

引用格式: LIAO Yi-peng, YANG Jie-jie, WANG Zhi-gang, *et al.* Flotation Performance Recognition Based on Dual-modality Convolutional Neural Network Adaptive Transfer Learning[J]. *Acta Photonica Sinica*, 2020, 49(10):1015001

廖一鹏, 杨洁洁, 王志刚, 等. 基于双模态卷积神经网络自适应迁移学习的浮选工况识别[J]. 光子学报, 2020, 49(10):1015001

基于双模态卷积神经网络自适应迁移学习的 浮选工况识别

廖一鹏¹, 杨洁洁¹, 王志刚², 王卫星¹

(1 福州大学 物理与信息工程学院, 福州 350108)

(2 福建金东矿业股份有限公司, 福建 三明 365101)

摘要:为提高小规模训练集下 CNN 特征驱动的浮选工况识别效果, 提出一种基于泡沫红外与可见光图像 CNN 特征提取及自适应迁移学习的工况识别方法. 首先构建基于 AlexNet 的双模态 CNN 特征提取及识别模型, 并通过 RGB-D 大规模数据集对模型的结构参数进行预训练; 其次, 用多个串联的双隐层自编码极限学习机代替预训练模型的全连接层, 实现对双模态 CNN 特征的融合及逐层抽象提取, 然后通过核极限学习机映射到更高维空间进行决策; 最后构建浮选小规模数据集对迁移后的模型进行训练, 并改进量子狼群算法用于模型参数优化. 实验结果表明: 自适应迁移学习能够明显提高小样本数据集下的识别准确度, 采用双模态 CNN 迁移学习较单模态 CNN 迁移学习的工况识别精度提高了 3.06%, 各工况的平均识别准确率达到 96.83%, 识别精度和稳定性较现有方法有较大提升.

关键词: 机器视觉; 浮选工况识别; 红外与可见光图像; 卷积神经网络; 迁移学习; 双隐层自编码极限学习机; 量子狼群算法

中图分类号: TP391

文献标识码: A

doi: 10.3788/gzxb20204910.1015001

Flotation Performance Recognition Based on Dual-modality Convolutional Neural Network Adaptive Transfer Learning

LIAO Yi-peng¹, YANG Jie-jie¹, WANG Zhi-gang², WANG Wei-xing¹

(1 College of Physics and Information Engineering, Fuzhou University, Fuzhou 350108, China)

(2 Fujian Jindong Mining Co. Ltd., Sanming, Fujian 365101, China)

Abstract: In order to improve the effect of CNN feature driven flotation performance recognition under small-scale training set, a method of flotation performance recognition based on adaptive transfer learning and CNN features extraction of foam infrared and visible images is proposed. Firstly, a dual-modality CNN feature extraction and recognition model based on AlexNet was constructed, and the structural parameters of the model were pre-trained through RGB-D large-scale data set. Secondly, a series of double hidden layer automatic encoder extreme learning machine is used to replace the full connection layer of the pre-training model, so that the dual-modality CNN features can be fused and abstracted layer by layer, and then the decision is made by mapping to higher dimensional space through the kernel extreme learning machine. Finally, the flotation small-scale data set is constructed to train the migrated model, and the improved quantum wolf pack algorithm is used for model parameter optimization. Experimental

基金项目: 国家自然科学基金(Nos.61471124, 61601126), 福建省自然科学基金(No.2019J01224), 福建省中青年教师教育科研项目(No. JT180056)

第一作者: 廖一鹏(1982—), 男, 讲师, 博士研究生, 主要研究方向为机器视觉技术、图像处理与模式识别. Email: fzu_lyp@163.com

通讯作者: 王卫星(1959—), 男, 教授, 博士, 主要研究方向为人工智能、图像处理与模式识别. Email: wxwxw@fzu.edu.com

收稿日期: 2020-04-09; **录用日期:** 2020-06-17

<http://www.photon.ac.cn>

results show that, adaptive transfer learning can significantly improve the accuracy of recognition in small sample data sets, the accuracy of performance recognition using dual-modality CNN transfer learning is 3.06% higher than that of single-mode CNN transfer learning, and the average recognition accuracy of each working condition reached 96.86%. The accuracy and stability of flotation performance recognition is greatly improved compared with the existing methods.

Key words: Machine vision; Flotation performance recognition; Infrared and visible images; Convolutional neural network; Transfer learning; Double hidden layer automatic encoder extreme learning machine; Quantum wolf pack algorithm

OCIS Codes: 150.1135; 100.4994; 110.2960

0 引言

浮选生产是选矿厂从矿石中提炼出金属矿物的最有效选矿方法,浮选工况指的是浮选生产过程的工作状态,工况的好坏决定了浮选回收率的高低,及时准确地识别工况对浮选生产的优化控制至关重要。目前,大部分浮选厂主要依靠人工肉眼观察浮选槽表面泡沫状态的变化进行生产工况的判别,这种方式主观性强、效率低,随着机器学习技术的发展,基于机器视觉的浮选生产指标预测方法逐渐成为研究热点^[1]。

浮选槽表面的泡沫特征与浮选工况有很强的相关性^[2],研究人员通过泡沫表面图像的各类特征建立工况识别模型^[3-4],实现了浮选工况的智能化识别,但识别精度受特征提取误差的影响较大,鲁棒性不强。卷积神经网络(Convolutional Neural Network, CNN)^[5]可从图像集中提取有效特征并与目标关系间进行深度学习,避免了复杂的特征提取过程,已在图像处理领域得到广泛应用。近年来,卷积神经网络已在浮选泡沫图像处理中得到应用研究。FU Y等最先将CNN应用于浮选泡沫图像的处理^[6],采用大数据集预训练的AlexNet网络提取泡沫图像特征并通过随机森林算法进行分类,与传统的特征提取方法相比,大大提高了识别精度;WANG X L等对分割后的泡沫图像进行CNN特征提取及分类^[7],通过统计各类气泡出现的频率分布进行工况识别,具有较高的准确度和效率;LIU L等设计了只含两个卷积层的简易CNN网络提取泡沫图像特征^[8],并通过SVM分类器实现了浮选过程故障检测;FU Y等在原先研究基础上,对预训练的AlexNet网络模型进行迁移学习^[9],构建浮选小数据集对全连接层参数重新训练,进一步提高了识别精度。这类方法都只考虑对泡沫可见光图像的静态特征提取,而泡沫红外热成像能表征气泡的破碎、合并等动态特征,可综合考虑提取两种模态图像的CNN特征,使特征更具多样性,进一步扩大样本量,有助于提高识别精度。卷积神经网络要求训练和测试的数据分布一致,并且需要大量样本进行训练才能获得优秀的网络结构,然而浮选厂现场工作环境恶劣,大规模样本的建立较为困难,迁移学习解决了训练样本和测试样本必须独立同分布以及样本数据量需求较大的问题^[10],将大规模数据集的学习知识迁移到小样本数据集的训练中,从而提高了卷积神经网络在小样本数据集应用中的分类精度。

综上所述,本文提出一种基于泡沫双模态图像CNN特征提取及自适应迁移学习的工况识别方法,以提高小规模训练集条件下的工况识别效果。在AlexNet基础上,构建泡沫可见光与红外图像的双模态CNN特征提取及识别模型,选择同样具有双模态图像的RGB-D大规模数据集对模型的结构参数进行预训练;然后对预训练模型的双模态CNN特征提取部分直接迁移,而用多个串联的双隐层自编码极限学习机代替全连接层,对提取的双模态特征进行融合及逐层抽象提取,再通过核极限学习机映射到更高维空间进行决策;最后,构建泡沫双模态图像小规模数据集对迁移后的模型进行训练,并改进量子狼群算法对模型参数进一步优化,以提高识别精度和泛化性能,增强稳定性。

1 双模态CNN特征提取及识别模型

根据精矿品位的等级可以将浮选生产过程分为优、良、中、合格、差、异常等六种工况^[7],浮选泡沫的表观特征是生产工况的综合反映,泡沫表面的静态和动态特征可作为工况评判的依据,目前研究人员主要通过检测前后帧图像信息的变化进行泡沫动态特征的提取^[3-4],因受光照及泡沫表面动态变化的影响,检测精度不高。对浮选槽表面的泡沫进行红外热成像,发现气泡产生崩塌或合并后释放出热量,相比周围气泡的温度高,热成像后呈现出高亮的黄色区域,对气泡稳定性具有一定的展现效果,泡沫双模态图像如图1所示,图1(a)的泡沫可见光图像只能表观颜色、尺寸、形状、分布等静态特征,而对应的红外热成像图1(b)能直接展现产

生崩塌、合并的气泡,图1(c)中红外图像有两个气泡产生崩塌,图1(d)中红外图像有三个小气泡合并成一个大气泡,泡沫红外图像对泡沫动态特征具有一定的表征作用.因此,可综合提取泡沫可见光和红外图像的双模态CNN特征作为工况识别的驱动特征.




图1 浮选泡沫双模态图像
Fig. 1 Flotation foam dual-modality image

2012年,KRIZHEVSKY A等^[11]提出的 AlexNet 网络在图像特征提取及识别方面的性能优于传统的卷积神经网络,且可以处理较大图像,随后提出的 VGG-16 和 ResNet 比 AlexNet 的性能更好^[10],但网络结构复杂,训练非常耗时.本文选用相对简单且易于训练的 AlexNet 网络构建双模态 CNN 模型, AlexNet 网络需要 3 通道的 227×227 图像作为输入,因此将两种模态的 256×256 图像通过非下采样剪切波变换(Non-Sub-sampled Shearlet Transform, NSST)^[12]分解为低频子带、高频尺度 1、高频尺度 2 等 3 个尺度图像,低频子带反映图像抽象的语义、结构等全局信息,高频尺度 1 主要反映图像纹理和粗边缘信息,而高频尺度 2 主要反映图像边缘细节信息.将 3 尺度的 256×256 图像插值处理成 3 张 227×227 图像作为 AlexNet 网络的输入,图像 3 尺度分解后进行 CNN 特征提取能够充分挖掘出图像的轮廓、纹理和边缘细节信息,而且扩大了样本数量,有利于提高图像的分类精度.本文所构建的双模态 CNN 网络结构如图 2 所示,包含上下两个通道的 AlexNet 网络,每个 AlexNet 保留原有的 5 个卷积层、3 个池化层和 1 个全连接层 fc6,将两个通道的 fc6 级联拼接,然后通过 fc7、fc8 进行特征融合和学习,最后采用 softmax 进行多分类.在实际应用中,构建大规模泡沫双模态数据集较为耗时,根据迁移学习思想^[13],如果源领域和目标领域的任务相似,源领域模型的有些参数将有助于目标领域模型的学习,可将源领域模型的部分参数直接迁移到目标领域模型中,RGB-D 数据集包含 RGB 和景深两种模态图像,泡沫双模态图像识别与 RGB-D 图像识别的任务相似,可借助较大规模的 RGB-D 数据集对模型预训练,本文采用 LAIK 等人公布的 RGB-D 数据集^[14]进行预训练,该数据集包含 51 个不同类别的家用物品,共有将近 25 万张 RGB-D 图像.

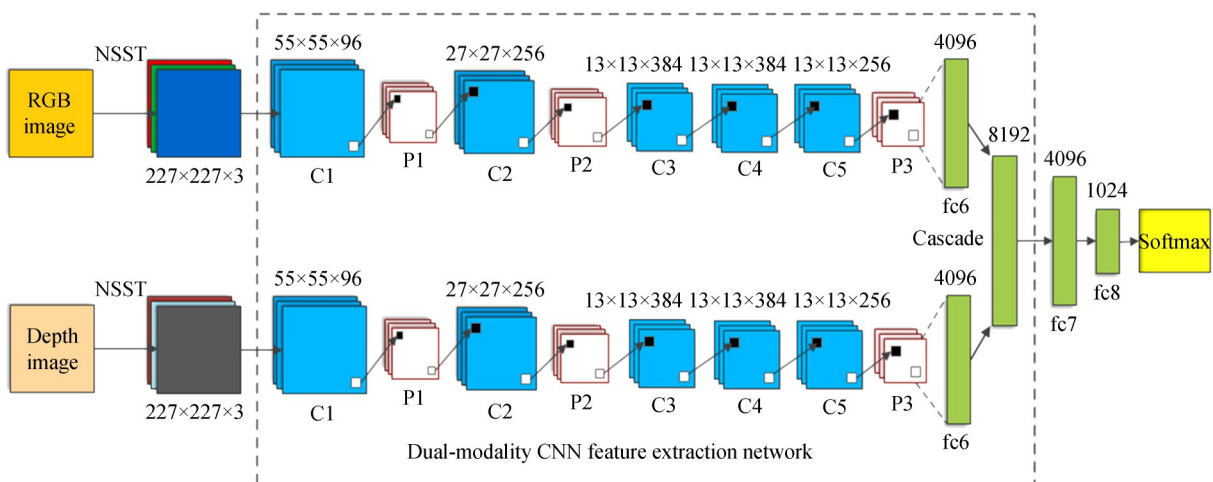


图2 双模态CNN特征提取及识别模型
Fig. 2 Dual-modality CNN feature extraction and recognition model

2 自适应迁移学习及工况识别

2.1 量子狼群算法改进

狼在恶劣环境下经过漫长的演化和繁衍,展现出令人赞叹的群体智能行为,吴虎胜等^[15]根据狼群协作捕猎的方式提出狼群算法(Wolf Pack Algorithm, WPA),该算法具有优秀的全局搜索和局部开发能力,引起广大学者的关注,被迅速应用于实际工程的优化控制.随着量子计算的发展,涌现出一些量子衍生优化算法,如:量子遗传算法(Quantum Genetic Algorithm, QGA)^[16]、量子和声搜索算法(Quantum Harmony Search, QHS)^[17]、量子菌群算法(Quantum Bacterial Foraging Algorithm, QBFA)^[18]等,这些算法借助量子叠加态和量子编码更新策略,能大幅度增强算法的寻优性能.GAO Y J等^[19]将量子计算引入到狼群算法的优化中,形成具有更强寻优能力的量子狼群算法(Quantum Wolf Pack Algorithm, QWPA),该算法将人工狼用多量子比特的形式表示,利用量子旋转门来控制量子比特的概率幅,从而调整狼群的捕猎行为,主要分为头狼产生、游走、召唤、围攻,狼群更新等步骤,提升了经典狼群算法的寻优性能,但该算法在狼群更新机制中,采用淘汰一部分较差人工狼,同时随机产生一部分新的人工狼,这将导致狼群多样性的缺乏,不能保证下一代狼群具有最优的适应度,影响收敛速度、易陷入局部极值.本文保留QWPA的头狼产生、游走、召唤、围攻等部分,而在狼群更新过程中,淘汰比例因子为 γ 的一部分较差人工狼,选取相同数量的较优人工狼,以头狼作为参照对象,采用量子旋转门进行更新和繁殖,保证狼群的多样性.

在量子狼群算法中,人工狼采用量子比特编码表示,一个量子比特可表示为: $|\phi\rangle = a|0\rangle + b|1\rangle$,其中 (a, b) 是两个幅常数, $|a|^2 + |b|^2 = 1$,一个量子同时包含 $|0\rangle$ 和 $|1\rangle$ 两个态的信息,人工狼和狼群的量子比特编码如式(1)所示.

$$\begin{cases} w'_m = \begin{bmatrix} \alpha'_{11} & \alpha'_{12} & \dots & \alpha'_{1h} \\ \beta'_{11} & \beta'_{12} & \dots & \beta'_{1h} \end{bmatrix}, m = 1, 2, \dots, M \\ W(t) = \{w'_1, w'_2, \dots, w'_M\} \end{cases} \quad (1)$$

式中, w'_m 表示第 m 个人工狼比特编码, t 为人工狼的繁衍代数, M 为人工狼数量,每匹人工狼包含 l 个基因, h 为编码每个基因的比特数, $W(t)$ 表示处于第 t 代的狼群编码.量子狼群通过量子旋转门实现进化操作,调整量子比特朝着有利的方向进化,量子旋转门的调整操作表示为

$$\begin{bmatrix} a'_i \\ b'_i \end{bmatrix} = \begin{bmatrix} \cos(\Delta\theta_i) & -\sin(\Delta\theta_i) \\ \sin(\Delta\theta_i) & \cos(\Delta\theta_i) \end{bmatrix} \begin{bmatrix} a_i \\ b_i \end{bmatrix} \quad (2)$$

式中, $(a_i, b_i)^T$ 与 $(a'_i, b'_i)^T$ 分别为第 i 个量子比特经旋转门更新前后的概率幅, $\Delta\theta_i$ 表示旋转相位.本文提出一种动态自适应旋转角函数为

$$\Delta\theta_i = -\text{sgn}(A_i) \left| \frac{\theta_{\text{best}} - \theta_i}{\pi} \right|^\lambda \Delta\theta e^{-\frac{k}{K_{\text{max}}}} \quad (3)$$

式中, $A_i = \begin{bmatrix} a_{\text{best}} & a_i \\ b_{\text{best}} & b_i \end{bmatrix}$, $-\text{sgn}(A_i)$ 用于控制旋转角方向, $\begin{bmatrix} a_{\text{best}} \\ b_{\text{best}} \end{bmatrix}$ 为当前头狼的某个量子比特对应的概率幅, $\begin{bmatrix} a_i \\ b_i \end{bmatrix}$ 为当前人工狼相对应的量子比特概率幅; θ_{best} 和 θ_i 分别为当前头狼和当前人工狼的某个量子比特在单位圆上的角度, K_{max} 为最大迭代次数, $\Delta\theta$ 为基本旋转角,调整范围为 $0 \sim \pi/2$,随着迭代次数 k 的增加而减小, $\Delta\theta_i$ 根据 $|\theta_{\text{best}} - \theta_i|$ 角度差变化而动态调整; λ 为 $\Delta\theta_i$ 动态调整的非线性调制指数, λ 取值范围为 $1.0 \sim 2.0$,以保证 $|\theta_{\text{best}} - \theta_i|$ 值越大调整幅度越大.采用动态自适应旋转角的量子旋转门对较优人工狼进行繁殖,保证了种群的多样性,在迭代初期进行缓慢的搜索,较大范围的搜索,而在后期进行快速地收敛,提高算法鲁棒性.

2.2 自适应迁移学习

预训练的双模态CNN模型是通过softmax分类器对全连接特征分类,并使用反向传播来训练所有网络参数,容易陷入局部最小值、过拟合等问题^[20-21].ELM是一种基于单隐层前馈神经网络的监督学习算法^[20],训练过程中调整的参数少、效率高、泛化性能好,ELM的线性表达式为

$$H\beta = T \quad (4)$$

式中, H 表示隐层单元的输出矩阵, β 表示表示隐含层和输出层间的连接权值矩阵, T 表示理想输出.ELM的隐含层节点数、输出权重及偏置是随机生成的,导致算法整体的稳定性不强,因此引入核函数得到核极限学习机(Kernel Extreme Learning Machine,KELM)^[22],克服了ELM隐含层参数随机性所带来的影响,本文选择RBF核函数作为KELM的核函数,KELM的输出函数表示为

$$\begin{cases} f(x) = \begin{bmatrix} K(x, x_1) \\ \dots \\ K(x, x_N) \end{bmatrix}^T \left(\frac{I}{C} + \Omega_{\text{ELM}} \right)^{-1} T \\ K(x, x_n) = \exp(-\sigma \|x - x_n\|^2) \quad \sigma > 0 \end{cases} \quad (5)$$

式中, I 表示对角矩阵, C 表示惩罚系数, $\Omega_{\text{ELM}} = HH^T$, H^T 表示 H 的广义逆, $K(x, x_n)$ 表示RBF核函数, σ 为核参数.为提高KELM的学习能力和稳定性,KIM J等^[23]将多个自编码极限学习机串联作为KELM的特征学习网络,大大提高了泛化性能.本文在此基础上构建双隐层自编码极限学习机代替预训练模型的fc7、fc8,如图3所示,每个自编码器的两个隐层节点数都为 N_i ,且 $N_i = 2N_{i+1}$,随机生成第一、二隐层节点的输入权重向量 w_1, w_2 和偏置 b_1, b_2 ,通过输入 X, w_1 和 b_1 计算第一隐层的输出矩阵,然后通过第一隐层输出矩阵、 w_2 和 b_2 计算第二隐层输出矩阵 H_i ,而后一个自编码器将 H_i 作为输入计算 H_{i+1} ,通过式(6)计算自编码器的输出权重矩阵 β_i 的值

$$\beta_i = \begin{cases} H_i^+ X & i = 1 \\ H_i^+ H_{i-1} & i = 2, 3, \dots, L \end{cases} \quad (6)$$

多个双隐层自编码极限学习机串联后,每个隐含节点 H_i 的输入权值都是前一个输出权值的转置 β_i^T ,通过式(7)可计算每个隐含节点输出矩阵 H_i ,将双模态CNN特征经过多个自编码器的特征抽取后再由KELM映射到更高维空间进行决策.

$$H_i = \begin{cases} X \beta_i^T & i = 1 \\ H_{i-1} \beta_i^T & i = 2, 3, \dots, L \end{cases} \quad (7)$$

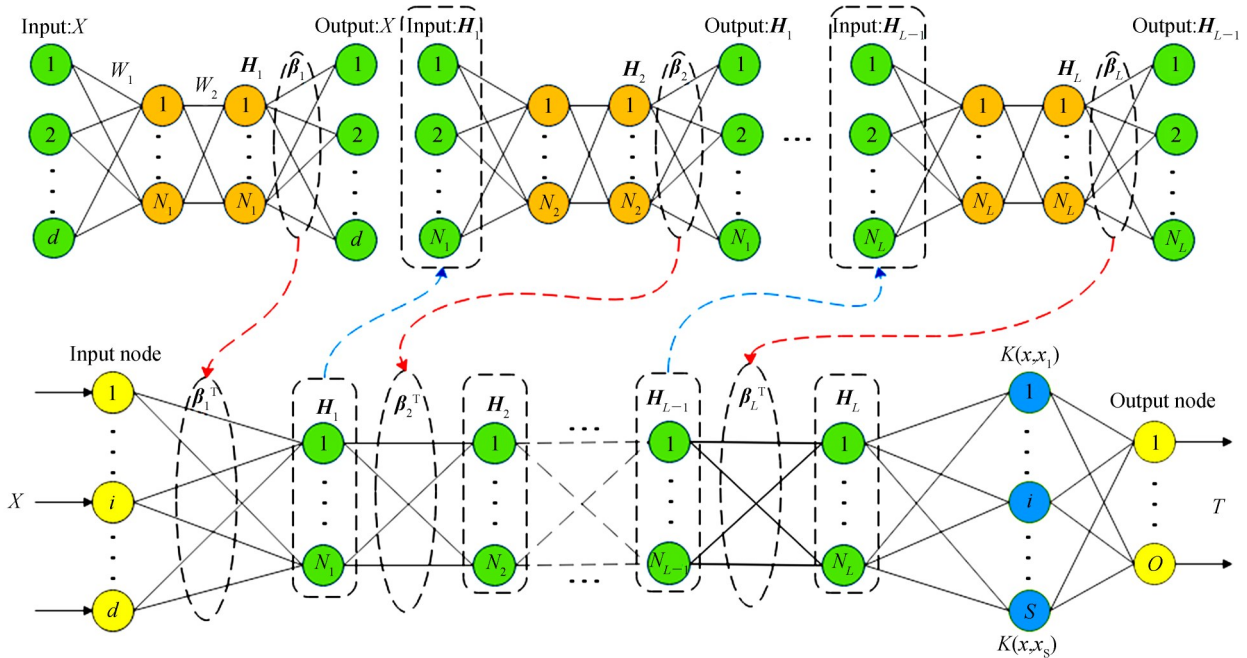


图3 双隐层自编码极限学习机

Fig. 3 Double hidden layer autoencoder extreme learning machine

将RGB-D数据集预训练的双模态CNN模型进行迁移,保留原有的卷积层、池化层、全连接层fc6、以及级联拼接输出部分,多个串联的双隐层自编码极限学习机代替预训练模型的fc7及fc8,KELM代替原有的

softmax,如图4所示,迁移后只需对双隐层自编码极限学习机和KELM进行训练学习,但同时其性能易受自编码器个数 L 、惩罚系数 C 和核参数 σ 的影响,不同的参数组合都会影响最终的拟合性能,为获取最优的分类性能,在训练过程中采用改进的量子狼群算法对这些参数进行自适应优化.

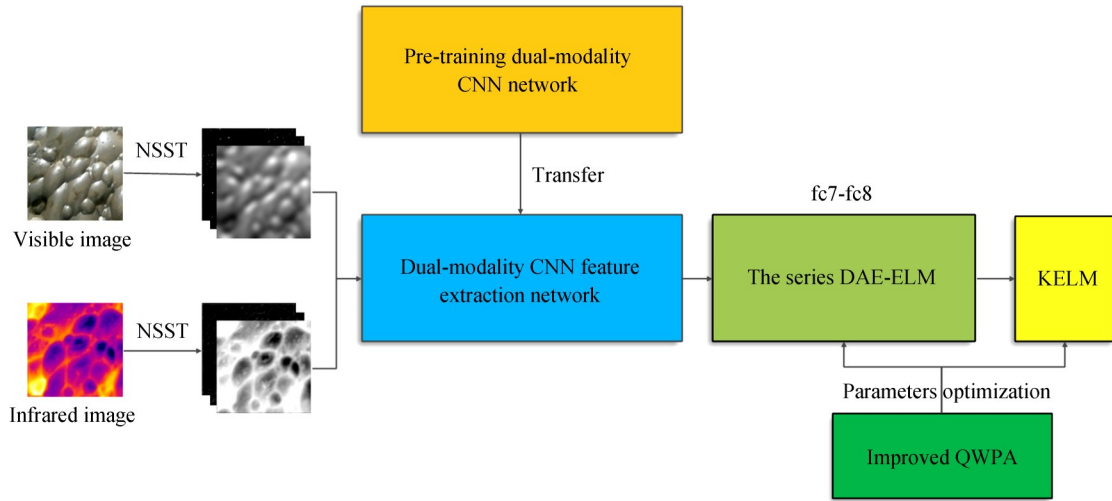


图4 自适应迁移学习模型
Fig. 4 Adaptive transfer learning model

2.3 工况识别步骤

本文提出的基于双模态CNN自适应迁移学习的工况识别步骤为

Step1:构建基于AlexNet的双模态CNN特征提取及识别模型,对RGB-D数据集的RGB图像和景深图进行NSST三尺度分解,两种模态图像分别插值处理得到 $227 \times 227 \times 3$ 图像作为模型的输入对整个模型的结构参数进行预训练.

Step2:构建双隐层自编码极限学习机,将多个双隐层自编码极限学习机串联后,前一个输出权值的转置 β_i^T 作为隐含节点 H_i 的输入权值,经过多个自编码器的特征抽取后作为KELM的特征输入.

Step3:对量子狼群算法的更新机制改进,淘汰比例因子为 γ 的一部分较差人工狼,选取相同数量的较优人工狼,以头狼作为参照对象,采用式(2)的量子旋转门及式(3)的动态自适应旋转角进行繁殖,保证种群的多样性,提高算法的寻优性能.

Step4:将预训练模型进行迁移,保留原有的卷积层、池化层、全连接fc6、以及级联拼接输出部分,多个串联的双隐层自编码极限学习机代替fc7和fc8,KELM代替原有的softmax分类算法.

Step5:建立小规模的首选泡沫双模态图像数据集,对迁移后的双隐层自编码极限学习机和KELM进行训练学习,同时将 L 、 C 和 σ 参数作为人工狼的基因,识别精度作为适应度,采用改进的量子狼群算法对模型进一步优化.

Step6:实时采集首选槽表面泡沫的可见光、红外图像,先由NSST分解并插值处理为 $227 \times 227 \times 3$ 图像,再通过双模态CNN自适应迁移学习模型进行工况识别.

3 实验结果与分析

为验证本文方法的有效性,以福建金东矿业股份有限公司的梅仙铅锌矿浮选厂作为实验对象,实验的硬件平台为Intel(R) Core(TM) i7-9700 CPU@3.00GHz、NVIDIA RTX2070 GPU、16GB(RAM),软件运行环境为Windows 10 Matlab 2016a、python 3.7、tensorflow 1.14.LAI K等公布的RGB-D数据集^[14]作为预训练样本,采用菲力尔T620红外热像仪采集不同时间段泡沫双模态图像,根据化验室提供相应时间段的工况等级构建浮选小规模数据集,对提出方法进行验证,给出了各实验步骤的结果及比较分析.

3.1 改进的量子狼群算法性能测试

为确定所提出的动态自适应旋转角函数中 λ 和 $\Delta\theta$ 参数的最佳值,利用表1中的5个经典基准函数进行

测试分析.

表1 基准函数信息
Table 1 Benchmark functions information

Function	Function formula	Parameter range	Optimum value
Rosenbrock	$f_1(x) = \sum_{i=1}^{N-1} [100(x_{i+1} - x_i^2) + (x_i - 1)^2]$	$[-10, 10]$	0
Rastrigrin	$f_2(x) = \sum_{i=1}^N [x_i^2 - 10\cos(2\pi x_i^2) + 10]$	$[-100, 100]$	0
Schewefel	$f_3(x) = 418.9829N + [-x_i \sin(\sqrt{x_i})]$	$[-500, 500]$	0
Shubert	$f_4(x) = 0.5 - \frac{\sin^2 \sqrt{x_1^2 + x_2^2} - 0.5}{[1 + 0.001(x_1^2 + x_2^2)]^2}$	$[-100, 100]$	1
Schaffer	$f_5(x) = \left\{ \sum_{i=1}^5 i \cos[(i+1)x + i] \right\} \left\{ \sum_{i=1}^5 i \cos[(i+1)y + i] \right\}$	$[-100, 100]$	-186.730 9

实验中狼群规模 $M=500$, 每个基因的编码长度取 $h=20$, 距离判定因子 $\omega=500$, 步长因子 $S=1\ 000$, 更新因子 $\gamma=6$, 探狼比例因子 $\delta=4$, 最大游走次数 $T_{\max}=20$, 最大迭代次数 $K_{\max}=500$. 对各个基准函数调整 λ 和 $\Delta\theta$ 参数的值进行实验, 每组数据进行 100 次重复实验, 统计达到最优值的概率, 以及达到最优值的平均迭代次数, 如表 2 所示, 当 λ 取 1.6、 $\Delta\theta$ 取 0.3π 时, 算法具有最强的全局寻优能力, 而且收敛速度较快.

表2 平均最优值概率(%)和迭代次数
Table 2 The average optimal value probability (%) and the number of iterations

$\Delta\theta$ λ	0.1 π	0.2 π	0.3 π	0.4 π	0.5 π
1.1	97.89/205.1	98.56/210.2	99.09/196.5	98.79/213.6	97.37/212.4
1.2	97.88/208.8	98.84/204.4	99.20/204.7	99.16/204.6	98.31/198.5
1.3	98.14/199.4	98.78/199.4	99.15/202.6	99.35/198.4	97.81/201.6
1.4	98.56/197.6	98.95/196.4	99.64/198.7	99.64/202.7	98.33/208.1
1.5	98.85/204.5	99.35/196.6	99.70/192.9	99.81/205.3	99.11/205.3
1.6	99.36/209.4	99.12/201.3	99.95/190.2	99.85/203.8	98.76/197.4
1.7	99.87/201.8	99.76/195.2	99.92/191.8	99.65/206.2	99.23/196.6
1.8	99.78/194.3	99.23/198.8	99.63/194.3	99.54/199.5	99.15/196.1
1.9	99.46/199.2	98.84/208.3	99.24/201.8	99.21/198.1	98.86/195.8
2.0	98.95/206.4	98.97/207.1	99.26/202.7	98.89/201.3	98.15/202.3

为了进一步验证改进的量子狼群算法的优势, 选取一个复杂二元非线性函数进行实验并与 QGA、QHS、QBFA、QWPA 等寻优算法比较, 二元非线性函数如式(8)所示.

$$\begin{cases} \max f(x, y) = x \sin(4\pi x) + y \sin(20\pi y) \\ -3.0 \leq x \leq 12.1, 4.1 \leq y \leq 5.8 \end{cases} \quad (8)$$

各算法的最大迭代次数都设置为 500, 本文方法的 λ 取 1.6、 $\Delta\theta$ 取 0.3π , 实验结果如图 5 所示, QWPA 的收敛精度和寻优能力高于 QBFA, 而改进后的 IQWPA 相比于 QWPA 的寻优能力和收敛速度提高了很多, 虽然 IQWPA 的收敛效果不如 QGA 和 QHS, 但是寻优能力和稳定性强很多. 说明改进后的 IQWPA 不仅可以较好地逼近全局最




图5 各优化算法运行效果
Fig. 5 The operation effect of each optimization algorithm

优解,收敛速度也有所提升,具有更高的鲁棒性.

3.2 双隐层自编码极限学习机性能测试

为验证双隐层自编码极限学习机的性能,选择不同大小、维度、分类数的三种经典数据集 Spambase、Shuttle、USPS 进行测试,并与单隐层自编码极限学习机进行比较分析.通过多个串联的自编码极限学习机对特征进行学习,然后作为 KELM 的输入进行分类,通过分类精度、以及 C 和 σ 对分类结果的影响进行比较分析.设置自编码极限学习机的层数 $L=3$,在 $0.01 \leq C \leq 1000$ 、 $0.01 \leq \sigma \leq 100$ 的范围调整参数进行测试,两种算法的平均测试准确率如图 6(a)、(b) 所示:AE-KELM 的平均准确率为 88.48%、标准差为 4.88%,DAE-KELM 的平均准确率为 91.11%、标准差为 2.64%,本文的 DAE-KELM 通过多个双隐层自编码极限学习机的特征逐层抽象提取,然后映射到更高维空间进行决策,相比于采用单隐层自编码极限学习机的 AE-KELM,具有更强的特征抽取能力,整体分类精度较高,而且标准差大大缩小,分类精度受 C 和 σ 的影响而产生的波动小,降低了对 C 和 σ 参数的敏感性,稳定性好.为进一步分析参数 L 的影响,采用改进的量子狼群算法自适应选取最优的 C 和 σ 参数,设置不同的网络深度 L 进行实验,结果如图 6(c) 所示,三种数据集下,随着 L 的增加测试精度有所提高,当 L 在 3~6 之间时具有较高的分类精度,后续随着 L 的增加,网络结构变得越复杂,导致测试精度下降.

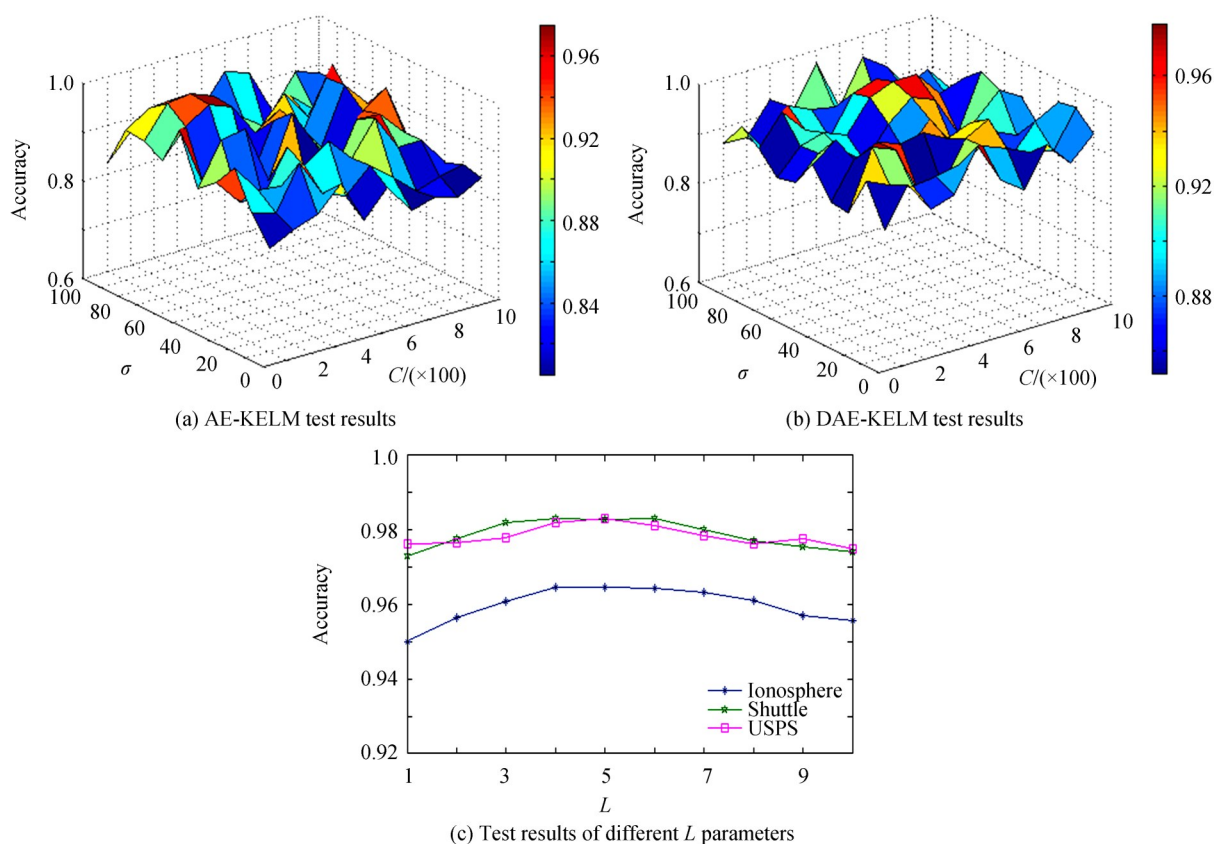


图6 双隐层自编码极限学习机性能测试

Fig. 6 Performance test of double hidden layer autoencoder extreme learning machine

为进一步分析比较双隐层自编码极限学习机的优势,采用改进的量子狼群算法自适应选取最优的 L 、 C 和 σ 参数进行实验,三种数据集的测试结果如表 3 所示,本文的 DAE-KELM 需要消耗较多的训练时间,但是在测试精度上比其他算法具有明显的优势,对不同种类的数据集都具有较好的分类和泛化性能.说明双隐层自编码极限学习机具有更强的特征抽取能力,有利于提高分类精度.

表3 各种KELM算法数据集测试结果
Table 3 Test results of data sets for various KELM algorithm

Data set	Lonosphere		Shuttle		USPS	
Test item	Accuracy/%	Times/s	Accuracy/%	Times/s	Accuracy/%	Times/s
KELM	90.12	1.253	91.31	26.930	91.75	162.961
AE-KELM	94.23	2.014	95.52	38.237	95.81	720.834
DAE-KELM	96.45	4.587	98.31	45.417	98.35	1 646.250

3.3 自适应迁移学习及工况识别效果

先采用LAIK等公布的RGB-D数据集^[14]对双模态CNN特征提取及识别模型预训练,然后将卷积层、池化层、全连接层fc6,以及级联拼接输出部分迁移到新的模型中,用L个串联的双隐层自编码极限学习机代替预训练模型的fc7及fc8,KELM代替原有的softmax.采用菲力尔T620红外热像仪采集6种工况下各5 000组泡沫双模态图像,4 000×6组作为训练集,1 000×6组作为测试集,对迁移后模型的双隐层自编码极限学习机和KELM进行训练学习,为获取最优的分类性能,在训练过程中采用改进的量子狼群算法对L、C和σ进行优化,3个参数的范围:1≤L≤10、0.01≤C≤1 000、0.01≤σ≤100,将3个参数作为人工狼的基因,平均识别精度作为适应度,实验中狼群规模M=500,基因长度h=20,距离因子ω=500,步长因子S=1 000,更新因子γ=6,探狼比例因子δ=4,最大游走次数T_{max}=20,最大迭代次数K_{max}=500,非线性指数λ=1.6、基本旋转角Δθ=0.3π.

为验证自适应迁移学习对小样本数据集的有效性,将训练集每次以递增200×6组样本的方式进行实验,测试样本数量保持不变,测试结果如图7所示:未采用迁移学习而直接对模型训练的整体识别精度较低,而且随着样本数量的增加,识别精度提升较为缓慢;自适应迁移学习能够明显提高小样本数据集下的识别准确度,随着样本数量的增加,识别精度快速提升,当样本数量超过2 800×6组以后就保持较高的识别精度;相同训练样本数量下,双模CNN自适应迁移学习模型较单模CNN自适应迁移学习模型具有更高的识别精度,采用双模态图像CNN特征有助于提高小样本数据集的分类准确度;当样本数量超过3 800×6组以后本文方法的识别精度提升缓慢,而当样本数量超过4 800×6组以后识别精度几乎稳定不变,因此本文双模CNN自适应迁移学习模型有效的小样本数量范围为3 800×6~4 800×6组.

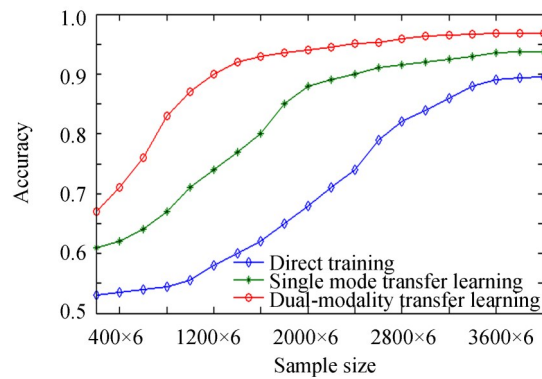


图7 不同训练样本测试结果
Fig. 7 Test results of different training samples

为验证本文方法的工况识别效果,采用4 000×6组训练样本、1 000×6组测试样本对模型进行测试,训练过程中改进的量子狼群算法获取的最优参数为:L=5,C_{best}=872.508 3和σ_{best}=53.694 1,并采用相同数据集对预训练模型、未采用迁移学习而直接训练的模型、可见光图像单模CNN自适应迁移学习的模型进行测试,识别结果如图8所示,对角线上6个格子代表6种工况的正确识别数量,其余格子代表对应X轴上的实际工况被误识别为对应Y轴上工况的数量,实验结果表明:异常工况下的可见光、红外图像信息变化较大,四种方式下该工况的识别精度都较高;因RGB-D图像与泡沫双模态图像存在一定的差异,图8(a)所示的直接采用预训练模型进行工况识别的精度较低;如果不迁移双模态CNN网络参数,直接采用创建的训练集对模

型全新训练学习,如图8(b)所示,在训练集样本数量有限情况下无法达到较高的识别精度;图8(c)、(d)所示的自适应迁移学习模型都具有较高的识别精度,相比于可见光图像单模CNN特征提取方式,对泡沫双模态图像CNN特征提取及融合后,可有效扩大相邻工况图像特征的差异程度,相邻工况间的误识别率大大降低,各工况的识别效果都得到较大改善,平均识别精度提高了3.06%。

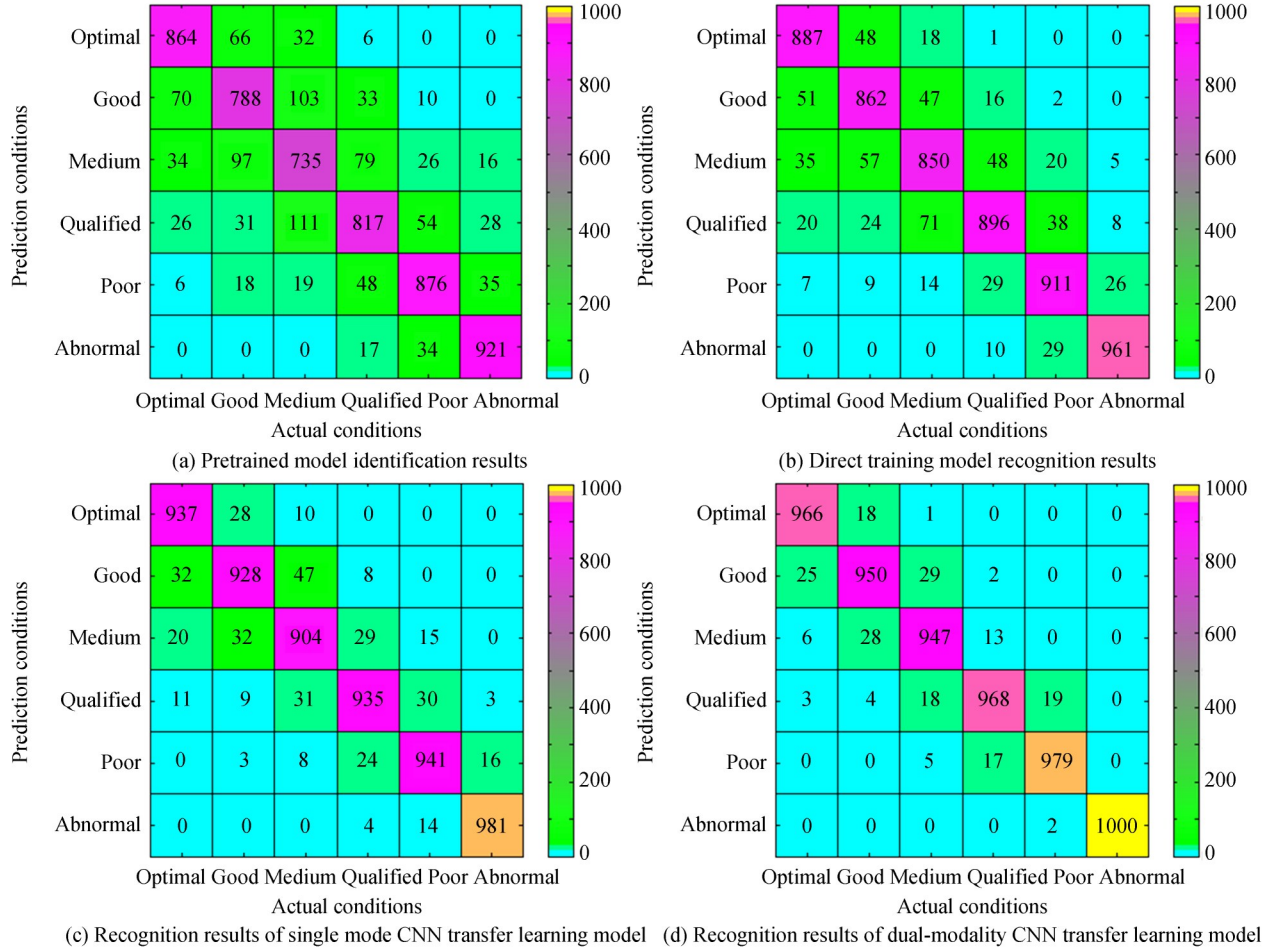


图8 工况识别结果比较

Fig. 8 Comparison of performance recognition results

为进一步验证本文方法的优势,采用相同的数据集对现有文献方法进行试验,统计各方法的平均识别精度和标准差,实验结果如表4所示.文献[6]将预训练的AlexNet用于泡沫图像的特征提取,采用随机森林算法代替softmax对泡沫图像分类,准确度较传统方法有一定提高,但标准差较大,稳定性差;文献[7]对气泡分割图像进行CNN特征和形态特征提取,通过统计各类气泡出现的概率分布进行工况识别,各工况的识别精度较为稳定,但整体识别精度有待提高;文献[8]构建只含两个卷积层的简易CNN网络提取泡沫图像特征,通过训练的SVM进行浮选生产故障判别,具有较高的故障识别率,但是工况识别比故障检测复杂,小样本数据集下无法取得较高的工况识别精度;文献[9]对预训练的AlexNet网络模型进行迁移,对全连接层参数和随机森林重新学习训练,大大提高了识别精度,也缩小了标准差;本文方法将预训练的双模态AlexNet特征提取网络进行迁移,对迁移后的串联双隐层自编码极限学习机和KELM重新训练学习,并采用改进的量子狼群算法对模型参数进一步优化,融合泡沫可见光、红外图像的CNN特征进行工况识别,小样本数据集下各工况的识别精度都有较大的提高,平均识别率达96.83%,识别精度和稳定性较现有方法有较大提升。

表4 不同方法的识别效果
Table 4 Recognition effect of different methods

Algorithm	Feature extraction method	Classification algorithm	Accuracy/%	Standard deviation/%
Ref. [6]	Alexnet	Random forest	85.93	4.24
Ref. [7]	CNN feature statistics	PW mean-shift	91.25	1.82
Ref. [8]	Two layers CNN	SVM	89.06	2.95
Ref. [9]	Alexnet transfer learning	Random forest	93.02	2.68
Proposed	Dual-modality alexnet transfer learning	Adaptive DAE-KELM	96.83	1.96

4 结论

为提高小样本训练集下CNN特征驱动的浮选工况识别效果,提出一种基于双模态CNN特征提取及自适应迁移学习的工况识别方法.本文提出一种动态自适应旋转角的量子旋转门方法以改进量子狼群算法的更新机制,改进后的量子狼群算法寻优能力更强、收敛效率高;构建的双隐层自编码极限学习机与单隐层自编码极限学习机相比,特征抽取能力更强,有利于提高分类精度,而且降低了惩罚系数 C 和核参数 σ 的敏感性;在AlexNet基础上构建双模态CNN特征提取网络,在相同训练样本数量下,较单模态CNN特征识别模型具有更高的识别精度;双模态CNN自适应迁移学习能够明显提高小样本数据集下的分类精度,在 $4\,000 \times 6$ 组样本的小规模训练集条件下,较单模态CNN迁移学习的识别精度提高了3.06%,各工况的平均识别准确率达到96.83%,识别精度和稳定性较现有方法有较大提升.

参考文献

- [1] ZHANG J, TANG Z H, AI M X, *et al.* Nonlinear modeling of the relationship between reagent dosage and flotation froth surface image by Hammerstein-Wiener model[J]. *Minerals Engineering*, 2018, **120**(5):19-28.
- [2] NAKHAEI F, IRANNAJAD M, MOHAMMADNEJAD S. Column flotation performance prediction: PCA, ANN and image analysis-based approaches[J]. *Physicochemical Problems of Mineral Processing*, 2019, **55**(5):1298-1310.
- [3] JAHEDSARAVANI A, MARHABAN M H, MASSINAEI M. Prediction of the metallurgical performances of a batch flotation system by image analysis and neural networks[J]. *Minerals Engineering*, 2014, **69**(8):137-145.
- [4] WANG Y L, SUN B, ZHANG R Q, *et al.* Sulfur flotation performance recognition based on hierarchical classification of local dynamic and static froth features[J]. *IEEE Access*, 2018, **6**(3): 14019-14029.
- [5] WU Jun-an, GUO Rui, LIU Rong-zhong, *et al.* Convolutional neural network target recognition for missileborne linear array LiDAR[J]. *Acta Photonica Sinica*, 2019, **48**(7): 0701002.
武军安,郭锐,刘荣忠,等.用于弹载线阵激光雷达的卷积神经网络目标识别[J].光子学报,2019, **48**(7):0701002.
- [6] FU Y, ALDRICH C. Froth image analysis by use of transfer learning and convolutional neural networks[J]. *Minerals Engineering*, 2018, **115**:68-78.
- [7] WANG X L, CHEN S, YANG C H, *et al.* Process working condition recognition based on the fusion of morphological and pixel set features of froth for froth flotation[J]. *Minerals Engineering*, 2018, **128**:17-26.
- [8] LI Z M, GUI W H, ZHU J Y. Fault detection in flotation processes based on deep learning and support vector machine[J]. *Journal of Central South University*, 2019, **26**(9): 2504-2515.
- [9] FU Y, ALDRICH C. Flotation froth image recognition with convolutional neural networks[J]. *Minerals Engineering*, 2019, **132**:183-190.
- [10] HAN D M, LIU Q G, FAN W G. A new image classification method using CNN transfer learning and web data augmentation[J]. *Expert Systems with Applications*, 2018, **95**: 43-56.
- [11] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Imagenet classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2012, **25**(2): 1097-1105.
- [12] LIAO Yi-peng, WANG Wei-xing. Flotation bubble delineation based on shearlet multiscale boundary detection and fusion[J]. *Acta Optica Sinica*, 2018, **38**(3):0315004.
廖一鹏,王卫星.基于Shearlet多尺度边界检测及融合的浮选气泡提取[J].光学学报,2018, **38**(3):0315004.
- [13] ZHANG Xue-song, ZHUANG Yan, YAN Fei, *et al.* Status and development of transfer learning based category-level object recognition and detection[J]. *Acta Automatica Sinica*, 2019, **45**(7): 1224-1243.
张雪松,庄严,闫飞,等.基于迁移学习的类别级物体识别与检测研究与进展[J].自动化学报,2019, **45**(7): 1224-1243.
- [14] LAI K, BO L, REN X, *et al.* A large-scale hierarchical multiview RGB-D object dataset[C]. 2011 IEEE International

- Conference on Robotics and Automation, China, Shanghai:IEEE, 2011: 1817-1824.
- [15] WU Hu-sheng, ZHANG Feng-ming, WU Lu-shan. New swarm intelligence algorithm—wolf pack algorithm[J]. *Systems Engineering and Electronics*, 2013, **35**(11):2430-2438.
吴虎胜, 张凤鸣, 吴庐山. 一种新的群体智能算法—狼群算法[J]. *系统工程与电子技术*, 2013, **35**(11): 2430-2438.
- [16] TKACHUK V. Quantum genetic algorithm based on qutrits and its application [J]. *Mathematical Problems in Engineering*, 2018, **4**:8614073.
- [17] LAYEB A. A hybrid quantum inspired harmony search algorithm for 0-1 optimization problems [J]. *Journal of Computational and Applied Mathematics*, 2013, **253**:14-25.
- [18] LIU L, SHAN L, DAI Y W, *et al.* A modified quantum bacterial foraging algorithm for parameters identification of fractional-order system [J]. *IEEE Access*, 2018, **6**(11): 6610-6619.
- [19] GAO Y J, ZHANG F M, ZHAO Y, *et al.* A novel quantum-inspired binary wolf pack algorithm for difficult knapsack problem[J]. *International Journal of Wireless and Mobile Computing*, 2019, **16**(3):222-232.
- [20] SUN Wei, DU Hong-ji, ZHANG Xiao-rui, *et al.* Traffic sign recognition method based on multi-layer feature CNN and extreme learning machine [J]. *Journal of University of Electronic Science and Technology of China*, 2018, **47**(3): 343-349.
孙伟, 杜宏吉, 张小瑞, 等. 基于CNN多层特征和ELM的交通标志识别[J]. *电子科技大学学报*, 2018, **47**(3): 343-349.
- [21] YIN Yun-hua, Li Hui-fang. RGB-D object recognition based on hybrid convolutional auto-encoder extreme learning machine[J]. *Infrared and Laser Engineering*, 2018, **47**(2):61-68.
殷云华, 李会方. 基于混合卷积自编码极限学习机的RGB-D物体识别[J]. *红外与激光工程*, 2018, **47**(2):61-68.
- [22] CHENG Y S, ZHAO D W, WANG Y B, *et al.* Multi-label learning with kernel extreme learning machine autoencoder [J]. *Knowledge-Based Systems*, 2019, **178**:1-10.
- [23] KIM J, LEE B. Identification of Alzheimer's disease and mild cognitive impairment using multimodal sparse hierarchical extreme learning machine[J]. *Hum Brain Mapp*, 2018:1-14.