

控制与决策

Control and Decision

基于局部特征增强的浮选过程改进半监督工况识别方法

艾明曦, 许庆, 张进, 孔庆洁, 李鹏, 谢永芳, 唐朝晖

引用本文:

艾明曦, 许庆, 张进, 等. 基于局部特征增强的浮选过程改进半监督工况识别方法[J]. 控制与决策, 2025, 40(9): 2891-2900.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.1439>

您可能感兴趣的其他文章

Articles you may be interested in

基于双分支特征融合的场景文本检测方法

A scene text detection based on dual-path feature fusion

控制与决策. 2021, 36(9): 2179-2186 <https://doi.org/10.13195/j.kzyjc.2020.0002>

行人重识别中度量学习方法研究进展

A survey on metric learning in person re-identification

控制与决策. 2021, 36(7): 1547-1557 <https://doi.org/10.13195/j.kzyjc.2020.0801>

基于多尺度特征表示的行人再识别

Multi-scale feature representation for person re-identification

控制与决策. 2021, 36(12): 3015-3022 <https://doi.org/10.13195/j.kzyjc.2020.0952>

基于协同聚类和权重注意力稀疏自编码网络的变化检测方法

Change detection approach based on cooperative clustering and weighted attention sparse autoencoder

控制与决策. 2021, 36(10): 2442-2450 <https://doi.org/10.13195/j.kzyjc.2019.1633>

基于分类特征约束变分伪样本生成器的类增量学习

Class incremental learning based on variational pseudo-sample generator with classification feature constraints

控制与决策. 2021, 36(10): 2475-2482 <https://doi.org/10.13195/j.kzyjc.2020.0228>

基于局部特征增强的浮选过程改进半监督工况识别方法

艾明曦¹, 许庆¹, 张进², 孔庆洁¹, 李鹏¹, 谢永芳^{3†}, 唐朝晖³

(1. 云南大学信息学院, 昆明 650500; 2. 昆明理工大学信息工程与自动化学院, 昆明 650504;
3. 中南大学自动化学院, 长沙 410083)

摘要: 深度学习方法在泡沫浮选监测中越来越受到关注, 然而, 此类方法面临对关键特征区域感知不足和难以获取足量高质量有标签泡沫图像的问题. 鉴于此, 提出一种基于局部特征增强的改进半监督工况识别方法 (local feature enhancement-based improved semi-supervised condition recognition method, LFE-ISSM). 首先, 级联 ResNet18 和卷积注意力模块 (convolutional block attention module, CBAM) 构造局部特征增强模块, 通过通道注意力和空间注意力双注意力机制强化泡沫图像的局部特征表达能力; 然后, 使用改进半监督算法训练工况识别模型, 算法在 Mean-Teacher 框架的基础上融合基于阈值的伪标签正则化策略和特征相似性对齐策略, 以确保伪标签的可靠性并有效引导模型学习数据中的潜在结构信息. 实验结果表明, 所提出方法可有效提取泡沫图像特征, 且在实际工业锌浮选数据集上的分类性能优于对比方法.

关键词: 工况识别; 特征增强; 半监督学习; 双注意力机制; 伪标签正则化; 特征相似性对齐

中图分类号: TP183 文献标志码: A

DOI: 10.13195/j.kzyjc.2024.1439

引用格式: 艾明曦, 许庆, 张进, 等. 基于局部特征增强的浮选过程改进半监督工况识别方法 [J]. 控制与决策, 2025, 40(9): 2891-2900.

Local feature enhancement-based improved semi-supervised condition recognition method for flotation process

AI Ming-xi¹, XU Qing¹, ZHANG Jin², KONG Qing-jie¹, LI Peng¹, XIE Yong-fang^{3†}, TANG Zhao-hui³

(1. School of Information Science and Engineering, Yunnan University, Kunming 650500, China; 2. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650504, China; 3. School of Automation, Central South University, Changsha 410083, China)

Abstract: Deep learning methods have gained increasing attention in froth flotation monitoring. However, such methods face challenges in perceiving key feature areas and obtaining a sufficient amount of high-quality labeled froth images. To address these issues, a local feature enhancement-based improved semi-supervised condition recognition method (LFE-ISSM) is proposed. First, a local feature enhancement module is constructed by cascading ResNet18 with a convolutional block attention module (CBAM). This dual-attention mechanism, incorporating both channel attention and spatial attention, enhances the expression ability of local features in froth images. Then, an improved semi-supervised algorithm is used to train the condition recognition model, which integrates a threshold-based pseudo-label regularization strategy and a feature similarity alignment strategy within the Mean-Teacher framework to ensure the reliability of pseudo-labels and effectively guide the model to learn the latent structural information in the data. Experimental results show that the proposed method can effectively extract features from froth images and outperforms comparative methods in classification performance on practical industrial zinc flotation datasets.

Keywords: condition recognition; feature enhancement; semi-supervised learning; dual attention mechanism; pseudo-label regularization; feature similarity alignment

收稿日期: 2024-12-12; 录用日期: 2025-05-21.

基金项目: 国家自然科学基金项目 (62303404, 62303201, 62233018); 云南省基础研究计划面上项目 (202401CF070171, 202401CF070111); 兴滇英才支持计划-青年人才专项项目; 云南大学研究生科研创新项目 (ZC-24248842).

责任编辑: 阳春华.

†通信作者. E-mail: yfxie@csu.edu.cn.

0 引言

泡沫浮选是一种利用物料表面物理化学性质差异分离矿物与杂质或不同矿物的选矿方法,被广泛应用于选矿行业^[1-2]。泡沫表面的视觉特征能够有效反映浮选过程中矿物和气泡的附着情况,因此,可以作为实时监测浮选工况的重要指示器。在浮选厂中,工人通过肉眼观察泡沫形态、稳定性、颜色等特征监测工况。然而,人工观测方法存在明显局限:一方面,观测结果具有较强主观性,缺乏定量评价依据;另一方面,由于无法进行持续、实时的监测,易错过浮选过程中泡沫状态的关键变化。因此,人工观测不仅增加生产成本,还可能会导致资源浪费和浮选效率下降,影响整体经济效益。

为克服人工观测的不足,基于深度学习的浮选监测方法应运而生。深度学习使用多层神经网络从输入图像中提取深层抽象特征,在处理复杂非线性关系方面表现出显著优势^[3-4],将其应用于基于泡沫图像的监测任务,可提升浮选监测的自动化水平和准确性。Wang等^[5]采用堆叠图卷积网络挖掘泡沫图像数据中与浮选过程深度相关的结构特征,有效提升了氯化钾品位的预测精度;Yang等^[6]构建了多尺度神经网络,实现了对不同分辨率泡沫图像的统一建模,并通过迁移学习策略提高了低分辨率图像的预测效果,可有效预测煤浮选精矿灰分含量;Ai等^[7]提出了基于知识蒸馏和有监督对比学习的锌浮选工况识别方法,将经验知识传递到基于深度学习的特征编码网络,并通过正、负样本对比增强了不同工况类别特征的可区分性;Wang等^[8]使用基于多条件数据质心的快速插补算法处理在线样本缺失值,同时融合泡沫图像深度视觉特征和关键过程变量,有效辨识了金浮选工况;Zhou等^[9]构建了一种用于金浮选工况识别的深度集成模型,并在验证集中引入了基于混淆矩阵的隶属度函数对各子模型预测结果进行修正,最终通过基于 F_1 分数的逼近理想解排序法融合多个模型输出,实现了比单一模型更有效的工况识别。上述方法主要依赖大规模有标签数据进行训练,但是,在实际工业场景中,有标签数据往往较为稀缺,难以工况监测模型提供充分的监督信息。此外,这些方法未能充分挖掘泡沫图像在通道和空间维度上的关键特征,导致模型在特征提取过程中难以有效衡量不同特征的重要性,进而影响其特征表达能力和监测性能。

半监督学习方法通过结合少量标记数据和大量未标记数据进行训练,以解决分类任务中有标签数据稀缺的问题^[10]。如Wang等^[11]针对半监督学习中

固定或手动调整阈值的局限,提出了Freematch方法,该方法通过未标记数据置信度的指数滑动平均(exponential moving average, EMA)动态估计特定于数据集的全局阈值和特定于类别的局部阈值,自适应地筛选出高质量伪标签,并引入了自适应公平性机制,鼓励模型在各类别间进行平衡预测;Arazo等^[12]提出了基于伪标签的半监督学习方法(pseudo-labeling in deep semi-supervised learning, Pseudo-Labeling),该方法通过网络预测生成软伪标签来引导未标记数据的学习,并结合mixup增强,减少了模型对错误预测的过拟合;Xie等^[13]提出了基于一致性训练的无监督数据增强方法(unsupervised data augmentation for consistency training, UDA),该方法通过使用RandAugment等数据增强技术对未标记数据进行了高质量噪声注入,以提高模型对输入扰动的鲁棒性,并在一致性框架下提升了分类性能;Xu等^[14]提出了基于动态阈值的半监督方法(semi-supervised learning with dynamic thresholding, Dash),该方法在训练过程中动态调整阈值,仅保留损失较小的样本,避免使用不可靠的伪标签。随着训练的进行,阈值逐渐降低,将更多的无标记数据加入训练;Sohn等^[15]提出了Fixmatch,该方法通过对未标记数据应用弱增强生成伪标签,仅保留置信度超过阈值的伪标签,并结合这些高置信度的伪标签对应的同一数据的强增强版本进行一致性训练,提升了对未标记数据的利用效率。上述半监督方法基于伪标签和一致性正则化,但是,它们通常聚焦于单个数据的处理,缺乏对数据邻域分布的整体视角,未能充分挖掘数据结构,从而限制了模型对未标记数据的整体理解和有效利用。此外,这些方法的特征提取器缺乏自适应聚焦机制,对图像关键特征区域关注不足。

为有效提取泡沫图像的关键特征并应对有标签数据稀缺的挑战,本文提出一种基于局部特征增强的改进半监督工况识别方法(local feature enhancement-based improved semi-supervised condition recognition method, LFE-ISSM)。首先,采用融合ResNet18和卷积注意力模块(convolutional block attention module, CBAM)的网络作为特征提取器,其中CBAM通过在通道和空间两个维度对特征进行自适应加权,增强模型对泡沫图像中的关键特征的关注。然后,使用基于Mean-Teacher架构的改进半监督学习算法训练工况识别模型。通过引入基于阈值的伪标签正则化策略和特征相似性对齐策略改进半监督损失,以增强伪标签的可靠性,并有效指导模型学习未标记泡沫图像数据的潜在结构。具体

而言, 基于阈值的伪标签正则化策略通过设定预测概率阈值, 仅当无标签数据的预测概率超过该阈值时, 才将其纳入一致性损失计算, 从而有效减少噪声数据的影响, 提升训练过程的稳定性; 特征相似性对齐策略通过聚类分析, 在教师模型的特征空间中探索无标签数据间的相似性关系, 可有效识别数据的内在结构, 进而揭示其潜在模式. 学生模型根据潜在模式优化样本对的相对位置, 促进相似样本的聚合与不相似样本的分离, 从而增强模型的判别能力和鲁棒性.

1 浮选工艺描述与分析

泡沫浮选根据矿物表面物理化学性质的不同分选矿物. 具体而言, 矿石通过球磨机研磨成适宜大小后, 与适量水混合形成矿浆. 矿浆中加入捕收剂、起泡剂和调整剂等浮选药剂进行调和. 搅拌槽将调和后的矿浆充分搅拌后输送至浮选槽.

在浮选槽中, 浮选机电机带动转子高速旋转并带动叶轮搅拌矿浆将吸入的空气切割为大量微小气泡. 气泡在上升过程中与矿浆中的矿物颗粒碰撞, 疏水性矿物颗粒会粘附在气泡表面, 被一同带至矿浆表层, 形成浮选泡沫层, 用以收集精矿, 亲水性矿物颗粒则留在矿浆中作为尾矿排出浮选槽^[16-17].

图1为国内某浮选厂的锌浮选工艺流程. 锌浮选过程可分为粗选、精选和扫选3个阶段. 在快粗选阶段, 锌矿物与气泡结合形成泡沫层, 泡沫被刮板刮出, 随后进入精选I、精选II和精选III进行进一步处理, 以得到高品位的精矿. 与此同时, 快粗选后的尾

矿进入粗选I、粗选II和扫选I、扫选II、扫选III, 通过再浮选回收尾矿中残留的锌矿物, 从而进一步提高矿物的回收率. 通过这3个阶段的协同作用, 锌浮选过程能够有效地提取锌矿物, 最大化矿物的回收效率, 并提高最终精矿的品位. 鉴于锌快粗选是整个锌浮选过程的第1道工序, 以及药剂调整的首要阶段, 其分选效果直接影响后续的浮选工序, 因此将其作为本文的监测重点.

2 基于局部特征增强的改进半监督工况识别

在用于浮选过程工况识别的LFE-ISSM中, 训练数据被划分为有标签数据 $D^l = \{X^l, Y^l\} = \{x_i^l, y_i^l\}_{i=1}^{N_L}$ 和无标签数据 $D^u = \{X^u, -\} = \{x_i^u, -\}_{i=1}^{N_U}$. 其中: x_i 为泡沫图像, y_i 为对应的工况类别, N_L 、 N_U 分别为有标签数据和无标签数据的数量.

LFE-ISSM 的整体架构如图2所示. 所提出方法基于 Mean-Teacher 框架, 包含学生模型 F_s 和教师模型 F_t , 两者在特征提取模块 $f(\cdot) = f_c(f_r(x_i))$ 和分类头 $h(\cdot)$ 结构上完全一致. 在训练过程中, 教师模型通过学生模型参数的 EMA 进行参数更新, 以保持其稳定性并指导学生模型的学习. 为精确提取泡沫图像特征, 设计局部特征增强模块作为特征提取器. 该模块由 ResNet18 和 CBAM 级联组成. 泡沫图像数据首先通过 ResNet18 进行初步特征提取, 提取到的特征继续输入 CBAM 模块, 利用通道注意力和空间注意力双注意力机制对特征进行加权处理, 从而突出关键特征并抑制冗余或次要特征, 提高模型对重要特征的关注能力.

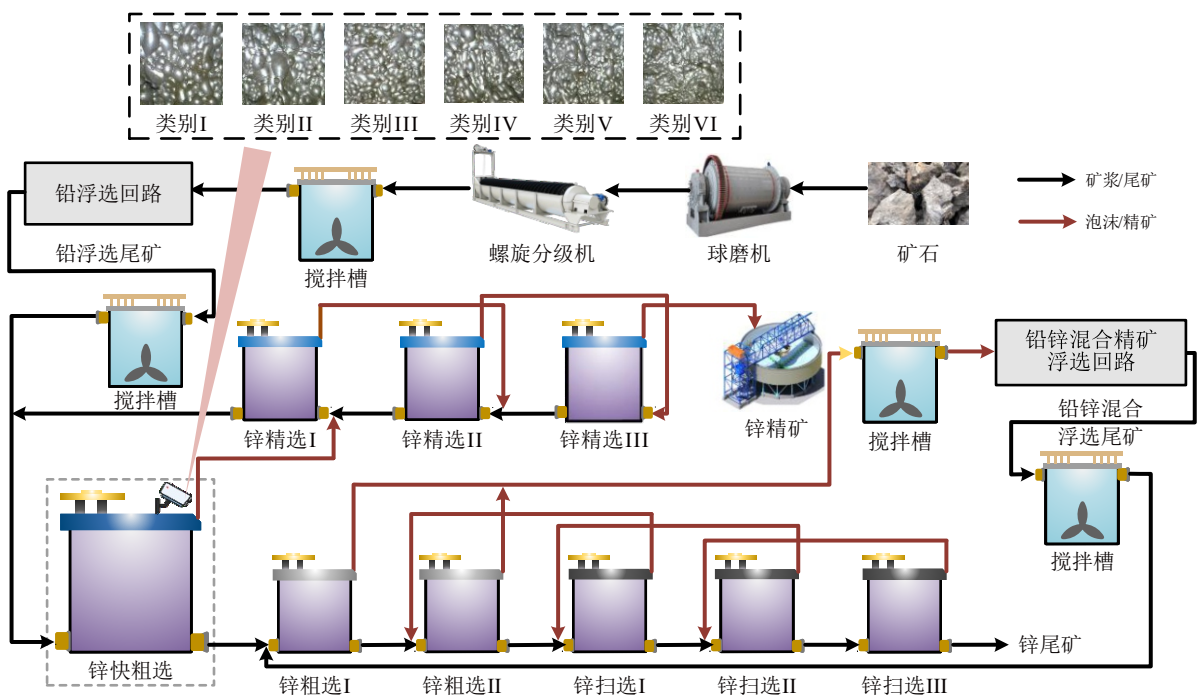


图1 锌浮选工艺流程

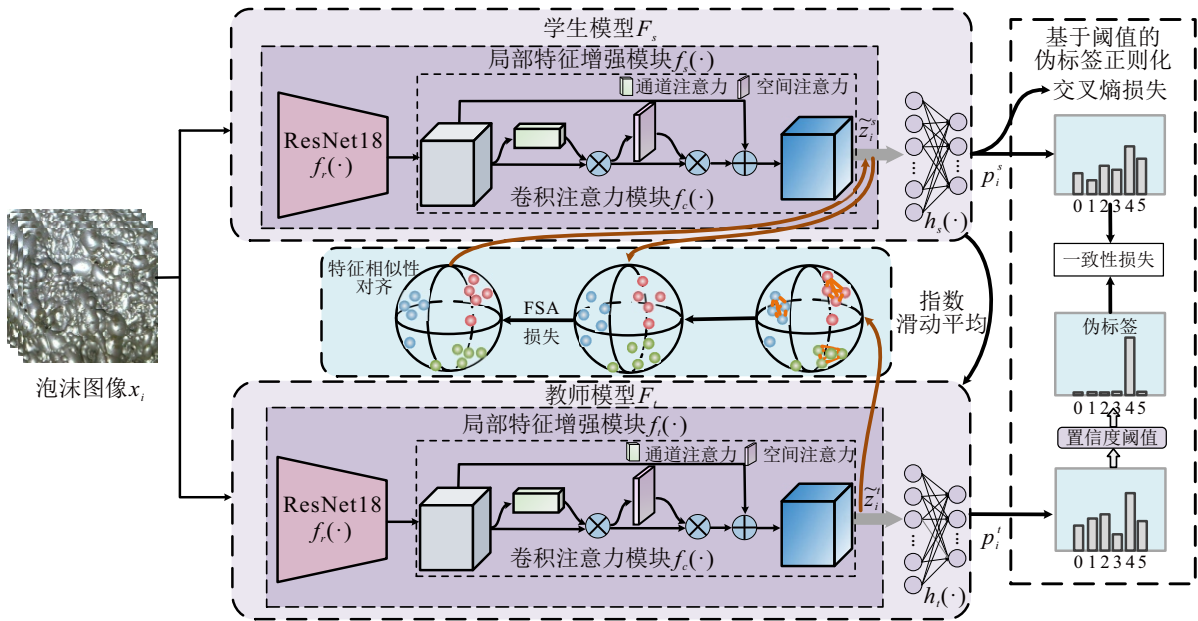


图2 基于局部特征增强的改进半监督工况识别方法框架

为提升半监督学习对无标签数据的利用效果,在 Mean-Teacher 的基础上引入了基于阈值的伪标签正则化策略和特征相似性对齐策略. 基于阈值的伪标签正则化通过设定置信度阈值, 筛选出预测类别概率超过阈值的无标签样本进行一致性损失计算, 以提高伪标签的准确性, 减少低置信度样本对模型训练的噪声干扰. 特征相似性对齐策略通过聚类算法在教师模型的特征空间中对无标签样本进行划分, 将其分为相似样本和不相似样本. 学生模型根据这种划分关系, 拉近相似样本的特征距离并推远不相似样本的特征距离, 从而优化特征空间, 帮助模型更好地捕捉数据间的潜在结构关系, 增强对数据分布的理解能力.

2.1 局部特征增强模块

为有效捕捉浮选泡沫图像中的关键特征, 提升模型在复杂工况下的识别精度, 本文采用集成 ResNet18 和 CBAM 的网络构建局部特征增强模块, 即将 CBAM 放置于 ResNet18 网络的最后一个卷积层后. 为保留原始特征信息并降低梯度消失的风险, ResNet18 和 CBAM 的级联方式保留 ResNet18 各层卷积的残差连接^[18]. CBAM 模块通过通道注意力和空间注意力双注意力机制, 自适应地增强模型对于局部特征的敏感性和提取能力^[19].

当泡沫图像 x_i 输入学生模型后, 首先通过 ResNet18 进行初步特征提取, 然后提取的特征进入 CBAM 模块. 在该模块中, 特征首先进行通道维度上的特征增强, 如图 3 所示. 具体而言: 首先, 将样本 x_i 输入 ResNet18 网络, 得到特征 $z_i^s \in \mathbb{R}^{C \times H \times W}$, C 、 H 、 W 分别为通道数、高度和宽度. 然后, 特征继续

输入 CBAM 模块, 在进入 CBAM 模块后, 特征首先通过通道注意力模块生成通道维度的注意力图 $M_c \in \mathbb{R}^{C \times 1 \times 1}$, 对每个通道的特征进行加权, 通道注意力的计算过程如下所示:

$$M_c(z_i^s) = \sigma(\text{MLP}(\text{AvgPool}(z_i^s)) + \text{MLP}(\text{MaxPool}(z_i^s))). \quad (1)$$

其中: $\text{AvgPool}(z_i^s)$ 和 $\text{MaxPool}(z_i^s)$ 分别表示对特征图 z_i^s 进行全局平均池化和全局最大池化, 得到每个通道的平均特征值 $z_{i,\text{avg}}^s$ 和最大特征值 $z_{i,\text{max}}^s$, 它们的输出维度均为 $\mathbb{R}^{C \times 1 \times 1}$; MLP 为多层感知机, σ 为 Sigmoid 激活函数, 它们构成一个共享网络, 用于产生每个通道的注意力权重. 将每个通道的注意力权重与原始特征的每个通道相乘, 得到特征 $\tilde{z}_i^s \in \mathbb{R}^{C \times H \times W}$, 计算过程如下所示:

$$\tilde{z}_i^s = M_c(z_i^s) \otimes z_i^s, \quad (2)$$

这里 \otimes 表示元素级乘法. 经过加权后, 特征图中的每个通道根据其重要性被重新赋予不同的权重, 从而使得重要的特征得到增强, 冗余或次要特征则被抑制.




图3 通道维度上的特征增强

将经过通道注意力加权得到的特征 \tilde{z}_i^s 输入空间注意力模块, 进行空间维度上的特征增强, 如图 4 所示. 空间注意力模块生成空间维度的注意力图 $M_s \in$

$\mathbb{R}^{1 \times H \times W}$, 在空间维度对特征图进行加权, 空间注意力的计算为

$$M_s(\bar{z}_i^s) = \sigma(f_{7 \times 7}([\text{AvgPool}(\bar{z}_i^s); \text{MaxPool}(\bar{z}_i^s)])) \quad (3)$$

其中: $\text{AvgPool}(\bar{z}_i^s)$ 和 $\text{MaxPool}(\bar{z}_i^s)$ 分别表示对特征 \bar{z}_i^s 沿通道维度进行全局平均池化和全局最大池化操作, 得到两个维度为 $\mathbb{R}^{1 \times H \times W}$ 的特征图; $[\cdot; \cdot]$ 表示将两个特征图在通道维度上进行拼接; $f_{7 \times 7}$ 表示核大小为7的卷积操作, 用于生成空间注意力权重. 将空间注意力权重逐像素地应用于特征 \bar{z}_i^s , 得到特征 $\tilde{z}_i^s \in \mathbb{R}^{C \times H \times W}$, 计算过程如下所示:

$$\tilde{z}_i^s = M_s(\bar{z}_i^s) \otimes \bar{z}_i^s \quad (4)$$

由于残差结构的引入, 最终学生模型的特征提取模块得到的特征为 $\tilde{z}_i^s = z_i^s + \tilde{z}_i^s$. 学生模型提取到的泡沫图像特征继续进入分类头, 得到对应的预测输出 $p_i^s = \text{softmax}(h_s(\tilde{z}_i^s))$. 同理, 泡沫图像 x_i 进入教师模型, 经过教师模型的局部特征增强模块后得到特征 \tilde{z}_i^t , 特征继续进入分类头后输出对应的预测 $p_i^t = \text{softmax}(h_t(\tilde{z}_i^t))$.




图4 空间维度上的特征增强

2.2 改进半监督学习

2.2.1 基于阈值的伪标签正则化策略

Mean-Teacher 半监督泡沫图像分类问题定义如下: 在数据加载阶段, 有标签的数据 x_i^l 被输入至学生模型 F_s 中, 无标签数据 x_i^u 则同时输入学生模型 F_s 和教师模型 F_t . 有标签数据进入学生模型后得到对应的特征 $\tilde{z}_i^{l,s}$ 和预测输出 $p_i^{l,s} = \text{softmax}(h_s(\tilde{z}_i^{l,s}))$. 有标签泡沫图像数据参与交叉熵损失的计算, 即

$$\ell_{\text{sup}} = \frac{-1}{N_L} \sum_{i=1}^{N_L} \sum_{c=1}^C y_{i,c}^l \log(p_{i,c}^{l,s}) \quad (5)$$

其中: $y_{i,c}^l \in \{0, 1\}$, 当样本 i 属于类别 c 时, 其为1; 否则为0. 无标签数据通过数据增强生成不同扰动后分别输入学生模型和教师模型, 得到相应的特征 $\tilde{z}_i^{u,s}$ 、 $\tilde{z}_i^{u,t}$ 以及预测输出 $p_i^{u,s} = \text{softmax}(h_s(\tilde{z}_i^{u,s}))$ 、 $p_i^{u,t} = \text{softmax}(h_t(\tilde{z}_i^{u,t}))$. 无标签泡沫图像数据用于两个模型生成的预测结果之间的一致性损失计算, 即

$$\ell_{\text{consistency}} = \frac{1}{N_U} \sum_{i=1}^{N_U} \|p_i^{u,s} - p_i^{u,t}\|^2 \quad (6)$$

然而, 模型对无标签泡沫图像的预测往往存在不确定性, 错误的预测可能会影响模型的训练效果及其泛化能力. 受到 Fixmatch 的启发, 本文对 Mean-Teacher 算法中的一致性损失进行改进, 提出了基于阈值的伪标签正则化策略. 具体而言, 通过设定置信度阈值, 仅选择预测概率高于阈值的伪标签数据参与训练, 从而提高伪标签的可靠性, 减少低置信度样本对模型训练的负面影响. 改进后的一致性损失为

$$\ell_{\text{consistency}} = \frac{-1}{N_U} \sum_{i=1}^{N_U} \sum_{c=1}^C y_{i,c}^{u,t} \mathbb{I}(p_{i,c}^{u,t} > \tau) \log(p_{i,c}^{u,s}) \quad (7)$$

其中: C 为类别数; $y_{i,c}^{u,t} = \text{one-hot}(\arg \max_c(p_{i,c}^{u,t}))$ 为教师模型对无标签数据进行预测后生成的伪标签; 约束条件 $\mathbb{I}(p_{i,c}^{u,t} > \tau)$ 表示教师模型的最大预测概率需要超过阈值 τ , 只有满足该条件时, 样本 x_i^u 才参与一致性损失计算.

2.2.2 特征相似性对齐策略

仅考虑单个数据的扰动而忽略数据间的联系, 可能会导致模型在未标记数据点附近表现良好, 但是在数据点间缺乏一致性^[20]. 因此, 在一致性正则化的基础上, 本文进一步考虑批次数据的相似性关系, 利用教师模型特征空间中无标签数据的特征, 挖掘当前批次无标签数据的潜在结构.

一批无标签数据 $X^u = \{x_1^u, x_2^u, \dots, x_B^u\}$ 经过数据增强后同时进入学生模型 F_s 和教师模型 F_t , 其中 B 为当前批次中的无标签泡沫图像数量. 通过局部特征增强模块从无标签数据中提取特征信息, 得到特征 $\tilde{Z}^{u,s} = \{\tilde{z}_1^{u,s}, \tilde{z}_2^{u,s}, \dots, \tilde{z}_B^{u,s}\}$ 和 $\tilde{Z}^{u,t} = \{\tilde{z}_1^{u,t}, \tilde{z}_2^{u,t}, \dots, \tilde{z}_B^{u,t}\}$, 对其进行 L2 归一化处理. 通过 K-Means 算法^[21]将教师模型得到的无标签样本特征分为不同的簇. 首先随机选择 C 个数据点作为聚类中心 $\{\mu_c\}_{c=1}^C$. 然后计算每个无标签样本特征 $\tilde{z}_i^{u,t}$ 到所有聚类中心的距离, 将其分类到最近的聚类中心所属的簇, 计算公式为

$$l_i = \arg \min_c \sqrt{\sum_{j=1}^D (\tilde{z}_{i,j}^{u,t} - \mu_{c,j})^2} \quad (8)$$

这里: l_i 为对应的簇标签, $\tilde{z}_{i,j}^{u,t}$ 为样本特征 $\tilde{z}_i^{u,t}$ 在第 j 个维度上的值, $\mu_{c,j}$ 为簇中心 μ_c 在第 j 个维度上的值, D 为样本特征的总维度. 接着, 对于每个簇 c , 计算所有样本的均值, 将其作为新的聚类中心, 即

$$\mu'_c = \frac{1}{K_c} \sum_{i=1}^{K_c} \tilde{z}_i^{u,t} \quad (9)$$

其中 K_c 为簇 c 中的样本数量. 这一过程重复循环进行, 直至聚类中心不再发生显著变化.

在簇划分完成后, 为提高簇的质量, 剔除离群点, 即距离簇中心较远的样本, 这些样本可能是噪声、异常值或并不真正属于该簇的值. 具体而言, 计算簇 c 内每个无标签样本特征 $\tilde{z}_i^{u,t}$ 与簇中心 μ_c^* 间的距离, 即

$$d_i = \|\tilde{z}_i^{u,t} - \mu_c^*\|_2 = \sqrt{\sum_{j=1}^D (\tilde{z}_{i,j}^{u,t} - \mu_{c,j}^*)^2}. \quad (10)$$

统计每个簇 c 内, 样本特征到簇中心的距离, 将中位数作为阈值 θ , 样本特征到簇中心的距离大于阈值的样本判定为离群点. 因此, 阈值并非采用固定值, 而是根据每个簇的具体数据分布动态计算. 通过这种方式, 离群点的剔除标准可根据簇的局部结构自适应调整, 从而增强算法的灵活性和鲁棒性.

剔除离群点后, 将位于同一簇内的样本特征定义为相似样本特征, 不同簇内的样本定义为不相似样本特征. 使用 w_{ij} 记录样本特征间的相似性关系, 当样本特征 $\tilde{z}_i^{u,t}$ 和 $\tilde{z}_j^{u,t}$ 位于同一个簇内时, $w_{ij} = 1$; 反之, 则为 $w_{ij} = 0$.

使用教师模型学习到的无标签数据的特征相似性, 约束学生模型的特征表示, 使得学生模型中相似样本对保持特征相似性, 不相似的样本对则保持不相似性. 当样本 x_i^u 与样本 x_j^u 在教师模型的特征空间中相似时, 即 $w_{ij} = 1$, 在学生模型的特征空间中要拉近这两个样本的特征距离; 反之, 则推远这两个样本的特征距离. 基于此, 设计特征相似性对齐 (feature similarity alignment, FSA) 损失函数, 引入一个边界 ζ 控制不相似样本对的余弦距离. 当余弦距离小于边界 ζ 时, 损失函数通过惩罚项 $\max(0, \zeta - (1 - \frac{z_{u,s}^i \cdot z_{u,s}^j}{\|z_{u,s}^i\|_2 \|z_{u,s}^j\|_2}))^2$ 扩大距离.

本文定义 FSA 损失为

$$l_{\text{FSA}} = \begin{cases} \left(1 - \frac{z_{u,s}^i \cdot z_{u,s}^j}{\|z_{u,s}^i\|_2 \|z_{u,s}^j\|_2}\right)^2, & w_{ij} = 1; \\ \max\left(0, \zeta - \left(1 - \frac{z_{u,s}^i \cdot z_{u,s}^j}{\|z_{u,s}^i\|_2 \|z_{u,s}^j\|_2}\right)\right)^2, & w_{ij} = 0. \end{cases} \quad (11)$$

其中 $\|\cdot\|_2$ 为 L2 范数.

综上所述, 半监督损失改写为

$$l = l_{\text{sup}} + \delta_1 l_{\text{consistency}} + \delta_2 l_{\text{FSA}}, \quad (12)$$

其中 δ_1 和 δ_2 为控制无监督损失对于半监督损失贡献度的权重.

3 实验结果与分析

3.1 实验设计与结果

为验证所提出 LFE-ISSM 方法在浮选过程工况识别中的有效性, 本实验在第 2 节所述的锌快粗选槽上方安装工业相机和光源, 实时拍摄浮选槽内泡沫的动态变化, 收集不同工况下的高质量图像数据, 收集到的 6 类典型工况下的泡沫图像如图 5 所示. 第 III 类为理想浮选状态, 此时矿物附着率最优, 泡沫层稳定且杂质含量降至最低; 第 I 类矿物附着率最低, 泡沫气泡较大, 气泡顶部有较多透明窗; 第 II 类矿物附着率介于工况类别 I 与工况类别 III 之间, 气泡较大, 透明窗较稀疏; 第 IV 类泡沫表面矿物附着率高于理想状态, 气泡较小, 且多呈椭圆形; 第 V 类泡沫表面矿物附着率过高, 气泡较小, 且由于变形严重, 泡沫层出现裂纹; 第 VI 类则为浮选故障状态, 泡沫中矿物数量超出其承载能力, 致使泡沫无法成形, 难以被收集. 实验数据集包含 60 000 张分辨率为 400×400 的泡沫图像. 数据集中的每类分别按照比例划分. 其中: 90% 的数据作为训练集, 10% 的数据作为测试集. 训练集中的数据进一步按照 2:7 的比例划分为有标签数据和无标签数据. 为避免破坏气泡的形状、大小以及颜色, 数据增强仅采用随机裁剪、中心裁剪、小幅度旋转和水平翻转. 具体过程如下: 首先将原始的 400×400 图像随机裁剪为 256×256 , 再进行中心裁剪得到 224×224 的图像; 然后对图像进行水平翻转和小幅度旋转处理. 由于数据增强的作用位置和发生概率不同, 同一图像会生成不同扰动版本.




图5 6 类典型工况下的泡沫图像

在训练阶段, 本文将学习率设置为 0.000 1, 优化器选用 SGD, 动量系数为 0.9, 权重衰减设为 $1e-4$, EMA 参数为 0.99. 优化算法涉及的超参数设置参考已有的半监督学习方法^[22]. 基于阈值的伪标签正则化策略中的置信度阈值 τ 和特征相似性对齐中的边

界 ζ 是本实验的关键参数. 若置信度阈值 τ 设定过低, 则会引入过多的噪声; 反之, 则会导致模型对无标签数据的利用率下降, 因此本实验将其设置为 0.9. 边界 ζ 的设定基于实验过程中对样本特征间距离的观察, ζ 过小可能会导致不相似样本过于接近, 进而影响模型的泛化能力; 而过大的 ζ 则可能会导致类别间的分界过于严格, 使得模型对于噪声敏感, 因此本实验将其设置为 1. 训练共进行 500 epoch, 并引入了早停策略, 即当测试集最佳精度在连续 50 epoch 内无变化时终止训练. 为避免模型在无标签数据上直接训练时产生不稳定的学习状态, 采用“预热”策略, 即在训练前 10 epoch 仅使用有标签数据进行初步训练, 随后逐步引入无标签数据参与训练. 实验评估使用准确率和 F_1 分数这两个指标, 有

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}, \quad (13)$$

$$F_1 = \frac{2 \times \frac{\text{TP}}{\text{TP} + \text{FP}} \times \frac{\text{TP}}{\text{TP} + \text{FN}}}{\frac{\text{TP}}{\text{TP} + \text{FP}} + \frac{\text{TP}}{\text{TP} + \text{FN}}}, \quad (14)$$

其中 TP、TN、FP、FN 分别为真阳性、真阴性、假阳性、假阴性.

6 类泡沫图像的分类准确率如表 1 所示. 其中: 第 I 类为 97.00%, 第 II 类为 88.50%, 第 III 类为 79.10%, 第 IV 类为 80.30%, 第 V 类为 77.90%, 第 VI 类为 91.30%. 由表 1 结果可见: 分类准确率较高的类别为类别 I、类别 II 和类别 VI, 表明这 3 类工况的泡沫图像特征较为明显, 模型可以较好地识别; 混淆较为严重的为类别 IV 和类别 V, 表明这两组类别间的特征相似度较高.

表1 6类泡沫图像的分类准确率 %

真实类别	预测类别					
	I	II	III	IV	V	VI
I	97.00	2.10	0.80	0.10	0.00	0.00
II	2.20	88.50	7.00	2.20	0.10	0.00
III	2.30	7.30	79.10	6.20	3.10	2.00
IV	0.00	2.60	8.30	80.30	8.80	0.00
V	0.00	0.00	4.00	9.70	77.90	8.40
VI	0.00	0.00	1.20	0.00	7.50	91.30

3.2 对比实验

为验证 LFE-ISSM 的有效性, 本文将全监督方法作为基线实验, 即不再将训练集按照 2:7 的比例进行划分, 直接将整个训练集用于训练 ResNet18 和 CBAM 的级联模型来进行工况分类. 同时, 将所提出方法与标准 Mean-Teacher 方法以及引言中提到的半监督方法, 即 Fixmatch、Freematch、UDA、Dash 和 Pseudo-Labeling 算法进行比较. 为保证实验的公平

性, 本研究对比的半监督方法均采用集成 CBAM 的 ResNet18 网络作为特征提取模型.

对比实验结果如表 2 所示. 在半监督分类方法中: Freematch 的效果最为不佳, 其分类准确率仅为 69.23%, F_1 分数为 0.6883, 原因在于该算法的自适应阈值调整策略依赖于模型对无标签数据的预测置信度, 该策略不适用于泡沫图像这类类别间差异较小且易出现标注错误的图像; 相比之下, UDA 的准确率和 F_1 分数分别比 Freematch 高出 8.34% 和 0.067, 该算法通过数据增强策略生成伪标签, 减少了训练过程中的偏差, 但是, 泡沫图像对于数据增强策略的高要求限制了其性能表现; Mean-Teacher 相比于 UDA 实现了更高的准确率和 F_1 分数, 分别为 79.96% 和 0.8007, 该算法通过生成教师模型和学生模型对无标签数据的一致性预测实现半监督学习^[22], 但是, 其性能易受到模型对无标签数据不准确预测的影响; 相较于 Mean-Teacher, Pseudo-Labeling 实现了更高的性能, 准确率为 82.90%, F_1 分数为 0.8297, 该算法通过模型生成的软伪标签来指导无标签样本的学习, 但是, 同样存在对无标签数据预测不准确的问题; Fixmatch 的性能优于 Pseudo-Labeling, 其准确率为 83.33%, F_1 分数为 0.8334, 该算法结合高置信度伪标签与一致性正则化提升了分类准确性; Dash 采用阈值约束的伪标签和一致性正则化进行半监督学习, 通过损失值动态调整阈值, 从而减少了模型对无标签数据错误预测的影响, 性能超过上述 5 种半监督方法, 达到了 83.78% 的准确率和 0.8369 的 F_1 分数; 然而, 所提出方法 LFE-ISSM 表现更为优异, 实现了 85.68% 的准确率和 0.8564 的 F_1 分数, 且准确率仅比全监督方法的 86.68% 低 1.00%, F_1 分数仅比全监督方法的 0.8666 低 0.0102, 充分表明了在有标签样本受限的情况下, LFE-ISSM 依然能够有效辨识工况, 展现出优越的性能优势.

表2 对比实验结果

方法	Acc/%	F_1
Supervised	86.68	0.8666
Freematch	69.23	0.6883
UDA	77.57	0.7553
Mean-Teacher	79.96	0.8007
Pseudo-Labeling	82.90	0.8297
Fixmatch	83.33	0.8334
Dash	83.78	0.8369
LFE-ISSM	85.68	0.8564

3.3 消融实验

为进一步研究 LFE-ISSM 各组成部分的贡献, 本文通过逐步移除特征相似性对齐策略、基于阈值的伪标签正则化策略以及 CBAM, 评估各部分的有

效性. 消融实验结果如图6所示. 图6结果表明: 当移除特征相似性对齐策略时, 模型分类准确率为83.37%, 较LFE-ISSM的准确率(85.68%)下降了2.31%, 表明该策略通过挖掘无标签数据的数据结构可显著提升模型分类性能; 当移除基于阈值的伪标签正则化策略时, 模型分类准确率为79.96%, 准确率在83.37%的基础上下降了3.41%, 表明该策略通过提高伪标签的可靠性能有效增强模型分类准确性; 当移除CBAM时, 模型分类准确率为76.82%, 准确率进一步下降了3.14%, 表明CBAM通过提取关键特征对于模型性能的提升具有重要作用. 实验结果清晰地验证了各部分在LFE-ISSM中的重要性及其对于模型性能贡献.

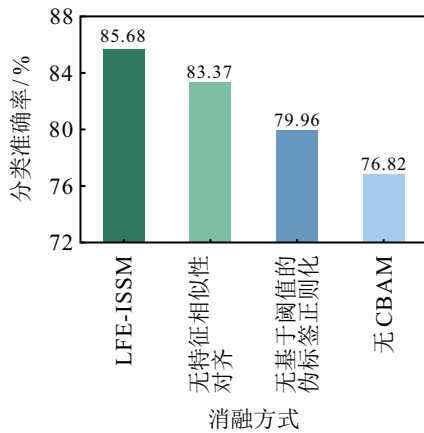


图6 消融实验结果

3.4 可视化

3.4.1 热力图可视化

为进一步分析局部特征增强模块的有效性, 本

文采用梯度加权类激活映射 (gradient-weighted class activation mapping, Grad-CAM) 方法深入分析浮选泡沫图像中各区域对于工况分类的贡献, 以揭示影响分类结果的关键区域. 本文从测试集中每个类别随机抽取图像进行可视化, 并将 ResNet18 模型和集成 CBAM 的 ResNet18 模型生成的热力图可视化结果进行比较, 如图7所示. 其中: 第1列和第4列为原始输入图像, 第2列和第5列为 ResNet18 的可视化结果, 第3列和第6列为集成 CBAM 的 ResNet18 模型的可视化结果, $p_c (c = 1, 2, \dots, 6)$ 表示模型将图像预测为第 c 类的 softmax 分数.

通过 Grad-CAM 的可视化分析, 能够清晰地展示集成 CBAM 的 ResNet18 模型在处理不同类别泡沫图像时所提取的关键视觉特征. 在第 I 类泡沫图像中: 气泡较大且顶部具有多个透明窗, 集成 CBAM 的 ResNet18 模型显著聚焦于这一关键特征区域, 激活区域明显且集中, 置信度高达 0.99; 而 ResNet18 模型虽然关注到了相似区域, 但是, 激活位置与最能代表类别 I 的特征区域未完全匹配, 且置信度较低 (0.48). 在第 II 类泡沫图像中: 气泡尺寸较大, 但是顶部透明窗较为稀疏, 集成 CBAM 的模型准确聚焦于这一特征区域, 且置信度高达 0.96; 相对而言, ResNet18 也聚焦于关键特征区域, 但是置信度只达到了 0.81. 对于第 III 类泡沫图像: 气泡尺寸均匀且泡沫稳定, 集成 CBAM 的 ResNet18 模型能够有效捕捉泡沫稳定区域, 且其激活区域集中, 置信度为 0.78; 而 ResNet18 未能准确区分特征, 置信度仅为 0.44. 第 IV 类泡沫图像中: 气泡较小, 且多呈现出椭圆形,

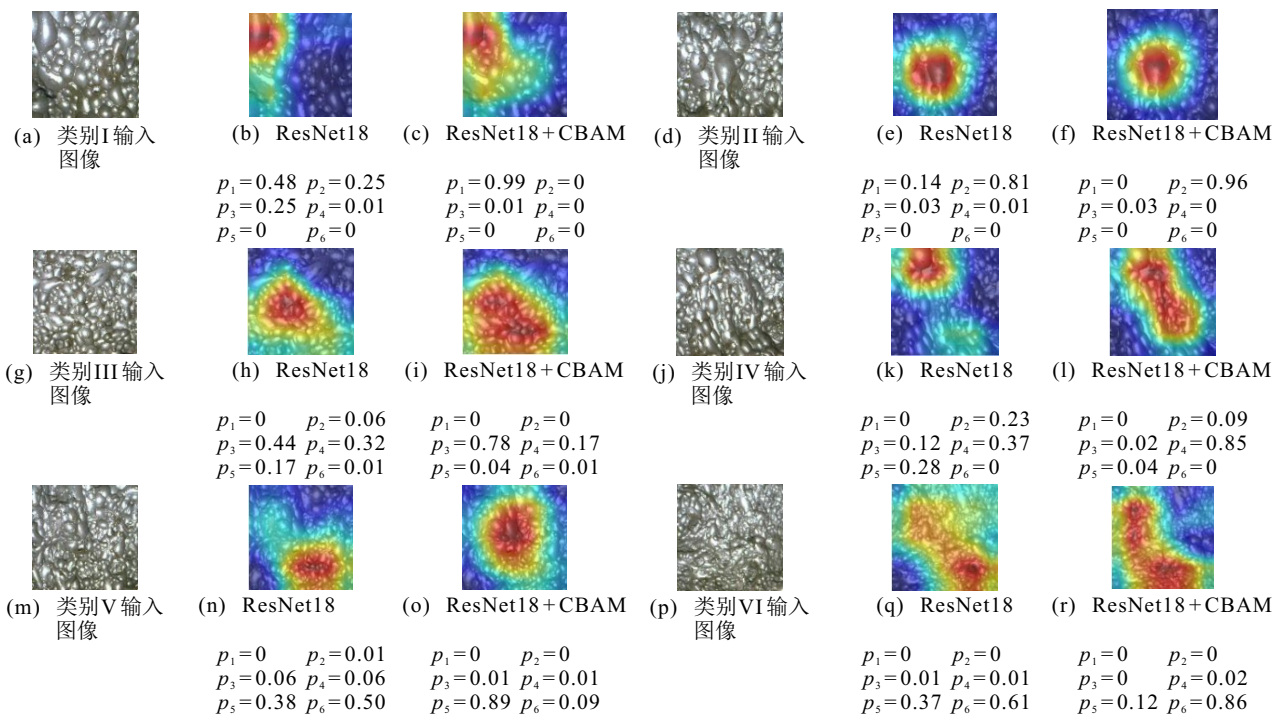


图7 ResNet18 模型和集成 CBAM 的 ResNet18 模型生成的热力图可视化

集成 CBAM 的模型成功识别并精准聚焦于气泡变形的关键区域; 而 ResNet18 未能有效识别该区域. 第 V 类泡沫图像中: 气泡变形明显且泡沫层出现裂纹, 集成 CBAM 的模型能够清晰地激活这些关键区域; 而 ResNet18 不仅未能正确识别裂纹特征, 还发生了错误分类, 将其误判为第 VI 类. 最后, 在第 VI 类泡沫图像中: 泡沫层较薄, 难以成型, 集成 CBAM 的 ResNet18 模型聚焦于泡沫层薄弱区域, 激活区域集中且准确; 而 ResNet18 尽管也关注到了该区域, 但是其聚焦效果较为分散.

通过对 6 个类别的泡沫图像的 Grad-CAM 可视化对比可知, 集成 CBAM 的 ResNet18 模型可聚焦于与每个类别相关的关键特征区域, 能够显著抑制无关特征的干扰. 与 ResNet18 相比, 集成 CBAM 的 ResNet18 不仅在分类准确率上表现优异, 且可增强模型对于不同类别间细微特征差异的敏感性.

3.4.2 t-SNE 可视化

为评估 LFE-ISSM 对不同类别泡沫图像特征的聚类效果, 本研究采用 *t* 分布随机邻域嵌入 (*t*-distributed stochastic neighbor embedding, *t*-SNE) 对模型训练初期和模型训练收敛时在测试集上的表现进行可视化分析, 结果如图 8 所示. 测试集由模型训练过程中未出现过的数据构成, 因此, 该可视化结果在反映模型对不同特征的分辨能力的同时能够有效

体现模型的泛化能力. 图 8(a) 为 LFE-ISSM 模型训练初期在测试集上的 *t*-SNE 可视化结果. 由图 8(a) 可见, 测试集中的不同类别数据点存在较大重叠, 整体特征分布较为分散且无明显的类别分离, 表明泡沫图像在特征空间中的类别区分度较低, 分类难度较大. 图 8(b) 为 LFE-ISSM 模型训练收敛时在测试集上的 *t*-SNE 可视化结果. 在优化后的特征空间中, 不同类别的数据点形成相对独立且清晰的簇结构, 类别间的重叠现象显著降低. 这一变化表明, LFE-ISSM 能够有效区分不同特征, 表现出良好的泛化能力. 具体而言, 类别 I、类别 II 和类别 VI 呈现出相对独立的簇结构, 表明模型能够很好地识别并区分这 3 个类别的泡沫图像特征. 相比之下, 由于类别 III 泡沫图像的视觉特征不够显著, 以及类别 IV 与类别 V 图像的视觉特征高度相似, 导致模型对这 3 个类别的分辨性能略低于类别 I、类别 II 与类别 VI. 这一结论与表 1 结果相符.

4 结论

针对深度学习应用于浮选监测过程中面临对关键特征区域感知不足和高质量有标签泡沫图像匮乏的问题, 本文提出了一种基于局部特征增强的改进半监督工况识别方法. 为准确提取泡沫图像关键特征, 所提出方法构建了局部特征增强模块, 即级联 ResNet18 和 CBAM, 使得模型能够聚焦于浮选泡沫图像通道级别和空间级别的关键信息. 为克服有标签数据稀缺的难题, 本文采用了改进的半监督算法训练工况识别模型. 一方面, LFE-ISSM 对 Mean-Teacher 模型中的一致性损失进行了改进, 通过引入阈值约束优化伪标签质量, 从而稳定了半监督的训练过程; 另一方面, LFE-ISSM 还在 Mean-Teacher 模型中引入了特征相似性对齐策略, 通过挖掘无标签泡沫图像数据的结构, 显著提高了模型对无标签数据的利用效率. 实验结果表明, 所提出方法能够在标注样本受限的情况下提取关键特征, 进而有效识别工况. 然而, 从实验结果可以看出, 所提出方法在处理视觉特征相似的样本时仍然存在辨识能力不足的问题, 影响了模型在部分工况类别上的分类效果. 后续研究将聚焦于提升特征的表达能力和区分度, 以增强模型对复杂工况的识别准确性.

参考文献 (References)

[1] Xu P F, Tian L K, Liu J P, et al. MsFfTsGP: Multi-source features-fused two-stage grade prediction of zinc tailings in lead-zinc flotation process via multi-stream 3D convolution with attention mechanism[J]. *Engineering Applications of Artificial Intelligence*, 2024, 129: 107647.

[2] 毛腾, 褚菲, 王建文, 等. 基于分布式混合贝叶斯网络

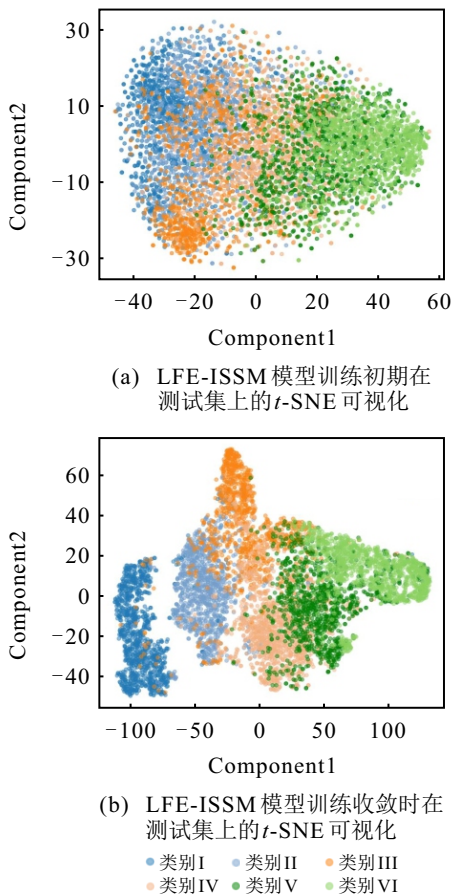


图8 测试集的 *t*-SNE 可视化

- 的煤泥浮选过程安全运行与产品质量一体化控制方法[J]. 控制与决策, 2025, 40(2): 497-506.
(Mao T, Chu F, Wang J W, et al. An integrated safe operation and product quality control method for coal slurry flotation process based on distributed hybrid Bayesian network[J]. Control and Decision, 2025, 40(2): 497-506.)
- [3] 刘颖, 刘德彦, 吕政, 等. 融合深度特征与多核学习的LSTWSVM及其工业应用[J]. 控制与决策, 2024, 39(8): 2622-2630.
(Liu Y, Liu D Y, Lv Z, et al. LSTWSVM fusion of deep feature and multiple kernel learning and its industrial applications[J]. Control and Decision, 2024, 39(8): 2622-2630.)
- [4] 褚菲, 郝莉莉, 王福利. 复杂工业过程运行状态评价方法回顾与展望[J]. 控制与决策, 2024, 39(3): 705-718.
(Chu F, Hao L L, Wang F L. Review and prospect of operation performance assessment methods for complex industrial processes[J]. Control and Decision, 2024, 39(3): 705-718.)
- [5] Wang Y L, Sui Q K, Liu C L, et al. Interpretable prediction modeling for froth flotation via stacked graph convolutional network[J]. *IEEE Transactions on Artificial Intelligence*, 2024, 5(1): 334-345.
- [6] Yang X L, Zhang K F, Thé J, et al. Multi-scale neural network for accurate determination of the ash content of coal flotation concentrate using froth images[J]. *Expert Systems with Applications*, 2025, 262: 125614.
- [7] Ai M X, Xie Y F, Ding S X, et al. Domain knowledge distillation and supervised contrastive learning for industrial process monitoring[J]. *IEEE Transactions on Industrial Electronics*, 2022, 70(9): 9452-9462.
- [8] Wang Y C, Wang S, Li K. Multi-condition flotation process condition recognition method based on deep learning and multivariate data pre-processing[C]. Proceedings of the 36th Chinese Control and Decision Conference. Xi'an, 2024: 1975-1980.
- [9] Zhou X J, He Y P. Deep ensemble learning-based sensor for flotation froth image recognition[J]. *Sensors*, 2024, 24(15): 5048.
- [10] Wang Y D, Chen H, Fan Y, et al. USB: A unified semi-supervised learning benchmark for classification[J]. *Advances in Neural Information Processing Systems*, 2022, 35: 3938-3961.
- [11] Wang Y D, Chen H, Heng Q, et al. FreeMatch: Self-adaptive thresholding for semi-supervised learning[J/OL]. 2022, arXiv: 2205.07246.
- [12] Arazo E, Ortego D, Albert P, et al. Pseudo-labeling and confirmation bias in deep semi-supervised learning[C]. International Joint Conference on Neural Networks. Glasgow, 2020: 1-8.
- [13] Xie Q Z, Dai Z H, Hovy E, et al. Unsupervised data augmentation for consistency training[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 6256-6268.
- [14] Xu Y, Shang L, Ye J X, et al. Dash: Semi-supervised learning with dynamic thresholding[C]. Proceedings of the 38th International Conference on Machine Learning. Virtual, 2021: 11525-11536.
- [15] Sohn K, Berthelot D, Carlini N, et al. FixMatch: Simplifying semi-supervised learning with consistency and confidence[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 596-608.
- [16] Nayak A, Jena M S, Mandre N R. Beneficiation of lead-zinc ores — A review[J]. *Mineral Processing and Extractive Metallurgy Review*, 2022, 43(5): 564-583.
- [17] Han J K, Chen P, Liu T S, et al. Research and application of fluidized flotation units: A review[J]. *Journal of Industrial and Engineering Chemistry*, 2023, 126: 50-68.
- [18] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]. *IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, 2016: 770-778.
- [19] Woo S, Park J, Lee J Y, et al. CBAM: Convolutional block attention module[C]. *Proceedings of the 15th European Conference on Computer Vision*. Munich, 2018: 3-19.
- [20] Luo Y C, Zhu J, Li M X, et al. Smooth neighbors on teacher graphs for semi-supervised learning[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, 2018: 8896-8905.
- [21] MacQueen J. Some methods for classification and analysis of multivariate observations[C]. *Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability*. California, 1967, 1(14): 281-297.
- [22] Tarvainen A, Valpola H. Mean teachers are better role models: Weight-averaged consistency targets improve semi-supervised deep learning results[C]. *Advances in Neural Information Processing Systems*. Long Beach, 2017: 1195-1204.

作者简介

艾明曦 (1991-), 女, 讲师, 博士, 主要研究方向为基于机器视觉的复杂工业过程智能监测、优化与控制, E-mail: mingxi_ai@ynu.edu.cn;

许庆 (1999-), 女, 硕士生, 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: xuqing@stu.ynu.edu.cn;

张进 (1990-), 男, 讲师, 博士, 主要研究方向为图像处理、深度学习、软测量建模, E-mail: j.zhang@kust.edu.cn;

孔庆洁 (2000-), 女, 硕士生, 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: kongqingjie@stu.ynu.edu.cn;

李鹏 (1976-), 男, 教授, 博士, 博士生导师, 主要研究方向为智慧能源系统、工业过程监测与控制, E-mail: lipeng@ynu.edu.cn;

谢永芳 (1972-), 男, 教授, 博士, 博士生导师, 主要研究方向为工业人工智能方法及应用、机器视觉与感知、智能优化与控制、深度学习, E-mail: yfxie@csu.edu.cn;

唐朝晖 (1965-), 男, 教授, 博士, 博士生导师, 主要研究方向为复杂工业系统的建模与优化控制、信息处理、计算机技术的研究与应用、图像处理技术, E-mail: zhtang@csu.edu.cn.