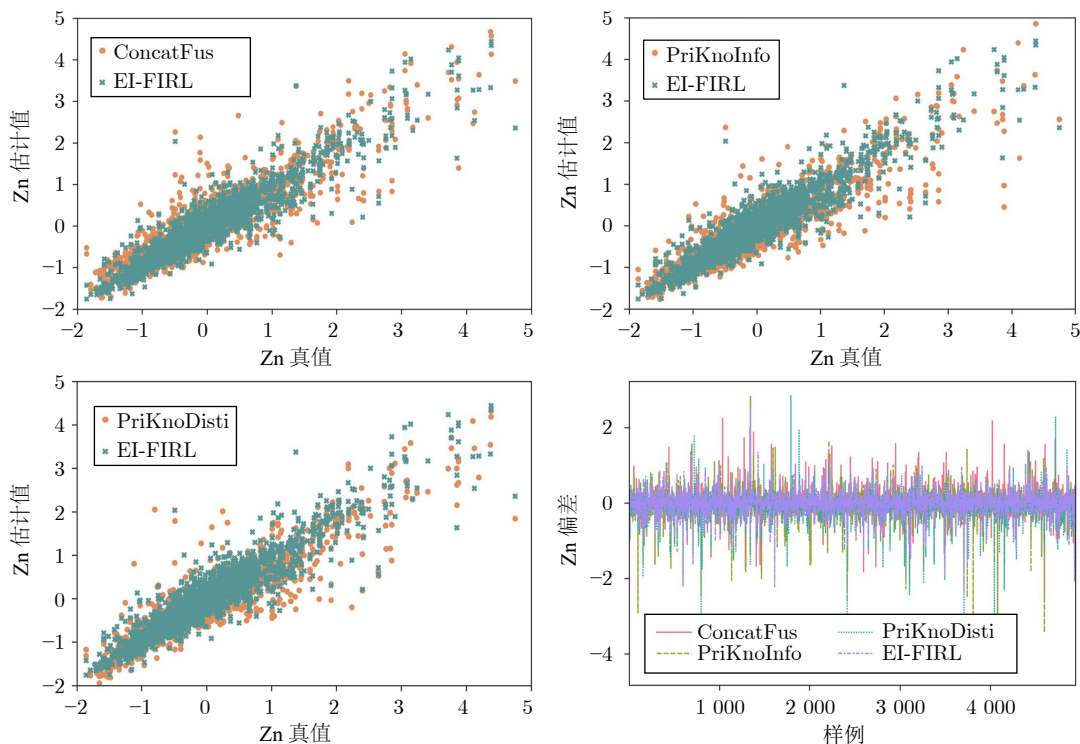


图 7 知识嵌入模型对比实验结果散点图及残差图

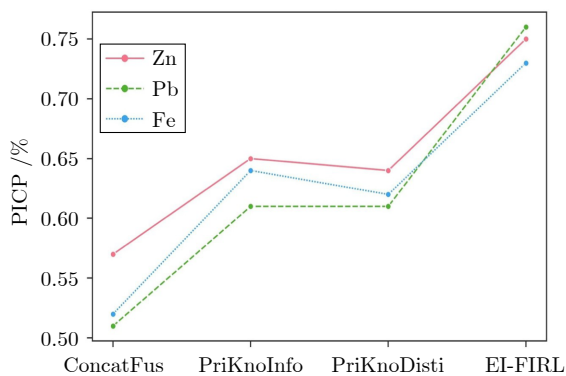
Fig. 7 Comparison experiment results of knowledge embedding models shown by scatter plots and residual plots

铅和铁的结果未展示). 表 2 汇总了 EI-FIRL 与三种知识嵌入对比模型的预测性能指标, 包括 MAE、RMSE 及 R^2 (由于手工特征离线提取, 故该表没有给出计算复杂度指标). 从残差图及 MAE 指标可见, EI-FIRL 在三种金属元素上的估计误差均小于对比算法, 其在锌、铅和铁上的 MAE 分别为 0.2156、0.2394 和 0.1658, 相较于性能最优的 PriKnoDisti, 分别减小了 5.89% (从 0.2291 到 0.2156)、0.50% (从 0.2406 到 0.2394) 和 17.39% (从 0.2007 到 0.1658). 从散点图与 RMSE 指标可进一步观察到, ConcatFus 及 PriKnoInfo 模型预测偏差较大, 其 RMSE 分别达到 0.3934、0.3881、0.3281 与 0.3830、0.3540、0.3146, 表明其知识融合方式对提高泡沫图像表征的区分能力及泛化能力有限. 相比之下, EI-FIRL 的散点分布更接近对角线, 拟合线两侧的离散程度显著降低, 表明模型在底流品位估计中具有

表 2 知识嵌入模型对比量化实验结果

Table 2 Quantitative comparison experiment results of knowledge embedding models

方法	成分	指标		
		MAE	RMSE	R^2
ConcatFus ^[24]	Zn	0.2638	0.3934	0.8507
	Pb	0.2893	0.3881	0.8477
	Fe	0.2287	0.3281	0.8922
PriKnoInfo ^[30]	Zn	0.2442	0.3830	0.8585
	Pb	0.2595	0.3540	0.8733
	Fe	0.2156	0.3146	0.9009
PriKnoDisti ^[13]	Zn	0.2291	0.3772	0.8643
	Pb	0.2406	0.3310	0.8826
	Fe	0.2007	0.2530	0.9366
EI-FIRL	Zn	0.2156	0.3488	0.8836
	Pb	0.2394	0.3338	0.8892
	Fe	0.1658	0.2281	0.9479



更强的稳定性. 在 R^2 指标上, EI-FIRL 分别达 0.8836、0.8892 和 0.9479, 较 PriKnoDisti 的 0.8643、0.8826 和 0.9366 分别提升了 2.23%、0.75% 和 1.21%. 该结果表明, EI-FIRL 通过分布特征隔离网络与经验引导表征学习提升泡沫图像表征的准确性, 验证了其在知识嵌入与表征学习方面的显著优势.

图 8 进一步比较了 EI-FIRL 与各对比算法在预测不确定性度量指标上的表现, 包括 PICP 和 MPIW. 在锌底流品位估计中, ConcatFus、PriKnoInfo 及 PriKnoDisti 的 PICP 指标分别为 0.57、0.65 和 0.64, 表明基于手工特征的知识嵌入方式对提升软测量模型的预测置信度有限. 究其原因, 可能是手工特征难以充分复现专家经验, 且其自身提取存在较大不确定性. 相比之下, EI-FIRL 的 PICP 指标显著提高至 0.75, 同时其 MPIW 值显著低于其他知识嵌入模型, 表明 EI-FIRL 通过在各关键视觉属性维度上形成与人工判别过程一致的特征响应, 能有效减少预测不确定性.

图 9 比较了 EI-FIRL 与三种知识嵌入对比模型的 EVS 指标. 实验结果表明, EI-FIRL 在锌、铅和铁三种底流品位预测任务中的 EVS 值均显著高于基于手工特征的知识嵌入方法. 与仅依赖显性特征拼接或浅层知识蒸馏的方法相比, EI-FIRL 通过经验引导表征学习机制实现了对尺寸、颜色、纹理等视觉属性及数据特征的联合表征建模, 使其表征空间更具区分性与泛化性.

3) 消融实验

为验证分布特征隔离网络与经验引导表征学习在 EI-FIRL 中的作用与贡献, 设计以下五种模型变体.

变体 1. 为评估分布特征隔离网络设计的合理性, 将 ResNet 编码输出经 4 个全连接投影函数分别映射至尺寸、颜色、纹理及数据子空间, 并联合经

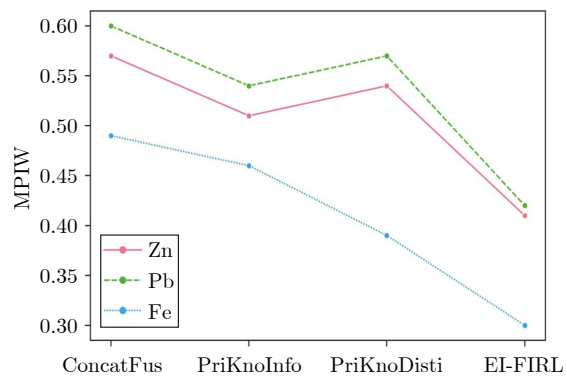


图 8 知识嵌入模型预测不确定性度量

Fig.8 Prediction uncertainty evaluation of knowledge embedding models

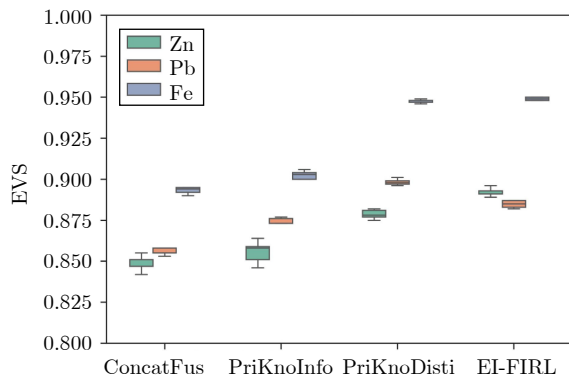


图9 知识嵌入模型可解释方差得分度量

Fig.9 Explained variance score evaluation of knowledge embedding models

验引导表征学习与品位估计损失训练网络。

变体 2. 为分析经验引导表征学习的重要性, 不引入基于特定视觉属性差异训练样例的对比学习, 仅采用模型输出与品位真值的均方误差损失构建软测量模型。

变体 3. 为研究尺寸表征学习的贡献, 将尺寸属性子空间并入数据子空间, 舍弃尺寸子空间的知识嵌入机制。

变体 4. 为研究颜色表征学习的贡献, 将颜色属性子空间并入数据子空间, 舍弃颜色子空间的知识嵌入机制。

变体 5. 为研究纹理表征学习的贡献, 将纹理属性子空间并入数据子空间, 舍弃纹理子空间的知识嵌入机制。

表 3 汇总了 EI-FIRL 与五种消融设置下的预测性能指标, 包括 MAE、RMSE 及 R^2 。实验结果表明, 完整 EI-FIRL 模型在各指标上均取得最优性能, 验证了分布特征隔离网络与经验引导表征学习在提升模型预测精度与稳定性方面的关键作用。具体而言, 去除经验引导表征学习后 (变体 2), 模型在锌、铅和铁的 R^2 分别下降约 3.58%、2.82% 和 1.53%, 说明经验引导表征学习显著增强了属性子空间的表征判别性。进一步地, 移除尺寸、颜色或纹理表征学习 (变体 3 ~ 变体 5) 均导致性能不同程度下降, 其中尺寸表征学习的影响最为显著, 表明气泡尺寸特征在反映浮选工况变化与矿物附着状态方面具有更高的敏感性与判别价值。

4) 泛化性分析

为进一步验证 EI-FIRL 在不同矿物类型泡沫图像表征上的泛化能力, 选取某浮选厂采集的锑粗选泡沫图像开展跨场景实验验证。由于该浮选厂未配置 XRF 分析仪, 为实现生产工况监测, 操作人员依据长期生产经验, 将浮选工况划分为如图 10 所

示的低品位、偏低品位、适中品位、偏高品位及高品位五种典型状态^[40]。共标注泡沫图像 20384 张, 各类工况样本分布相对均衡, 五类工况占比分别为 19.6%、20.2%、19.9%、21.4% 和 18.9%。数据集经随机打乱后, 按 70%、15% 与 15% 比例划分为训练集、验证集与测试集。为全面评估 EI-FIRL 在跨矿种工况识

表 3 消融实验量化结果

Table 3 Quantitative results of ablation experiments

设置	成分	指标		
		MAE	RMSE	R^2
变体 1	Zn	0.2264	0.3679	0.8684
	Pb	0.2445	0.3369	0.8839
	Fe	0.1985	0.2640	0.9388
变体 2	Zn	0.2499	0.3917	0.8520
	Pb	0.2606	0.3666	0.8641
	Fe	0.1988	0.2685	0.9334
变体 3	Zn	0.2245	0.3600	0.8720
	Pb	0.2412	0.3345	0.8842
	Fe	0.1903	0.2477	0.9400
变体 4	Zn	0.2234	0.3561	0.8776
	Pb	0.2387	0.3336	0.8875
	Fe	0.1731	0.2404	0.9421
变体 5	Zn	0.2198	0.3627	0.8731
	Pb	0.2445	0.3369	0.8839
	Fe	0.1875	0.2473	0.9401
EI-FIRL	Zn	0.2156	0.3488	0.8836
	Pb	0.2394	0.3338	0.8892
	Fe	0.1658	0.2281	0.9479

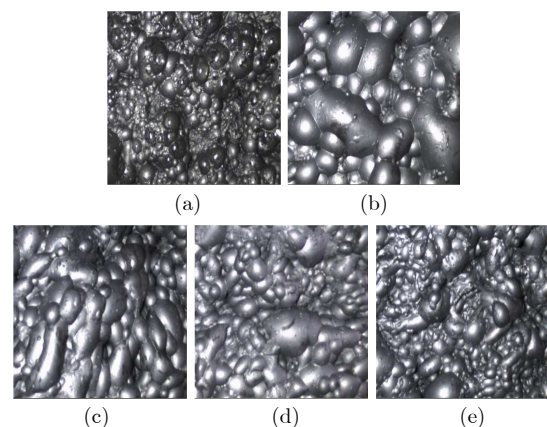


图 10 锑浮选五类典型工况图像示例 ((a) ~ (e) 对应低品位、偏低品位、适中品位、偏高品位、高品位工况)

Fig.10 Illustrative images of five typical working conditions in antimony flotation ((a) ~ (e) correspond to low-grade, slightly low-grade, medium-grade, slightly high-grade, and high-grade conditions, respectively)

别任务中的性能, 采用准确性 (Accuracy)、精确度 (Precision)、召回率 (Recall) 及 F1 指标进行量化分析。

实验结果如表 4 所示。EI-FIRL 的工况识别准确性方面显著优于常规深度学习泡沫图像表征方法, 包括 TCN、MSFE 及 RLN 等。与基于泡沫视觉形成机理的 DEFIE 模型相比, EI-FIRL 的准确性、精确度、召回率及 F1 分别由 85.31%、85.28%、85.75% 及 85.17% 提升至 89.41%、89.71%、89.48% 及 89.39%, 对应提升率为 4.81%、5.19%、4.35% 及 4.95%。进一步地, 相较于性能最优的知识嵌入模型 PriKnoDisti, 上述四项分类指标仍分别提升 3.27%、3.43%、2.83% 和 3.27%。该工况识别实验结果表明, 在仅依赖人工工况标定、缺乏连续品位真值监督的条件下, EI-FIRL 仍能够学习具有判别性的泡沫视觉表征, 验证了其在不同矿物类型和生产环境下的良好泛化能力。

表 4 锑浮选工况分类验证实验 (%)

Table 4 Experimental validation of antimony flotation working condition classification (%)

方法	指标			
	Accuracy	Precision	Recall	F1
TCN ^[37]	81.26	81.73	81.50	81.31
MSFE ^[22]	83.07	83.46	83.41	83.09
RLN ^[38]	84.07	84.40	84.30	84.05
ViT ^[39]	82.18	82.53	82.38	82.15
DEFIE ^[4]	85.31	85.28	85.75	85.17
ConcatFus ^[24]	85.18	85.22	85.57	85.11
PriKnoInfo ^[30]	85.40	85.75	85.67	85.45
PriKnoDisti ^[13]	86.14	86.28	86.65	86.12
EI-FIRL	89.41	89.71	89.48	89.39

4 结束语

针对机器视觉浮选过程软测量中泡沫图像表征能力不足、模型泛化性较差的问题, 提出了一种专家经验引导的泡沫图像表征学习 (EI-FIRL) 方法。首先, 将泡沫图像映射至尺寸、颜色、纹理等具有明确工艺解释意义的视觉属性子空间, 以及用于补充隐性判别信息的数据特征子空间, 使各子空间侧重刻画主导视觉属性下的判别性变化特征, 为专家知识注入提供结构化表征载体。其次, 通过为各视觉属性子空间构造具有特定视觉属性差异的训练样例, 利用对比学习引导模型在不同子空间中学习与专家观测经验一致的判别特征, 实现专家感知经验驱动的图像表征学习。基于 EI-FIRL 构建的锌快粗底流品位软测量模型验证了所提方法在预测精度与

稳定性方面的有效性与先进性; 此外, 基于锑粗选泡沫图像的工况识别实验表明, EI-FIRL 在不同矿物类型泡沫图像表征任务中具有较好的泛化能力。需要指出的是, 所提子空间结构化表征旨在实现具有工艺解释意义的视觉属性弱解耦表征, 并非在统计意义上对不同属性进行正交分离。此外, EI-FIRL 主要针对泡沫图像的静态视觉表征, 尚未显式建模泡沫层的运动模式特征。后续研究将进一步结合动态视觉分析, 拓展 EI-FIRL 在复杂工况下的应用能力。

参考文献

- Zhang J, Tang Z H, Xie Y F, Chen Q, Ai M X, Gui W H. Timed key-value memory network for flotation reagent control. *Control Engineering Practice*, 2020, **98**: Article No. 104360
- Ai M X, Xie Y F, Tang Z H, Wu J D, Li P, Zhang J. Self-supervised dynamic and static feature representation learning method for flotation monitoring. *Powder Technology*, 2024, **442**: Article No. 119866
- Liu Jin-Ping, He Jie-Zhou, Tang Zhao-Hui, Xie Yong-Fang, Ma Tian-Yu. WCGAN-based illumination-invariant color measuring of mineral flotation froth images. *Acta Automatica Sinica*, 2022, **48**(9): 2301–2315
(刘金平, 何捷舟, 唐朝晖, 谢永芳, 马天雨. 基于 WCGAN 的矿物浮选泡沫图像光照不变颜色提取. *自动化学报*, 2022, **48**(9): 2301–2315)
- Zhang J, Ai M X, Tang Z H, Xie Y F, Wu J D, Ma J. Data-efficient soft sensing learning for flotation process monitoring. *IEEE Transactions on Instrumentation and Measurement*, 2025, **74**: Article No. 5037810
- Zhang J, Tang Z H, Xie Y F, Ai M X, Gui W H. Convolutional memory network-based flotation performance monitoring. *Minerals Engineering*, 2020, **151**: Article No. 106332
- Zhang J, Tang Z H, Ai M X, Gui W H. Nonlinear modeling of the relationship between reagent dosage and flotation froth surface image by Hammerstein-Wiener model. *Minerals Engineering*, 2018, **120**: 19–28
- Cui Lin-Lin, Shen Bing-Bing, Ge Zhi-Qiang. A mixture variational autoencoder regression model for soft sensor application. *Acta Automatica Sinica*, 2022, **48**(2): 398–407
(崔琳琳, 沈冰冰, 葛志强. 基于混合变分自编码器回归模型的软测量建模方法. *自动化学报*, 2022, **48**(2): 398–407)
- Zhang J, Ai M X, Tang Z H, Xie Y F, Ma J, Wu J D. A sentinel-based adaptive hybrid soft sensing method for industrial process monitoring. *IEEE Transactions on Instrumentation and Measurement*, 2025, **74**: Article No. 5025813
- Ai M X, Zhang J, Li P, Wu J D, Tang Z H, Xie Y F. Semi-supervised contrastive learning for flotation process monitoring with uncertainty-aware prototype optimization. *Engineering Applications of Artificial Intelligence*, 2025, **145**: Article No. 110222
- Aldrich C, Avelar E, Liu X. Recent advances in flotation froth image analysis. *Minerals Engineering*, 2022, **188**: Article No. 107823
- Zhang J, Tang Z H, Xie Y F, Ai M X, Zhang G Y, Gui W H. Data-driven adaptive modeling method for industrial processes and its application in flotation reagent control. *ISA Transactions*, 2021, **108**: 305–316
- Zhang J, Tang Z H, Xie Y F, Ai M X, Gui W H. Generative adversarial network-based image-level optimal setpoint calculation for flotation reagents control. *Expert Systems With Applications*, 2022, **197**: Article No. 116790

- 13 Ai M X, Xie Y F, Ding S X, Tang Z H, Gui W H. Domain knowledge distillation and supervised contrastive learning for industrial process monitoring. *IEEE Transactions on Industrial Electronics*, 2023, **70**(9): 9452–9462
- 14 Gao X L, Tang Z H, Xie Y F, Zhang H, Gui W H. A layered working condition perception integrating handcrafted with deep features for froth flotation. *Minerals Engineering*, 2021, **170**: Article No. 107059
- 15 Sadr-Kazemi N, Cilliers J J. An image processing algorithm for measurement of flotation froth bubble size and shape distributions. *Minerals Engineering*, 1997, **10**(10): 1075–1083
- 16 Zhang J, Tang Z H, Liu J P, Tan Z, Xu P F. Recognition of flotation working conditions through froth image statistical modeling for performance monitoring. *Minerals Engineering*, 2016, **86**: 116–129
- 17 Zhang J, Tang Z H, Xie Y F, Ai M X, Gui W H. Visual perception-based fault diagnosis in froth flotation using statistical approaches. *Tsinghua Science and Technology*, 2021, **26**(2): 172–184
- 18 Liu J P, He J Z, Xie Y F, Gui W H, Tang Z H, Ma T Y. Illumination-invariant flotation froth color measuring via Wasserstein distance-based CycleGAN with structure-preserving constraint. *IEEE Transactions on Cybernetics*, 2021, **51**(2): 839–852
- 19 Gharehchogh B K, Kuzekanani Z D, Sobhi J, Khiavi A M. Flotation froth image segmentation using mask R-CNN. *Minerals Engineering*, 2023, **192**: Article No. 107959
- 20 Fan Y H, Lv Z Q, Wang W D, Tian R, Zhang K H, Wang M C, et al. A density map regression method and its application in the coal flotation froth image analysis. *Measurement*, 2022, **205**: Article No. 112212
- 21 Zarie M, Jahedsaravani A, Massinaei M. Flotation froth image classification using convolutional neural networks. *Minerals Engineering*, 2020, **155**: Article No. 106443
- 22 Tang Z H, Zhang J, Xie Y F, Ding S X, Ai M X. Semisupervised contrastive memory network for industrial process working condition monitoring. *IEEE Transactions on Instrumentation and Measurement*, 2023, **72**: Article No. 5025110
- 23 von Rueden L, Mayer S, Beckh K, Georgiev B, Giesselbach S, Heese R. Informed machine learning—A taxonomy and survey of integrating prior knowledge into learning systems. *IEEE Transactions on Knowledge and Data Engineering*, 2023, **35**(1): 614–633
- 24 Li Y X, Xie S C, Wang J C, Zhang J, Yan H Y. Sparse sample train axle bearing fault diagnosis: A semi-supervised model based on prior knowledge embedding. *IEEE Transactions on Instrumentation and Measurement*, 2023, **72**: Article No. 3531911
- 25 Deng X, Feng S H, Lv G Y, Wang T, Lang C Y. Beyond word embeddings: Heterogeneous prior knowledge driven multi-label image classification. *IEEE Transactions on Multimedia*, 2023, **25**: 4013–4025
- 26 Chen Z W, Xu J M, Peng T, Yang C H. Graph convolutional network-based method for fault diagnosis using a hybrid of measurement and prior knowledge. *IEEE Transactions on Cybernetics*, 2022, **52**(9): 9157–9169
- 27 Lu D, Wang F L, Liu Y, Wang S, Li K. Process operating performance assessment for plant-wide froth flotation via distributed multigraph deep embedding graph clustering network. *IEEE Transactions on Instrumentation and Measurement*, 2024, **73**: Article No. 2515510
- 28 Sun B, Yang W, He M F, Wang X L. An integrated multi-mode model of froth flotation cell based on fusion of flotation kinetics and froth image features. *Minerals Engineering*, 2021, **172**: Article No. 107169
- 29 Qiao W, Liu X L, Huang J P, Wu G X. A prior knowledge embedding contrastive attention learning network for variable working conditions bearing fault diagnosis with small samples. *IEEE Sensors Journal*, 2024, **24**(23): 39967–39980
- 30 Lu F Y, Tong Q B, Jiang X D, Du X, Xu J J, Huo J Y. Prior knowledge embedding convolutional autoencoder: A single-source domain generalized fault diagnosis framework under small samples. *Computers in Industry*, 2025, **164**: Article No. 104169
- 31 Zhang T C, Chen J L, Ye Z S, Liu W T, Tang J Y. Prior knowledge-informed multi-task dynamic learning for few-shot machinery fault diagnosis. *Expert Systems With Applications*, 2025, **271**: Article No. 126439
- 32 Zhang T C, Chen J L, He S L, Zhou Z T. Prior knowledge-augmented self-supervised feature learning for few-shot intelligent fault diagnosis of machines. *IEEE Transactions on Industrial Electronics*, 2022, **69**(10): 10573–10584
- 33 Chen S Z, Zhang S Y, Feng D C, Taciroglu E. Embedding prior knowledge into data-driven structural performance prediction to extrapolate from training domains. *Journal of Engineering Mechanics*, 2023, **149**(12): Article No. 04023099
- 34 Hong Y X, Lin K, Xu J, Chang B H, Du D. Expert knowledge-guided deep neural network based on context-aware hierarchy for foils joining quality monitoring. *Advanced Engineering Informatics*, 2026, **69**: Article No. 104001
- 35 Jiang Z H, Guo Y H, Pan D, Gui W H, Maldague X. Polymorphic measurement method of FeO content of sinter based on heterogeneous features of infrared thermal images. *IEEE Sensors Journal*, 2021, **21**(10): 12036–12047
- 36 Pan Dong, Xu Chuan, Gong Peng-Xu, Jiang Zhao-Hui, Gui Wei-Hua. Online measurement of molten iron temperature field at blast furnace taphole based on infrared and visible vision. *Acta Automatica Sinica*, 2025, **51**(2): 343–355
(潘冬, 许川, 龚芑旭, 蒋朝辉, 桂卫华. 基于红外与可见光视觉的高炉铁口铁水温度场在线检测. *自动化学报*, 2025, **51**(2): 343–355)
- 37 Wang X, Zhou J W, Wang Q K, Liu D X, Lian J M. An unsupervised method for extracting semantic features of flotation froth images. *Minerals Engineering*, 2022, **176**: Article No. 107344
- 38 Ma B Y, Du Y Y, Zhou X J, Yang C H. A novel adaptive optimization method for deep learning with application to froth flotation monitoring. *Applied Intelligence*, 2023, **53**(10): 11820–11832
- 39 Peng C, Liu Y K, Ouyang Y Y, Tang Z H, Luo L, Gui W H. Grade prediction of froth flotation based on multistep fusion transformer model. *IEEE Transactions on Industrial Informatics*, 2024, **20**(4): 6030–6040
- 40 Ai M X, Xie Y F, Xie S W, Li F B, Gui W H. Data-driven-based adaptive fuzzy neural network control for the antimony flotation plant. *Journal of the Franklin Institute*, 2019, **356**(12): 5944–5960



张进 昆明理工大学信息工程与自动化学院副教授。2022 年获得中南大学控制科学与工程专业博士学位。主要研究方向为深度学习, 数据高效建模。E-mail: j.zhang@kust.edu.cn
(ZHANG Jin Associate professor at the Faculty of Information Engineering and Automation, Kunming University of Science and Technology. He received his Ph.D. degree in control science and engineering from Central South University in 2022. His research interests include deep learning and data efficient modeling.)



黄嘉豪 昆明理工大学信息工程与自动化学院硕士研究生. 主要研究方向为基于机器视觉的复杂工业过程智能监测与优化.

E-mail: jiahao_huang@stu.kust.edu.cn

(HUANG Jia-Hao Master student at the Faculty of Information Engineering and Automation, Kunming University of Science and Technology. His main research interest is intelligent monitoring and optimization of complex industrial processes based on machine vision.)



艾明曦 云南大学信息学院讲师. 2022 年获得中南大学控制科学与工程博士专业博士学位. 主要研究方向为深度学习, 流程工业智能感知与建模. 本文通信作者.

E-mail: mingxi_ai@ynu.edu.cn

(AI Ming-Xi Lecturer at the School of Information Science and Engineering, Yunnan University. She received her Ph.D. degree in control science and engineering from Central South University in 2022. Her research interests include deep learning, intelligent perception and modeling in industrial processes. Corresponding author of this paper.)



唐朝晖 中南大学自动化学院教授. 2008 年获得中南大学控制科学与工程博士专业博士学位. 主要研究方向为深度学习, 图像处理.

E-mail: zhtang@csu.edu.cn

(TANG Zhao-Hui Professor at the School of Automation, Central

South University. He received his Ph.D. degree in control science and engineering from Central South University in 2008. His research interests include deep learning and image processing.)



谢永芳 中南大学自动化学院教授. 1999 年获得中南大学控制科学与工程博士专业博士学位. 主要研究方向为复杂工业过程建模、优化与控制.

E-mail: yfxie@csu.edu.cn

(XIE Yong-Fang Professor at the School of Automation, Central

South University. He received his Ph.D. degree in control science and engineering from Central South University in 1999. His research interests include modeling, optimization and control of complicated industrial processes.)



马 军 昆明理工大学信息工程与自动化学院教授. 2016 年获得昆明理工大学冶金工程控制专业博士学位. 主要研究方向为故障诊断.

E-mail: mjun@kust.edu.cn

(MA Jun Professor at the Faculty of Information Engineering and Automation, Kunming University of Science and Technology. He received his Ph.D. degree in metallurgical engineering control from Kunming University of Science and Technology in 2016. His main research interest is fault diagnosis.)