

# 数据驱动的浮选过程建模、控制与优化研究进展

王康<sup>1</sup>, 徐航<sup>1</sup>, 李晓理<sup>1,2,3</sup>, 樊尊冠<sup>1</sup>, 赵鑫<sup>4</sup>

(1. 北京工业大学信息学部, 北京 100124; 2. 计算智能与智能系统北京市重点实验室, 北京 100124;  
3. 数字社区教育部工程研究中心, 北京 100124; 4. 中铁十九局集团矿业投资有限公司, 北京 100161)

**摘要:** 矿物浮选是存在动态性和不确定性的复杂过程, 精矿品位、金属回收率等关键指标的精确软测量和优化控制是浮选过程急需解决的难题。随着技术的进步, 针对矿物浮选过程中建模、控制及优化研究取得了重要进展, 特别是数据驱动的智能方法。该文梳理了基于数据的浮选过程建模、控制和优化方面的研究进展。首先, 介绍矿物浮选过程并描述相关控制问题; 其次, 分别概述基于运行数据和泡沫图像的浮选工况识别与指标预测方法; 之后, 从基于模型控制和无模型控制角度综述浮选过程的智能控制策略; 然后, 讨论浮选过程中针对单目标和多目标的设定值优化算法; 最后, 展望浮选过程智能控制的未来研究方向。

**关键词:** 浮选过程; 数据驱动; 工况识别; 智能控制; 软测量; 优化控制

中图分类号: TP 13; TP 29

文献标志码: A

文章编号: 0254-0037(2023)04-0485-22

doi: 10.11936/bjtxb2022090002

## Research Progress on Data-driven Modeling, Control and Optimization of Flotation Process

WANG Kang<sup>1</sup>, XU Hang<sup>1</sup>, LI Xiaoli<sup>1,2,3</sup>, FAN Zunguan<sup>1</sup>, ZHAO Xin<sup>4</sup>

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China;

2. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China;

3. Engineering Research Center of Digital Community, Ministry of Education, Beijing 100124, China;

4. China Railway 19th Bureau Group Mining Investment Co., Beijing 100161, China)

**Abstract:** The mineral flotation process is a complex process with dynamics and uncertainties, which confronts with the problems of accurate soft measurement and optimal control of key indices such as concentration grade and flotation recovery. With the advancement of relevant technologies, important progresses have been made in modeling, control and optimization of mineral flotation process, especially in the data-driven intelligent methods. The research progress of data-based flotation process modeling, control and optimization methods were summarized. First, the descriptions of the flotation progress and corresponding control problem were given in detail. Second, based on operating data and froth images, working condition recognition and index prediction methods were summarized, respectively. Afterwards, intelligent control strategies were introduced from the perspectives of model-based and model-free methods. Then, set-point optimization algorithms with single-objective and multi-objective were reviewed. Finally, future tendencies in the intelligent control of the flotation process were discussed.

收稿日期: 2022-08-31; 修回日期: 2022-10-21

基金项目: 国家自然科学基金资助项目(61873006); 北京市自然科学基金资助项目(4212040, 4204087)

作者简介: 王康(1989—), 男, 讲师, 主要从事复杂系统建模控制与优化、人工智能理论与应用方面的研究, E-mail: wangkang@bjut.edu.cn

**Key words:** flotation process; data-driven; working condition recognition; intelligent control; soft measurement; optimal control

在新一代产业变革中,电子信息、新能源汽车、节能环保等领域的发展推动了选矿行业的持续增长.随着我国经济和城市化进程的快速发展,以及“一带一路”的快速推进,工业生产中对于铜、铁、锡等金属的产量和质量需求越来越高.以铜为例,2002年我国铜资源消费量首次超过美国,跃居世界首位,2020年我国精炼铜消费总量1 208万t,占世界精炼铜消费总量的53.6%<sup>[1-2]</sup>.但是,我国选矿行业现状却不容乐观.首先,我国主要矿产资源与国外相比杂质含量高、开采难度大.其次,选矿设备、工艺相对落后,制约了矿产的开发利用.上述原因导致矿物消耗量大,利用率低,不仅造成严重的经济损失,还对环境产生一定负担.因此,提高精矿品位并提高矿产资源利用率是亟待解决的难题.

浮选法利用不同矿物颗粒亲疏水性的差异来分选矿物,是最重要的选矿方法之一.然而,浮选过程复杂多变,受到多个因素影响,是一个非线性、多耦合、滞后性的复杂工业过程,难以通过机理研究确定具体的模型进行选矿生产流程控制.一直以来,工业现场对于浮选过程中浮选泡沫的大小、颜色、刮泡声音、尾矿颜色等特征的检测手段比较落后,实际操作中主要依赖技术工人凭借经验估计调整药剂添加量.受限于技术工人的经验和主观判断,无法客观评价浮选状态,造成矿物原料和浮选药剂的严重浪费.与此同时,原矿属性的不稳定导致工况变化、指标波动,传统控制方案难以实现浮选效果的精确控制.为了满足矿物浮选指标、提高生产效率、节约资源与生产成本,实现浮选流程的自动化和智能化具有重要的意义.对浮选过程进行建模、控制和优化,是实现浮选过程智能控制的重要方面.对于目前已有的大量建模、控制及优化方法,本文将按不同的标准进行分类整理.

近年来,随着图像传感器及机器学习技术的发展,通过浮选过程图像信息进行浮选工况的智能识别、关键过程指标的预测和软测量以及结合深度学习和人工智能技术的数据驱动智能控制和优化成为可能.结合运行过程数据,国内外专家学者对浮选过程的智能建模、控制和优化方法进行了大量研究<sup>[3-8]</sup>,并取得一系列重要进展.本文首先

概述矿物浮选过程及相关难点.其次,围绕浮选过程的数据建模问题,分别描述图像分类、工况识别与关键过程变量软测量方法.然后,从实际应用需求出发,分别阐述浮选过程基于模型和无模型的智能控制策略;针对控制成本问题,分别概述单目标和多目标的设定值优化算法.最后,对浮选过程的建模、优化与控制问题未来的研究方向进行展望.

## 1 矿物浮选过程及控制问题描述

### 1.1 矿物浮选过程描述

选矿过程主要流程包括:破碎、球磨、浮选和尾矿重选,如图1所示.首先,矿石经破碎机粗碎,得到的产品经过圆锥破碎机后进入振动筛,筛上产品重新送入圆锥破碎机进行粉碎,筛下产品为合格品,送入细料仓备用.以上工序采用两级闭路破碎工艺,是选矿过程的第一部分.经破碎工序后,细料仓中的产品经给料机和传送带送入一级球磨机,球磨后送入分级机.分级机的溢流将被泵入水力旋流器,砂返回球磨机,构成闭路磨矿作业.旋流机的溢流进入浮选作业流程,底流进入溢流球磨机,产生的矿浆进入水力旋流器重新分级.以上工序构成两级闭路磨矿工艺.经球磨后,水力旋流机细度合格的矿浆溢流至混浆槽,同时自动给药机加入浮选药剂进行混合搅拌,自流至浮选作业工序.该工序首先对产品进行多次粗选以富集产物得到精矿,将不符标准的低品位矿进行多次扫选,再将扫选后的产物经多次精选进行富集,富集后得到精矿,其他无法分离的劣质产品即为尾矿,尾矿将通过摇床或溜槽等设备分离有用矿物和伴生的矿粒,此工序即为尾矿重选.

浮选是矿物选别过程中最重要的部分,根据矿浆颗粒表面的物理化学性质不同导致的亲疏水性差异来进行筛选.将球磨机磨成的合格矿物颗粒经过传送带送入浮选槽中,并添加水和各种浮选药剂,形成符合浮选要求的矿浆.在搅拌的作用下,同时在浮选槽底部鼓入空气,具有疏水性的有用颗粒与上升的气泡充分接触并附着在气泡表面,形成大量的浆状泡沫漂浮在浮选槽表面.浮选




图1 选矿工艺流程

Fig. 1 Mineral beneficiation process

槽顶部的泡沫刮至溜槽形成精矿,亲水性的无用颗粒沉在浮选槽底部,随着矿浆排出形成尾矿。

### 1.2 浮选过程相关问题描述及难点分析

在浮选过程中,精矿品位和矿物回收率是最重要的2个评价指标,精矿品位反映目标矿物在精矿中的贫富程度,品位越高说明精矿质量越好。矿物回收率反映矿物资源的综合利用程度,回收率越高,矿物利用越彻底。在浮选过程的控制量中,矿浆流量波动需在工艺规定的范围内,即浮选液位要稳定。如果矿浆流量波动范围较大,会影响浮选过程选别时间并导致液位波动,降低精矿品位和矿物回收率。药剂添加量也是一个重要的控制量,能够改变矿物表面的亲水性、疏水性,正确调整药剂添加量可以提高矿物的可浮性,以获得最佳效益。此外,准确预测产品成本,通过产品成本的变化趋势合理地选矿生产过程成本控制也具有重要意义。对于上述指标的准确预测有助于浮选过程的自动控制,但由于控制量的复杂交互和相互依赖,建立一个能够准确预测浮选指标的模型是很大的难点。

泡沫浮选是选矿工业中广泛应用的分离方法之一,但是经过多年研究,针对其过程的控制方法仍然相对低效。浮选控制的重点是维持主要控制量(通常是指矿浆液位、空气流量、药剂添加量)在一个指定区间,目前广泛应用的控制方法仍然是传统的单输入单输出(single input single output, SISO)控制器,例如比例积分微分(proportional-

integral-differential, PID)控制器,通过分别应用于多个浮选槽实现类似多变量控制的效果。由于生产水平的提升,传统控制方法的性能逐渐不能满足要求。不仅需要控制多个变量,还要最大程度地抵抗干扰对系统的影响,同时还需获得良好的控制性能,因此开发新的控制方法也是浮选过程中需要解决的问题。

浮选过程的控制优化目标是在满足多个等式约束和不等式约束的情况下实现指定性能指标最优。约束条件表达式为

$$\begin{cases} h_i(t, x) = 0 \\ g_j(t, x) \geq 0 \end{cases} \quad (1)$$

式中: $h_i$ 为空气流量、药剂添加量等常值量; $g_i$ 为浮选槽液位等在特定范围内变化的物理量; $x$ 为操作变量; $t$ 为时间变量; $i = 1, 2, \dots; j = 1, 2, \dots$ 。

控制的性能指标应在预期范围内达到最优,常见的性能指标包括精矿品位、尾矿品位、矿物回收率等,其表达式为

$$\min F_a(t, x) \quad a = 1, 2, \dots \quad (2)$$

式中  $a$  为性能指标数量。

在控制性能达到要求的同时,还需要考虑其他运行指标,例如经济效益、设备损耗等,表达式为

$$\min G_b(t, x) \quad b = 1, 2, \dots \quad (3)$$

式中  $b$  为运行指标数量。

综上所述,浮选系统控制优化的数学描述为



$$\begin{aligned} \min J(t, x) &= J(F_a(t, x), G_b(t, x)) \\ a &= 1, 2, \dots; b = 1, 2, \dots \\ \text{s. t. } \begin{cases} h_i(t, x) = 0 \\ g_j(t, x) \geq 0 \end{cases} & \quad (4) \\ i &= 1, 2, \dots; j = 1, 2, \dots \end{aligned}$$

问题的求解目标是获得使式(4)中约束条件和指标成立的最优操作变量  $x$ 。问题的求解过程本质上是通过建立操作变量与性能指标的联系(可以是近似动态模型,也可以是通过网络建立的黑箱模型),设计算法寻找最优设定值,并利用该设定值设计控制算法实现预期的性能指标。

由于浮选过程的复杂非线性特性,实际操作中面临如下多种问题。

1) 矿物浮选流程复杂、变量耦合性强且变量之间存在采样时刻和采样频率差异,基于数据的性能指标模型和运行过程动态模型精度有待提高。

2) 浮选过程往往存在输入参数变动和运行工况变化,对控制器的鲁棒性和控制精度提出了更高要求;同时,基于泡沫图像和泡沫视频的控制器的设计增强了与深度学习等技术相结合的必要性。

3) 浮选往往需要针对多个冲突的目标进行优化,而多个优化目标的权重难以简单衡量,如何处理这些冲突,获得满意的优化效果,是浮选过程优化中一个重要的问题。

## 2 基于数据的浮选过程指标模型

矿物浮选过程指标模型是表征过程运行指标和操作变量的数学描述,目的是更好地为浮选过程优化控制提供指导。因此,浮选过程建模受到国内外学者的广泛关注。其中,机理建模和数据建模是2种主要的建模方式。然而,浮选是一个非线性、多耦合、滞后和复杂的工业过程,难以通过机理建模进行精确描述<sup>[9]</sup>。考虑到生产中收集的工业数据包含大量的系统运行信息,基于数据驱动的浮选过程建模方法被广泛使用。从应用角度划分,现代数据驱动浮选过程建模主要分为两大类:利用浮选模型对泡沫图像进行分类并对运行工况进行识别;基于浮选模型对相关过程变量进行预测和软测量。

### 2.1 基于浮选泡沫的图像分类和工况识别

实际浮选过程中操作人员通过观察泡沫纹理、大小等表面特征,将浮选泡沫主观地分成几种不同的类型,并根据分类结果采取相应的操作。然而,矿

物浮选流程长、干扰因素多,各种工况下的泡沫表面特征所代表的信息很难进行系统描述。另外,人工操作的主观随意性较大,各操作人员对相同泡沫特征的理解也不尽相同,导致浮选操作无法达到最优状态<sup>[10]</sup>。随着计算机和工业摄像机在浮选过程中的广泛应用,采用机器视觉系统及数字图像处理技术进行图像分类及工况识别,可大幅提高矿物浮选的生产效益。

基于数据的浮选建模中,庞大数据集中的异常数据对建模的速度和精确度都会造成影响,异常训练数据识别和处理对于提高模型训练精度具有重要意义。针对某梯浮选过程品位检测频度低、数据量小且存在异常标记图像的问题,Cen等<sup>[11]</sup>提出一种改进的基于密度的聚类算法检测并消除训练数据集中的异常图像,进一步采用浮选泡沫胶囊网络而非卷积神经网络(convolutional neural network, CNN)建立识别模型以减少数据使用量,在少量数据的情况下有效提高了梯回收率。

支持向量机(support vector machine, SVM)是一种以非线性映射为理论基础的小样本学习方法,它以结构风险最小化为基础,较好解决了非线性、小样本、高维数等问题,具有很强的泛化能力,同时由于它是一个凸二次优化算法,能够保证得到的极值解是全局最优解,有更好的适应及推广能力<sup>[12]</sup>。针对浮选泡沫视觉特征的多样性和重要度差异以及浮选工况样本数分布不平衡等问题,任会峰等<sup>[13]</sup>提出一种基于在线泡沫视觉表观特征加权 SVM 的浮选工况识别方法。在不同色彩空间内计算泡沫颜色,采用多方向融合的空间灰度共生矩阵提取泡沫纹理特征,以视觉特征的信息增益评价该特征的重要度,再利用不同工况的样本数加权策略消除样本数不平衡的影响,采用 SVM 方法实现了泡沫图像优良、合格、不合格3种浮选工况的自动准确在线识别。由于存在特征信度差异和各向异性,各种泡沫纹理特征对分类器贡献也存在一定的差异,同时类间样本数非均匀分布等问题给浮选工况的自动识别带来困难。阳春华等<sup>[14]</sup>提出一种浮选工况的自动识别方法,首先通过基于多角度融合的空间灰度共生矩阵计算角二阶矩、熵、惯性矩、逆差矩和相关性等二阶统计量以描述泡沫纹理特征,然后引入信息熵的概念,以二阶统计量的信息增益分配各种纹理特征对分类器的信度,再通过类间样本数加权策略消除样本分布的不平衡性,最后实现一对一加权 SVM 的浮选工况识

别,有效降低小样本的错分率,提高整体识别率。

深度学习与传统模式识别方法最大的区别在于它所采用的特征是从大数据中自动学习得到,而非手工设计,良好的数据特征可以提高模式识别系统的性能。深度神经网络具有从图像数据中捕获复杂特征的能力,在图像识别方面优于传统方法。针对浮选过程在多种操作条件下运行的问题,Zarie等<sup>[15]</sup>开发了一种基于CNN的浮选过程图像分类方法,采用CNN对不同空气流速下采集的泡沫图像进行六分类,并进一步对不同运行条件(空气流量、起泡剂用量、矿浆固体含量、泡沫深度和捕收剂用量)下拍摄的泡沫图像进行四分类,实验验证了在分类精度和计算时间方面明显优于人工神经网络分类器,为基于机器视觉的控制系统奠定了基础。针对根据铂精矿品位等划分的泡沫图像,Fu等<sup>[16]</sup>使用3种预训练的神经网络结构 AlexNet、VGG16 和残差神经网络(residual network, ResNet)进行图像分类和对比分析,并从预训练、再训练、网络深度等方面给出改善分类精度和加快训练速度的方法。在锑粗选异常工况下可能出现由于泡沫层高度改变,从而导致位置固定的工业相机采集到的泡沫图像存在离焦模糊的问题。保江等<sup>[17]</sup>利用大量泡沫图像数据采用 Inception ResNet V1 深度神经网络构建特征提取器,进而提取深度视觉特征,然后基于极限梯度提升(extreme gradient boosting, XGBoost)机器学习算法筛选深度视觉特征,并将复原图像特征与深度视觉特征进行融合,从而对不同工况下的泡沫图像进行分类识别。该方法有效地降低了样本错分率,提高了锑粗选异常工况识别准确率。

泡沫外观的时间变化趋势也可以反映浮选性能的变化。前述识别方法往往集中在统计特征上,而忽略了浮选过程中动态变化的时间信息。针对这一问题,陈青等<sup>[18]</sup>结合泡沫纹理的时间和空间特征,提出了基于动态纹理的建模方法并应用于浮选工况分类。首先采用自回归滑动平均(auto regressive moving average, ARMA)模型进行动态纹理建模,通过样本学习得到模型参数  $A$ 、 $C$ 、 $Q$ 。对不同类样本模型参数  $A$ 、 $C$  计算其 Martin 距离,根据最小距离原则进行分类识别。所提出的动态纹理模型能准确地描述动态泡沫,并且有效地检测浮选泡沫状态。Tian等<sup>[19]</sup>利用气泡尺寸分布的统计特性和时间相关性进行工况识别。使用累积分布函数描述采样图像中的气泡尺寸分布构建累计分布统计(cumulative

distribution statistics, CDS),并通过双向长短时记忆网络(bidirectional long short-term memory, BiLSTM)提取泡沫视频中序列图像的气泡尺寸分布之间的时间相关性,构建累积分布时间相关性(cumulative distribution time correlation, CDTC)特征,通过联合学习网络将纹理和速度特征与构造的 CDS 和 CDTC 特征相结合,有效提高浮选运行工况识别效果。

精矿品位是反映浮选效果的重要指标<sup>[13-14,16]</sup>,与此同时,泡沫特征、入矿类型、药剂添加量的变化对于浮选效果具有重要影响,众多学者从泡沫特征<sup>[17-20]</sup>、入矿类型<sup>[21]</sup>、药剂添加量<sup>[22-23]</sup> 等方面进行工况识别。针对锑浮选泡沫图像特征信息冗余、矿源成分复杂引起工况难以识别的问题,刘美丽等<sup>[20]</sup>提出一种基于多信息融合与可拓理论的锑浮选工况识别方法。采用敏感性指数与相关性分析提取关键泡沫特征,并融合入矿条件参数,作为浮选工况的评价参数,建立锑浮选工况识别的物元可拓模型,同时运用可拓层次分析法(extension analytic hierarchy process, EAHP)确定各泡沫特征评价参数权重,计算待识别工况与预设工况类别的综合关联度,并以最大关联度为准则,实现锑浮选工况的准确识别。针对铜浮选过程中矿源变化频繁而造成的浮选工况难以识别、生产过程不稳定等问题,卢明等<sup>[21]</sup>提出一种局部颜色特征与关键工艺参数融合的铜浮选入矿类型识别方法。采用多元图像处理提取泡沫图像局部颜色特征,然后采用混合滤波、时间配准算法将其与关键工艺参数进行数据融合,将融合后的混合特征进行模糊聚类,实现入矿类型的有效识别,为在线识别浮选工况建立了基础。在浮选过程中,由于人工识别的主观性强准确性低,出现了试剂浪费和产品质量不合格等问题。Cao等<sup>[22]</sup>将最大相关最小冗余(minimum redundancy maximum relevance, MRMR)算法与改进的高斯混合模型聚类器(semi-supervised Gaussian mixture models, SSGMM)相结合,提出混合分类模型 MRMR-SSGMM 用于识别浮选过程中的药剂用量工况。MRMR 对最佳泡沫图像特征进行筛选,以提供 SSGMM 分类器。在训练和学习特征样本的过程中,将泡沫图像的标记特征和样本的信息映射到未标记特征样本,实现了泡沫图像的分类。该方法可以为浮选生产过程中药剂用量的调整提供可靠指导,实现药剂用量的准确及时控制。针对不同药剂添加量情况下的浮

选泡沫图像, Zhu等<sup>[23]</sup>利用图像处理技术提取图像纹理特征, 结合粗糙集和学习向量量化(learning vector quantization, LVQ)神经网络建立药剂添加量分类模型. 现场应用与仿真对比证明其所建立

的数学模型可以满足浮选过程的控制要求.

针对上述浮选过程泡沫的图像分类和工矿识别研究, 表1列举了不同分类算法对精矿品位、泡沫特征、入矿类型等工况的分类和识别结果.

表1 基于浮选泡沫的图像分类和工况识别算法

Table 1 Image classification and working condition recognition algorithms based on flotation froth

分类指标	文献	分类方法	分类等级	特点
精矿品位	[13-14]	加权 SVM	优良(高品位)、合格(满意品位)、异常(低品位)	通过加权策略解决了类间样本数不均的问题
	[16]	AlexNet、VGG16、ResNet	Class 1: 0.732 ~ 1; Class 2: 0.385 ~ 0.732; Class 3: 0.211 ~ 0.385; Class 4: 0 ~ 0.211	AlexNet 和 VGG16 在 95% 以上的置信水平分类表现更好, ResNet 在接近 95% 的置信水平下效果更好
泡沫特征	[17]	Inception ResNet V1、XGBoost	冒槽、轻微冒槽、正常、轻微沉槽、严重沉槽	有效降低了样本错分率, 提高了筛粗选异常工况识别准确率
	[18]	ARMA 模型	Cluster 1: 理想泡沫; Cluster 2: 稀的泡沫; Cluster 3: 黏稠泡沫	考虑了浮选过程中动态变化的时间信息
	[19]	BiLSTM	Class I > 55; Class II [54, 55]; Class III [53, 54]; Class IV < 53	结合了统计和时间相关特征
	[20]	物元可拓模型、EAHP	优、良、中、差	不需要大量样本进行学习, 将评价标准由单一确定值转变为区间值, 可以确定各参数的权重
入矿类型	[21]	模糊 C-均值聚类算法	含滑石、蛇纹石少, 铜矿易浮游; 含滑石、蛇纹石多, 铜矿易浮游; 含滑石、蛇纹石多, 铜矿难浮游; 含其他矿物较多, 铜矿难浮游	局部颜色特征与工艺参数融合
药剂添加量	[22]	MRMR-SSGMM	捕收剂与起泡剂用量之比: a类(1:3); b类(2:3); c类(0.5:3); d类(1:4); e类(1:2)	找到最佳数量的泡沫图像特征和最佳泡沫图像特征, 使分类器达到最大的分类精度
	[23]	LVQ 神经网络	药剂多(13, 16); 药剂正常[7, 13]; 药剂少(4, 7)	简单易行, 不需要对输入数据进行归一化、正交化
空气流速			A、B、C、D、E、F	
运行参数	[15]	CNN	模糊 C 均值聚类结果, A、B、C、D 四类	加快了网络的训练过程, 从图像数据中捕获更高级别的特征
图像是否异常		密度聚类算法	正常图像; 异常图像	采用基于密度的聚类算法, 对异常图像进行识别
矿浆品位	[11]	浮选胶囊网络	A(非常低); B(低); C(中等); D(高); E(非常高)	用较少的训练样本准确识别泡沫图像类别

## 2.2 基于浮选模型的关键变量预测和软测量

随着数据驱动以及计算机技术的广泛应用, 建立的浮选过程相关指标预测模型相较于人工检测方法更加准确快捷. 根据建模方法利用基于数据的浮选模型进行相关变量的预测和软测量研究可大致分

为两大类: 传统数据驱动建模方法和基于深度学习的建模方法.

### 2.2.1 传统数据驱动建模方法

#### 1) 品位和回收率

为了模拟实际浮选生产中操作员通过观察泡沫



特征进行药剂添加量调整的过程,Zhang等<sup>[24]</sup>将精矿品位的控制转化为泡沫特征的控制,提出一种用于过程模型更新的增量学习方法,使用有源回归神经网络构建动态浮选过程模型。通过起泡剂、捕收剂、活化剂和铅锌品位预测泡沫结构特征,有效解决了输入干扰情况下的模型失配问题。由于浮选过程的复杂性,由操作员控制的操作变量往往不能及时适当调整,Yan等<sup>[25]</sup>研究了一种基于工艺知识和实际工业数据的混合贝叶斯网络(Bayesian network, BN)智能操作调整框架。在得到精矿品位的预期值后,通过BN推理进行在线操作调整,并进一步预测调整之后的精矿品位以保证其可靠性。同样基于BN,Yan等<sup>[26]</sup>考虑到建模的复杂性,提出一种面向全厂浮选工业过程的模块化BN建模框架将精矿品位等技术指标控制在可接受的范围内。首先将全厂浮选过程分解为若干相关子模块,通过结构学习和参数学习建立相应的局部BN,并基于过程知识和相关变量,将每个局部BN融合到全局BN中,结合实际应用进一步预测精矿品位。该方法比传统方法具有更好的效果,可以作为一种智能工具,为实际操作人员提供合理的决策。针对浮选过程中7个采样点的原矿石等级和分离原矿石等级数据,Yan等<sup>[27]</sup>分别采用反向传播(back propagation, BP)神经网络、偏最小二乘法(partial least squares, PLS)、即时学习偏最小二乘法(just-in-time learning partial least squares, JIT-PLS)、自适应偏最小二乘法(adaptive learning partial least squares, adaptive-PLS)和窗口自适应偏最小二乘法(window adaptive learning partial least squares, window-adaptive-PLS)预测精矿品位,并进行实验对比分析。上述建模方法都可以用于估算铜精矿品位,但对于不完整的历史训练数据,adaptive-PLS方法是估计铜精矿品位的最有效方法,它可以提前准确预测下一个测量周期的铜精矿品位,并可用于指导操作。

马恩杰等<sup>[28]</sup>以原矿配矿比例、粉矿品位、磨矿粒度以及选别粉矿处理量等为输入,建立了基于加权SVM的强磁精矿品位、强磁尾矿品位、弱磁精矿品位、弱磁尾矿品位4个指标的预报模型。通过构造重要性函数确定了SVM的加权系数,并利用该厂生产管理系统中的历史数据,采用没有加权、按时间加权、按样本距离加权的SVM进行对比分析,得出确定SVM加权系数的方法预报效果更好的结论。针对矿物浮选过程中回收率难以在线检测的问题,周开军等<sup>[29]</sup>以图像特征作为模型输入,

采用最小二乘支持向量机(least squares support vector machine, LS-SVM)构造预测模型,并通过交叉验证实现模型参数优化。首先对泡沫颜色、泡沫速度、气泡尺寸等特征进行提取,并对泡沫特征与回收率进行了相关性分析。然后利用图像特征与矿物回收率数据对模型进行训练,并优化模型参数,验证了回收率预测准确性和模型泛化能力。针对单一特征不能完全反映泡沫图像信息,而多特征的任意组合易造成特征冗余的问题,黄佳炜等<sup>[30]</sup>利用提取的13类泡沫图像特征,分别搭建了SVM、递归特征消去SVM(SVM with recursive feature elimination, SVM-RFE)、二进制粒子群优化SVM(binary particle swarm optimized SVM, SVM-BPSO)、SVM-RFE-BPSO四类精矿品位预测模型。利用SVM-RFE算法去除部分冗余特征,通过缩减粒子群算法的搜索空间寻找最优特征子集,然后利用SVM对特征子集组成的特征空间进行分类。SVM-RFE-BPSO以较少的特征数获得较高的预测精度,实现了输入特征的简化。

浮选过程中,由于强烈的搅拌及鼓风作用使得矿物粒子与泡沫分布不均,从而造成样本数据存在不确定性,严重影响入矿品位在线估计的精准度。针对样本数据中存在的确定性,吴佳等<sup>[31]</sup>提出基于核主元分析(kernel principal component analysis, KPCA)和模糊C均值聚类-概率支持向量回归(fuzzy C-means clustering - probability support vector regression, FCM-PSVR)的建模方法,利用泡沫图像特征与加药量等数据建立金锑入矿品位和精矿品位的估计模型,基于专家规则对估计结果的可信度进行评价,为指导金锑浮选加药量的控制起到了重要作用。复杂硫化物矿石难以加工,通常需要多级浮选,每个阶段的过程输出都受到系统中不同子过程的影响。针对这一问题,Popli等<sup>[32]</sup>提出并实现了一种动态监测方案,构建铅锌回收的动态基础模型来表示铅锌硫化物的多级粗选过程,并利用SVM分类和多元图像数据回归实时测量品位和回收率。以铅和锌浮选阶段的进料粒度和捕收剂用量为设计变量,应用扩展卡尔曼滤波器进行状态和参数估计,拟合铅和锌精矿的附着子过程。通过施加捕收剂剂量扰动,测试估计和监测算法捕捉附着变化效果及其对精矿回收率的影响。

## 2) 经济指标

准确预测产品成本,通过产品成本的变化趋势对生产进行合理调整,对浮选生产过程成本控制具

有重大意义. 由于影响产品成本的因素多而复杂, 准确预测产品成本是一个重要而又难以解决的问题. 杨新等<sup>[33]</sup>提出基于自适应神经模糊推理系统 (adaptive neuro-fuzzy inference system, ANFIS) 的选矿产品成本预测模型, 用减法聚类、最小二乘法及梯度下降法辨识了 T-S 模型. 通过某浮选厂综合精矿成本及其影响因素对实际产品成本进行了估算, ANFIS 预测模型具有较好的泛化能力, 能够准确预测选矿产品成本. 杨刚等<sup>[34]</sup>提出一种改进 BP 神经网络的成本预测方法. 该方法首先用灰色关联分析法计算各因素与成本之间的相关度, 选择相关度最大的 4 个变量, 即入矿品位、精矿品位、尾矿品位和台时处理量作为模型的输入; 然后通过黄金分割优选法确定隐含层网络节点数建立选矿成本预测模型. 该模型简单可行, 避免了复杂的数学运算, 可以对精矿成本的变化趋势进行准确预测.

### 3) 液位和药剂添加量

常规的检测方法在浮选过程中难以准确检测浮选槽液位, 针对这一问题, 桂卫华等<sup>[35]</sup>提出一种基于相关向量机 (relevance vector machine, RVM) 的浮选液位软测量方法. 该方法基于采集的浮选泡沫表层图像, 通过提取硫浮选泡沫溢流速度和泡沫稳定度动态图像特征, 融合浮选过程充气量、矿浆流量等过程参数, 实现硫浮选过程中浮选槽液位的预测. Troncoso 等<sup>[36]</sup>采用自回归 (autoregressive exogenous, ARX) 方法对多级浮选槽液位系统进行辨识, 并采用卡尔曼滤波器进行状态估计. 王玉昆等<sup>[37]</sup>提出一种基于 KPCA 和 LS-SVM 的浮选加药控制模型, 采用 KPCA 算法对样本数据进行降维处理, 简化模型结构, 并用 LS-SVM 建立浮选加药控制模型, 将给矿流量、给矿浓度、给矿品位、给矿粒度以及浮选精矿品位输入模型以确定浮选过程的药剂添加量. 然后采用基于柯西变异和高斯变异改进的混合蛙跳算法对 LS-SVM 模型的参数进行优化, 显著提高浮选加药的预测精度.

### 2.2.2 基于深度学习的建模方法

深度神经网络是一种特征递进式的学习算法, 浅层的神经元直接从输入数据中学习一些低层次的简单特征, 例如边缘、纹理等. 而深层的特征则需要基于已学习到的浅层特征进一步学习更高级的特征, 隐藏层增加意味着由激活函数带来的非线性变换的嵌套层数更多, 从而能构造更复杂的映射关系, 因此基于深度学习的建模方法可以更加精准有效地实现对品位等指标的预测.

浮选过程中, 良好的数据特征可以更好地实现生产过程指标的预测, 传统的特征提取方法通常考虑有限的特征类型, 需要用专家知识选择特征, 并且可能对变化的成像条件敏感. 针对这一问题, Horn 等<sup>[38]</sup>采用深度学习替代传统的纹理特征提取方法. 与其他算法必须训练特征提取器不同, CNN 打破全连通网络具有固定维数的缺点, 允许发现和利用纹理和光谱特征, 使用 4 种不同铂品位的浮选泡沫图像进行训练研究. 相较于传统的特征提取方法, CNN 特征提取性能更具竞争力. 基于传递学习和 CNN, Fu 等<sup>[39]</sup>使用 AlexNet 网络从浮选泡沫图像中提取特征, 通过使用 CNN 对来自完全不同领域的图像数据进行预训练, 可以可靠地预测工业铂浮选设备中的运行条件. 在含砷硫化物的批量浮选实验中, CNN 在多变量图像分析中优于其他先进的方法, 能更有效地从浮选泡沫中进行特征提取.

CNN 多用来处理针对图像和视频的各种任务, 其准确率一般优于其他神经网络模型, 近年来 CNN 在泡沫浮选过程建模中应用广泛. 浮选泡沫层不可避免含有一些不期望的杂质, 为了对产品进行适当分级, 软测量器需要区分不同物质产生的模式. 基于 CNN 进行浮选监测, Zhang 等<sup>[40]</sup>开发了一种用于泡沫浮选的卷积记忆网络软测量模型. 该方法利用 CNN 提取深度泡沫图像特征并索引记忆单元, 在此基础上, 融合注意力机制及语义键值记忆网络以减少杂质对泡沫图像特征的干扰, 实际生产数据的模拟表明该监控方案较其他方法有更好的预测性能. Wen 等<sup>[41]</sup>提出一种利用泡沫图像和 CNN 结构预测浮选精矿灰分的浮选软测量方案. 将来自煤炭浮选现场的泡沫图像数据集划分为 7 个区间类别, 并进行数据增强. 基于不同的超参数, 采用 AlexNet、VGG16、VGG 19、ResNet18、ResNet34、ResNet50、ResNet101 七种 CNN 对比分析预测性能, 使用泡沫图像中所有子图像预测结果的最高灰分含量表示其区间的灰分含量. 随着 CNN 层的加深, 测试精度从 47.6% (AlexNet) 提高到 96.2% (ResNet101), 优化超参数后, ResNet101 对 7 个精矿灰分区间的识别准确率达到 97.1%, 表明 CNN 在精矿灰分预测具有良好的工业性能.

时间序列模型利用过去一段时间内某事件时间的特征来预测未来一段时间内该事件的特征. 由于操纵变量的复杂交互和相互依赖, 基于时间



序列网络建立能够准确预测浮选过程指标的模型有助于实现浮选过程的自动控制。Pu等<sup>[42]</sup>开发了一种名为 FlotationNet 的分层深度学习网络,基于长短期记忆(long short-term memory, LSTM)模块和完全连接的体系结构,从浮选设备中获取进料纯度和工艺操作参数,预测产品中铁纯度和二氧化硅纯度。除了考虑输入和输出纯度之间的时间关系外,还考虑了操作变量和输出纯度间的高度非线性,针对铁预测精度和二氧化硅预测精度之间的关系,自定义损失函数并实现 L2 正则化,以优先考虑铁预测结果。实验分析表明,FlotationNet 对铁纯度的预测精度显著高于原始的 LSTM 和模糊神经网络获得的预测精度。由于输入参数对加工铁和二氧化硅的影响机制不同,FlotationNet 对二氧化硅预测精度最差,需要进一步提高 FlotationNet 的性能。现有泡沫浮选品位监测方法多侧重于采用单个浮选池的视觉泡沫特征,然而泡沫浮选是一个长流程工业过程,不同浮选池的多源特性可以进一步提高品位监测的准确性。对此,Zhang等<sup>[8]</sup>提出一种具有多源特征的分组时间序列网络(grouping time series network, GTSN)用于锌尾矿品位监测。该方法使用自聚类算法根据附加测量属性对多源特征进行分组,将分组特征发送到具有不同动态特性的不同时间序列子网络中,并整合分组特征向量来表示尾矿品位。在模型训练中引入多任务学习来最小化每个单独分组特征和集成特征的品位预测误差,GTSN 能够有效结合多源特征实现对品位的准确预测。在泡沫浮选监测中,基于机器视觉的软测量虽然可以为精矿品位提供稳定可靠的在线估计,但难以进行在线测量。手工特征很难从外观和运动角度充分探索泡沫表面行为特征,并且不同时间间隔提取的图像特征与精矿品位之间的相关性可能不同。为了利用泡沫表面行为的时间序列信息和泡沫表面行为在过去时刻的重要性差异预测精矿品位,Ai等<sup>[43]</sup>开发了一种基于深度学习的双流特征提取模型,并提出一种包含时间序列分析模块和注意力机制的混合预测模型,以预测图像特征与精矿品位之间的关系。该方法能够探索和利用更多的指示信息准确地预测精矿品位。

在泡沫浮选中,浮选池泡沫特征和预测品位之间通常存在时间延迟,难以将观察到的浮选池特征与预测品位相匹配。针对于这一问题,Zhang等<sup>[44]</sup>综合考虑第一粗选机泡沫图像和先前测量的

尾矿品位特征时间序列。利用编码器-解码器模型进行锌尾矿品位预测。根据泡沫视频图像帧率和 X 射线荧光分析仪品位测量频率的关系,通过找到最近的可用特征向量,自动提取第一粗选机的特征时间序列。将第一粗选机的特征时间序列馈送到编码器以生成上下文向量,然后将上下文向量和先前测量的品位发送到解码器以预测当前尾矿品位。所提出的模型有效地捕获了特征时间序列与先前测量等级之间的动态一致性,实现了品位的准确预测。泡沫浮选中,泡沫视频的采样率明显高于使用特殊检测设备获得的标记品位,这就使得模型输入数据采样率高于输出数据采样率,导致时间序列数据不匹配。针对这一问题,Zhang等<sup>[45]</sup>提出一种基于 LSTM 的网络以估计锌浮选回路中第一粗选机的尾矿品位。首先通过计算泡沫图像视觉特征的平均值,并对进料等级进行集成,获得泡沫视频输入特征表示。然后将泡沫视频输入特征引入 LSTM 网络训练得到序列特征以匹配标记等级。这种品位监测模型可以充分利用泡沫视频信息,并解决采样率不匹配的问题。特征重构的方法为解决输入输出采样率不匹配问题提供了一种新思路,Zhang等<sup>[46]</sup>设计了一个称为特征重构回归(feature reconstruction regression, FR-R)网络的深度神经网络架构。首先提取特征向量序列作为输入特征,以获取输入数据的动态时间信息。然后设计了一个具有权重共享核网络和固定位置编码的特征重构网络以生成重构的特征向量,并将重构的特征向量作为回归网络发送到全连接层中,以链接标记的性能。FR-R 网络有效解决了工业浮选过程性能监测中输入数据和标记性能之间的采样率不匹配和时间延迟问题。泡沫浮选是一个非常复杂的工业过程,部分时刻泡沫状态可能与品位没有绝对关系,性能监控模型仅把分析仪测量的等级作为输入,而不考虑输出特性,因此 X 射线荧光分析仪测量的等级与泡沫视频特征之间需要更充分的集成。Zhang等<sup>[47]</sup>提出一种暹罗时间序列和差分(siam time series and differential, STS-D)网络,有效集成不同时间步长的输入特征,并标记前一时刻的性能。所提出的 STS-D 网络包括 2 个子网络,一种是暹罗时间序列网络,其目的是在当前和先前时刻为输入时间序列提取有效和统一的特征表示;另一种是差分网络,它将 2 个输入时间序列的特征表示与前一时刻的标记性能相结合,以增量方式预测当前时刻的性能。所提出

的 STS-D 网络能够有效处理时间序列不匹配的问题,并对品位进行高精度预测。

### 2.2.3 基于多模型集成的建模方法

浮选过程由多个存在相互关联和耦合特性的浮选流程构成,针对特定流程的单一预测模型容易造成模型精度低和泛化性差。针对这类问题,曹斌芳等<sup>[48]</sup>提出一种基于多源数据的铝土矿浮选过程生产指标集成建模方法。首先分析了浮选过程的工艺机理与生产指标相关的多源数据(生产数据和泡沫图像特征数据),分别建立各生产指标预测子模型和同步误差补偿子模型,并采用信息熵和智能协调策略分别构建精矿品位和尾矿品位的集成预测模型。工业验证和工况分析表明集成建模策略可以有效提高模型预测精度、泛化性和可信度。

在浮选过程中,将机理模型与数据驱动模型相结合也是提高生产指标预测精度的一种方法。李启富等<sup>[49]</sup>建立了以描述浮选状态的 14 个泡沫特征数据为输入的 B 样条偏最小二乘(B-spline partial least squares, BS-PLS)精矿品位预测模型。考虑到该数据模型虽然可以取得较高精度,但其泛化能力较差,预测结果不稳定,而机理模型有较好的泛化能力,故采用信息熵的方法将机理模型与数据模型进行集成,建立了精矿品位预测的集成模型;为保证模型预测精度,采用滑窗滚动方法更新 2 个单一模型的参数和集成模型的权值,并用集成模型偏差对输出进行修正。此方法大幅提高了精矿品位预测模型的稳定性和预测精度,为建立优化控制系统提供可靠依据。综合而精确的浮选模型是优化矿物回收率和品位的基础。Sun 等<sup>[50]</sup>利用浮选动力学知识和泡沫图像特征提出一种多模式建模框架。在该框架中,过程动力学被表示为每个工作条件的子模型的加权和,权重随进料和操作条件而变化。对于每个工况,子模型被表示为简化浮选动力学模型和补偿模型之和。由于动力学不能明确涵盖影响因素,因此建立了基于 LSTM 的补偿模型,通过从顺序收集的泡沫图像中学习进行误差补偿,减少真实过程动力学和动力学模型之间的不匹配。集成多模式建模有效地利用了浮选动力学知识和泡沫图像特征,促进在线监测系统的开发。

表 2 汇总了浮选过程指标预测方法,并整理了预测模型采用的输入变量及预测指标。

## 3 浮选过程智能控制方法

浮选过程十分复杂,至今仍然没有一种令人

满意的通用控制方法,这导致现今的浮选效率达不到很高的水平。因此,通过现有的技术,优化浮选过程中的控制技术并提出新的控制技术十分重要。

浮选过程控制算法通过控制相关变量,达到使控制指标满足期望的目的。部分控制量及指标<sup>[51]</sup>如下。

1) 操作变量:尾阀及进料阀等阀门开度、气泵开度等设备参数。

2) 中间变量:矿浆液位、泡沫高度、进料流量、进料品位、尾矿流量、气体流量等测量值。

3) 控制指标:精矿品位、尾矿品位、回收率等最终评价指标。

随着技术的发展,现代控制算法可以按不同标准分为不同类别。本文将浮选控制方法分为基于模型控制和无模型控制 2 个大方向,并分别进行介绍。

### 3.1 基于模型的控制方法

#### 3.1.1 模型预测控制

模型预测控制(model predictive control, MPC)是指利用控制对象的动态模型,预测控制变量未来动作对输出的影响,主要针对含优化需求的控制问题<sup>[52]</sup>。在之前的研究中,该方法与同时期的多变量控制方法相比,已经被证明是十分优秀的,这主要是因为其概念简单,能够轻松有效地处理具有控制约束条件的多输入多输出复杂系统<sup>[53]</sup>。随着各种新理论的开发及应用,现今已经可以将 MPC 与更新的控制技术融合,获得更好的控制性能。

MPC 策略由预测模型、目标函数以及控制律 3 个部分组成,其中预测模型的获取对于 MPC 来说至关重要,模型不仅需要准确表示系统动态特征,并且形式还要尽量简单<sup>[51]</sup>。为避免模型不匹配而导致的控制缺陷,Zhang 等<sup>[24]</sup>将以增量学习为基础的自适应过程模型作为核心,设计了一种非线性 MPC 控制器。该控制器基于过程模型,通过增设的一组成本函数,获得未来时刻的输出,并由此获得最佳控制序列。实际铅锌泡沫浮选厂的结果表明此控制器可以将精矿品位控制在预期值。

动态矩阵控制(dynamic matrix control, DMC)<sup>[54]</sup>是 MPC 算法的一种,是一种基于对象阶跃响应预测模型、滚动实施并结合反馈校正的优化控制算法。Brooks 等<sup>[55]</sup>介绍了一种将 DMC 用于浮选过程的控制方法,在小幅提升精矿品位的同时显著降低了浮选药剂的使用量,成为更大系统中 MPC 控制策略的一部分。

表2 浮选过程指标预测方法

Table 2 Prediction algorithms of flotation process indicators

文献	预测方法	模型输入变量	预测指标
[24]	自回归神经网络	铅矿品位、锌矿品位、起泡剂用量、捕收剂用量、活化剂用量	泡沫尺寸、速度、表面纹理等个特征
[31]	KPCA 和 FCM-PSVR	加药量、泡沫图像特征	入矿品位
[25]	BN 模型	工况条件、精选槽 I 初始液位、精选槽 I 初始速率、精选槽 I 初始液位、精选槽 I 初始速率	精矿品位
[26]	BN 模型	原矿石品位、矿石进料量初始值、泡沫图像特征等 12 个过程变量	精矿品位
[27]	BP、PLS、JIT-PLS、adaptive-PLS、window-adaptive-PLS	粗选 I 进口、扫选 II 出口、精扫选 II 出口、柱精选 II 出口等处的铜品位	精矿品位
[28]	加权 SVM	原矿配矿比例、粉矿品位、磨矿粒度以及选别粉矿处理量	强、弱磁精矿与尾矿品位
[30]	SVM、SVM-RFE、SVM-BPSO、SVM-RFE-BPSO	泡沫尺寸等 3 个泡沫特征	精矿品位
[40]	CNN	GoogLeNet 抽取的泡沫图像特征	精矿品位
[41]	CNN	泡沫图像特征	精矿灰分
[42]	分层深度学习网络 FlotationNet	进料纯度和运行参数等 23 个特征	铁精矿品位和二氧化硅纯度
[43]	双流特征提取模型	泡沫图像运动特征及表观特征	精矿品位
[46]	FR-R 网络	泡沫大小、速度、纹理、破碎率等图像特征及粗选进料品位	精矿品位
[47]	STS-D 网络	泡沫大小、速度、纹理、破碎率等图像特征及粗选进料品位	精矿品位
[49]	BS-PLS 和机理模型的集成模型	泡沫颜色、纹理、速度等 14 个图像特征	精矿品位
[50]	浮选动力学模型和 LSTM 集成模型	泡沫图像特征	精矿品位
[8]	GTSN	泡沫图像特征	尾矿品位
[44]	编码器-解码器	泡沫大小、速度、纹理、破碎率等图像特征及粗选进料品位	尾矿品位
[45]	LSTM	泡沫大小、速度、纹理、破碎率等图像特征及粗选进料品位	尾矿品位
[48]	生产指标预测子模型和误差补偿模型、信息熵和协调策略集成模型	给矿品位、浓度、粒度、加药量以及矿浆 pH 值和泡沫红色分量、流速、稳定性、大小、承载率、纹理等图像特征	精矿品位和尾矿品位
[29]	LS-SVM	泡沫颜色、泡沫速度、气泡尺寸,以及气泡破碎率等特征	回收率
[32]	SVM 和多元图像数据回归	进料粒度和捕收剂用量	品位和回收率
[33]	ANFIS	精矿成本数据	实际产品成本
[34]	灰色关联分析与 BP 神经网络	入矿品位、精矿品位、尾矿品位、台时处理量	选矿成本
[35]	RVM	泡沫溢流速度、稳定度、充气量、入矿流量	液位
[36]	ARX	入矿流量、五级浮选槽阀门开度	五级浮选槽液位
[37]	KPCA、LS-SVM	给矿流量、给矿浓度、给矿品位、给矿粒度、精矿品位	药剂添加量



对于含有多个浮选槽的浮选系统,由于各个浮选槽之间存在相互影响,普通的MPC方法并不能很好地期望水平控制在理想范围。针对此问题,Putz等<sup>[56]</sup>介绍了一种混合MPC方法。该方法建立自主切换运行条件的系统混合模型,以该模型为基础,通过最小化关于操作变量的目标函数,获得多级浮选系统的理想控制策略。仿真结果表明,该方法可以通过控制每个浮选池的流出阀门开度,使矿浆液位稳定的同时,将尾矿品位保持在预设水平,该方法成为浮选分布式控制策略集成的一部分。

### 3.1.2 反馈解耦控制

浮选过程多变量之间存在耦合,控制整个浮选回路的多变量控制器并不容易实现,因此需要设计解耦器分离不同的控制回路以克服此问题。解耦控制器的实质是对多输入多输出系统设计补偿器,从而降低耦合程度或将系统转化为多个无耦合的子系统<sup>[57]</sup>。相比于MPC,解耦控制器所需的计算量少,可以更好地在工业慢速处理器上得以应用。

解耦控制器可通过结合反馈信号和补偿信号达到理想控制效果。Jiang等<sup>[58]</sup>设计了一种基于补偿信号的运算层解耦控制器。该控制器将浮选过程视为设备层和运算层组成的2层结构,在设备层中获取运行数据,并通过未建模动态补偿器获得补偿信号,确定反馈解耦控制器的参数矩阵。仿真表明该控制器可以实现浮选过程的稳态跟踪、稳态解耦和未建模动态补偿。

相似地,Stenlund等<sup>[59]</sup>介绍了一种基于流量前馈的解耦控制器,该控制器通过前馈补偿器抵消被控对象中参数的相互作用,从而可以使用常规的SISO控制方法对每个独立回路进行单独控制。实际工厂环境下的多级浮选应用表明该解耦控制器可以准确地将每一级浮选槽的液位控制在设定值,而原始的SISO控制策略则难以取得满意的控制效果。

实际生产过程中进料矿石品位、易磨性等参数常发生变化,导致基于固定模型的控制难以实时做出响应。为了克服系统的干扰及参数不确定性,Nasseri等<sup>[3]</sup>设计了一种自适应解耦控制器,通过内部模型方法自动计算解耦器的参数,从而达到控制器随输入变化而自适应调整的目的。仿真结果表明,该控制器可以有效消除输入变量之间的耦合作

用,且在控制效果上优于一般的MPC控制器及PID控制器。

为进一步消除工况变化对于控制效果的影响,Li等<sup>[60]</sup>提出一种多模型自适应解耦控制策略,该控制方法将自适应神经网络、模糊推理与自适应解耦控制相结合,针对不同工况生成不同控制策略,并通过切换机制自主选择。实际浮选过程应用表明,该自适应解耦控制器可以有效消除环路中的干扰和耦合,并且相对于普通的PID控制,显著提高了跟踪能力。

### 3.1.3 模糊控制

模糊控制是处理系统中不精确和不确定变量的一种有效方法,核心是将模糊输入量通过预设规则转化为控制策略的模糊推理机。模糊控制理论已经发展了数十年,直到今天,其思想对于工业控制仍然适用<sup>[61-62]</sup>。

针对动态非线性系统的浮选控制较大程度上依赖于工作点以及一般的反馈控制器对于扰动非常敏感等问题,Saravani等<sup>[63]</sup>开发了一种基于模糊模型的模糊控制器,通过在模拟结果和操作变量以及性能参数之间检测到的相关矩阵获得模糊控制规则,控制器根据输入量进行工作点和控制策略的选择,从而产生控制信号。仿真结果表明控制器能够在合理的时间内将过程性能保持在所需水平,最终将回收率和精矿品位等指标控制在较好区间。Núñez等<sup>[64]</sup>提出一种分层混合模糊策略,该策略分为宏观上的整体性能控制和具体到每个浮选柱中的细化稳定策略,可以实现在低回收率、低精矿品位、正常运行3种操作场景之间的自适应切换,解决了局部变量无法与性能指标相联系,以及控制策略无法适应不同操作场景的问题。仿真实验证明,该方法能够改善浮选过程的控制性能,提高平均精矿品位和平均回收率,降低回收率和精矿品位标准偏差,并可与磨矿等浮选环节相结合产生更好的效果。

实际浮选过程中,泡沫图像特征存在可以直接反映生产工况、容易提取和分析等特点,因此出现很多机器视觉与模糊控制相结合的方法<sup>[65-68]</sup>。Jahedsaravani等<sup>[69]</sup>提出了一种基于泡沫图像特征的浮选过程建模与控制方法,使用神经网络建立泡沫图像特征与过程变量之间的相关性模型,并通过选定的过程变量设计模糊控制器,在期望水平上提取泡沫特征以控制过程性

能. 通过施加不同的参考输入和干扰信号进行仿真, 结果显示该控制器可以结合泡沫尺寸与泡沫速度, 通过控制 pH 值等量使精矿品位等指标达到理想水平.

### 3.1.4 神经网络控制

对于复杂对象, 非线性控制器比线性控制器有着更好的控制效果. 但是由于缺少综合分析非线性系统的通用方法, 非线性系统的设计更加困难<sup>[70]</sup>. 为捕捉浮选系统的非线性行为, Mohanty<sup>[71]</sup>设计了一种基于神经网络的 MPC 控制器. 该控制器由动态神经网络模型及优化器组成, 动态模型通过阀门开度预测液位, 优化器通过液位优化下一时刻的阀门开度, 从而得到控制策略. 相比于普通的线性控制器, 基于神经网络的控制器能更好地控制液面, 但往往仅在已训练的范围内取得较

好的控制效果, 存在模型无法外推的缺点.

由于常规神经网络存在权重参数计算量大, 易出现过拟合和泛化损失等问题, Cubillos 等<sup>[72]</sup>设计了一种自适应混合神经网络控制器. 该控制器测量浮选过程的输入和输出变量, 使用动态混合神经网络进行权重自适应递归, 以获得操作变量最优值. 该方法达到了通过控制进料流量调整精矿及尾矿品位的目的, 并具有较强的灵活性和鲁棒性.

基于模型的控制方法部分总结如表 3 所示. 可以看出, 由于基于神经网络的控制方法对系统动态模型要求不高, 且可以通过收集到的数据自主学习, 同时达到良好的控制效果, 神经网络控制逐渐成为流行方法. 但是对于要求不高且硬件落后的控制系统, 使用传统控制方式更加经济.

表 3 基于模型的浮选过程控制方法

Table 3 Model-based control methods for flotation process

分类指标	文献	控制方法	操作变量	控制指标	特点
模型 预测 控制	[24]	增量学习、自适应神经网络	药剂添加量 $u_1 - u_3$	泡沫特征	可以滚动优化, 及时弥补模型畸变、干扰; 依赖准确的优化问题模型
	[55]	动态矩阵控制	空气流量、矿浆液位、药剂添加量	精矿品位、尾矿品位	
	[56]	分段仿射、混合动态逻辑	矿浆液位、尾矿流量	精矿品位、尾矿品位	
反馈 解耦 控制	[58]	操作反馈解耦控制、线性模型参数识别	矿浆液位、进料量	精矿品位、尾矿品位	将一个多变量系统化为多个独立的单变量系统进行控制; 对参数变动较为敏感
	[59]	解耦控制、线性二次控制	阀门开度 $u_1 - u_5$ 、进料流量	各级浮选槽液位 $y_1 - y_5$	
	[3]	自适应解耦控制	尾矿流量、空气流量、洗涤水流量	泡沫深度、气体含量	
	[60]	自适应网络模糊推理系统 线性自适应解耦	阀门开度 $u_1 - u_3$ 、进料流量	各级浮选槽液位 $y_1 - y_3$	
模糊 控制	[63]	模糊模型	空气流量、矿浆液位、药剂添加量	精矿品位、回收率	规则易于理解与设定; 适应能力强, 有一定的鲁棒性
	[64]	模糊专家控制、分布式控制	洗涤水流量、空气流量	精矿品位、尾矿品位	
	[69]	神经网络、模糊控制	药剂添加量、空气流量、进料量	精矿品位、回收率、泡沫大小	
神经 网络 控制	[71]	动态多层感知器神经网络	尾矿流量、矿浆液位	泡沫深度	可学习和自适应, 有一定的智能性
	[72]	自适应混合神经网络	药剂添加量、矿浆液位	精矿品位、尾矿品位、回收率	

### 3.2 无模型控制方法

上述基于模型的浮选过程控制方法, 所依赖的模型往往并非精确的动力学模型, 而是在忽略一些

过程的基础上得到的近似模型. 近似模型可以大大简化控制方法的设计, 但同时也会限制控制方法的控制性能. 无模型控制方法在一定程度上解决了这

类问题.

### 3.2.1 基于强化学习的控制方法

强化学习通过优化价值函数,指导智能体进行探索从而生成控制策略,避免了直接对系统机理的推导,是目前很有发展前景的方向. Ai 等<sup>[73]</sup>提出一种基于深度学习特征的两层最优控制方案. 该控制方案结合深度学习与强化学习的优点,上层通过深度学习提取泡沫图像特征并据此生成设定值,下层通过一种保守的双 Q 学习生成控制策略. 仿真表明该方法不仅可以生成接近实际系统的设定值,还可准确跟踪该设定值,是一种十分有效的无模型控制方法. 为实现基于数据驱动的浮选过程实时控制, Jiang 等<sup>[74]</sup>提出一种基于强化学习的交叉学习算法. 该算法结合策略迭代算法收敛快和值迭代算法更新频繁的优点,优化训练过程以获得在线学习的最优控制解. 在控制输入满足约束条件的情况下,实现期望指标的最优跟踪控制,且控制性能优于值迭代与策略迭代算法.

动态规划是一种基础的强化学习算法,其基本思想是将待求解问题分解为若干子问题进行最优求解. 矿物浮选过程中的参数变化可视为一种马尔可夫过程,并能够通过动态规划进行求解<sup>[75]</sup>. Maldonado 等<sup>[76-77]</sup>使用离散动态规划方法,实现不同工况下多级浮选槽泡沫深度的准确控制,并进一步基于动态规划的方法探究多级浮选系统中回收率曲线与浮选泡沫分离情况之间的关系.

动态规划对于求解简单问题具有较好的工业适用性,但在状态变量维数增加时,其计算量成几何倍数增加,从而产生维数灾. 自适应动态规划 (adaptive dynamic programming, ADP) 采用神经网络逼近动态规划中的指标函数和控制策略,可有效解决上述维数灾问题,为求解非线性系统的最优控制问题提供了切实有效的控制方案. 针对输入时延和非消失干扰情况下浮选过程的药剂控制问题, Li 等<sup>[78]</sup>提出一种基于数据驱动的 ADP 最优控制方法. 无须系统的动力学知识,仅通过输入在线测量数据即可获得药剂添加量的最优控制策略,相较于传统的 PID 控制器及 MPC 控制器获得了更好的稳定性和有效性. 相似地, He<sup>[79]</sup>验证了 ADP 控制器相比于传统策略迭代控制器的优越性,并将其实际应用于硫浮选工艺过程.

基于 ADP 控制器的设计中存在选择基函数困难、系统状态并不总是可以在线获得等问题,因此将

ADP 控制与状态观测器或机器视觉相结合是十分必要的<sup>[80]</sup>. Li 等<sup>[81]</sup>提出一种将机器视觉与 ADP 相结合的优化控制方法. 利用神经网络从泡沫图像中直接获得浮选指标,进一步以最小化浮选指标与参考值之间的误差为目标设计基于 ADP 的双循环迭代策略,在满足药剂添加约束的同时大幅减少参考浮选指标的跟踪误差.

### 3.2.2 基于深度学习的控制方法

深度学习是使用深度神经网络的有监督机器学习方法,与强化学习不同之处在于,深度学习的过程是静态的,不会通过主动探索环境获得新数据,并且得益于网络的深层结构,深度学习可以更好地处理高维数据.

基于机器视觉的控制方法可以轻松地从图像中获取有用信息,无须引入各种侵入式传感器,也无须破坏浮选设备的结构,在浮选过程中得以广泛应用. Kaartinen 等<sup>[82]</sup>提出一种结合多相机系统和专家控制器来提高浮选性能的新方法. 采用神经网络获得过程变量与图像数据之间的强联系,将图像数据变量转化为控制器输入,并通过专家控制优化回收率等指标.

为了利用泡沫图像的动态变化信息,需要一种可检测关联时间序列的控制方法. Ai 等<sup>[83]</sup>提出一种基于 LSTM 的神经网络预测控制器,利用图像特征及模糊专家控制寻找最优特征设定值<sup>[84]</sup>,使用 LSTM 来识别离散采样时刻的预测泡沫图像特征向量,实现了对泡沫特征的跟踪控制.

深度学习与强化学习之间存在区别,同时也存在联系. Li 等<sup>[85]</sup>通过神经网络实现强化学习,提出了一种零和博弈 Q 学习算法. 该算法推导了基于 Q 函数的博弈贝尔曼方程求解最优设定值和最差扰动,使用神经网络优化该方程,仿真结果表明了算法的有效性.

浮选过程部分无模型控制算法总结如表 4 所示. 相比于基于模型的控制方法,无模型控制更多地体现了智能性,在无须了解系统的任意动力学特征的同时,获得更加优秀的控制性能. 但是相对于传统控制方法,深度学习或强化学习需要更好的硬件设备,这也提高了控制成本.

## 4 浮选过程优化设定算法

浮选过程控制的目标是使被控变量尽可能地跟踪控制系统的设定值,为了优化精矿品位、矿物回收



表4 浮选过程无模型控制方法

Table 4 Model-free control methods for flotation process

分类指标	文献	控制方法	操作变量	控制指标	特点
基于强化学习	[73]	Q 学习	药剂输入 $u_1 - u_3$	预测图像特征、精矿合格率	智能体自主探索策略,无须近似模型,有一定的智能性
	[74]	交叉学习	矿浆液位、进料流量	精矿品位、尾矿品位	将问题分解为子问题,对于一般的工业问题适应性较好
	[76]	动态规划	每个浮选池液位 $u_1 - u_5$	精矿品位、尾矿品位、回收率	在动态规划的基础上,增加了高维特征的处理能力,避免维数灾难的产生
	[78]	ADP	药剂添加量 $u_1 - u_3$ 、进料流量	精矿品位、尾矿品位	
	[79]	ADP	尾矿液体体积、空气流量	精矿品位、尾矿品位、回收率	
基于深度学习	[81]	ADP、双循环迭代策略	药剂添加量 $u_1 - u_4$	精矿品位、尾矿品位	
	[82]	深度神经网络、专家控制	图像特征(泡沫颜色、尺寸、速度、破碎率、载荷)	精矿品位、回收率	深度神经网络实现的有监督的机器学习,是一种静态学习过程,可学习深层特征及更复杂的映射关系
	[83]	LSTM 深度神经网络、模糊专家控制	药剂添加量 $u_1 - u_5$ 、进料品位	精矿品位、尾矿品位	
	[85]	零和博弈 Q 学习、 $H_\infty$ 控制	矿浆液位、进料量	精矿品位、尾矿品位、回收率、经济效益指标	

率等运行指标,提高产品质量并改善矿物利用率,需要动态更新矿物浮选过程操作变量的最优设定值。本部分将分别讨论浮选过程在单个运行指标和多个运行指标情况下的设定值优化算法。

#### 4.1 基于单个运行指标的浮选过程设定值优化方法

精矿品位和矿物回收率是矿物浮选过程的重要指标,众多学者根据生产实际,提出了分别将精矿品位、尾矿品位、矿物回收率等作为唯一目标,或者基于规则将多个目标综合考虑的设定值优化算法。针对浮选过程的主要性能指标,本部分将设定值优化方法分为基于规则的优化方法和使用机器学习的优化方法2类,分别介绍如下。

##### 4.1.1 基于规则的设定值优化方法

基于规则的优化方法是将专家或操作员的实际经验和神经网络的推理转化为规则集合,根据实际情况选择不同的规则调整变量的设定值。该方法的优点是数据获取和规则建立容易,同时可以获得较优的设定值。综合考虑精矿品位和尾矿品位,Chai 等<sup>[86]</sup>提出一种基于规则推理(rule-based reasoning, RBR)的药剂设定值优化系统。系统由单元药剂预设模型 RBR、反馈补偿器和前馈补偿器 RBR、加药计算系统组成。选矿厂的实际

应用表明,该方法可以在操作条件发生变化时自行调整加药设定值,进而获得较高的精矿品位和较低的尾矿品位。

在对多个指标优化设定值时,可以依据工况或规则将其分解为多组不相关的优化指标。Dong 等<sup>[87]</sup>提出一种煤浮选工艺的切换优化控制方法。该方法分别针对精煤灰分、回收率这2个优化目标进行优化,并使用 LS-SVM 在2种工况之间切换控制,分别获得药剂添加量和泡沫深度的最优设定值。在实际的煤浮选过程中,该方法相较于传统方法提高了平均精煤灰分和精煤回收率。

对于基于机器视觉的控制方法,改变输入量从而使图像特征保持在最优状态是必要的。Ai 等<sup>[83]</sup>提出了一种基于模糊关联规则(fuzzy association rules, FAR)的设定值优化方法,用于生成图像特征的最优设定值。该方法通过模糊关联规则,不仅可以利用现有的专家经验得到进料条件与最优图像特征之间的关系,还能通过规则挖掘算法获得此前未发现的关联。仿真表明使用该方法生成的最优设定值最终可以获得一组理想指标。

##### 4.1.2 基于机器学习的设定值优化方法

由于存在图像噪声、人工无法识别图像高维特

征等问题,能够满足浮选过程动力学的图像特征设定值难以计算<sup>[39]</sup>. 针对此问题,Zhang 等<sup>[88]</sup>开发了一种基于生成对抗网络的设定值计算方法. 该方法从工业数据中学习优化知识,使用特征一致性控制生成3类图像特征的最优设定值,并提高设定值的可达性.

强化学习可在不了解系统动力学模型的前提下,针对运行指标产生丰富的策略优化设定值. 然而目前很少有将其应用于浮选问题的研究<sup>[89-90]</sup>. 针对此情况,Li 等<sup>[85]</sup>提出一种新的Q学习方法,该方法仅使用测量数据进行学习,并通过零和博弈Q学习算法优化经济效益指标,获得最佳精矿品位和尾矿品位作为后续 $H_{\infty}$ 最优设定值,双层优化方案有效提高指标优化性能.

针对设备层存在设定值约束条件下操作未知模型的浮选工业过程优化控制问题,Jiang 等<sup>[91]</sup>提出一种基于提升技术和强化学习的新型双速率数据驱动算法. 该算法采用基于强化学习的策略迭代方法优化综合体现精矿品位与尾矿品位的价值函数,进而生成矿浆液位与进料流量的最优设定值.

#### 4.2 基于多目标优化的浮选过程设定值优化算法

浮选过程中存在多个衡量控制效果的运行指标,例如精矿品位、尾矿品位、回收率等,每个指标又都存在多个影响因素,如药剂剂量、通风量、液位等. 同时控制尽可能多的性能指标,是浮选控制过程中的一个重要问题.

此外,实际的浮选过程中,往往存在多个优化

指标互相冲突的情况. 针对此类问题,常用方法是求解帕累托最优前沿,并根据实际情况和专家经验选择最优优解作为最优设定值. Zhang 等<sup>[92]</sup>综合考虑金回收率和金精矿品位2个优化目标,提出了一种基于精英策略快速非支配排序遗传算法(non-dominated sequencing genetic algorithm, NSGA-II)的多目标优化模型,该模型全面考虑了浮选过程中变量的相互作用,提升了自身准确性的同时提高了金矿浮选能力. 针对多级浮选槽回路多目标优化过程中的决策变量二值问题,Guria 等<sup>[93]</sup>提出基于跳跃基因自适应遗传算法的NSGA-II改进方法,可更快地获得全局最优解. 浮选回路仿真表明该方法在浮选池液位存在约束的情况下,通过非支配解的帕累托集最大限度地提高了金属回收率及精矿品位.

Barrozo 等<sup>[6]</sup>改进了多目标优化萤火虫算法<sup>[94]</sup>,并将其与帕累托最优准则和反停滞算子相关联,找到最大化精矿品位和回收率的条件,并在实验中获得比NSGA-II算法更好的结果.

浮选过程运行指标优化问题的部分解决方法整理如表5所示. 使用单目标优化的方法设计简单,易于实现;但未充分考虑目标之间的相关性,难以充分挖掘系统性能或在优化特定指标时牺牲其他指标. 对于多目标优化的情况,目前应用较多的是先通过各种算法获得帕累托前沿,对指标进行取舍后再进行优化. 该方法消耗计算资源大,因此尚未在工业应用中大规模推广.

表5 浮选过程运行指标优化方法

Table 5 Optimization methods for operation indices of the flotation process

分类指标	文献	运行指标	优化算法	优化设定值	特点
单个运行 指标优化	[86]	精矿品位 尾矿品位	基于RBR	浆料浓度、矿石质量、 空气流量、浮选液位、 药剂添加量	基于规则的设定值优化算 法可将多个运行指标作为 整体考虑;数据和规则易 于获取,工业上易于实现
	[87]	精煤灰分 精煤回收率	专家系统理论、模糊控制	泡沫深度 药剂添加量	
	[83]	药剂添加量 精矿品位	基于FAR挖掘	泡沫图像特征 $x_1 - x_4$	
	[88]	精矿品位	深度神经网络、生成对抗 网络	泡沫图像特征 $y_1 - y_3$	
	[85]	精矿品位 尾矿品位	深度神经网络、Q学习	精矿品位 尾矿品位	
	[91]	精矿品位 尾矿品位	深度神经网络、强化学习、 策略迭代	矿浆液位、进料流量	

续表 5

分类指标	文献	运行指标	优化算法	优化设定值	特点
多目标 优化	[92]	精矿品位	NSGA-II	研磨细度	解决多个目标之间存在相互作用甚至矛盾时的优化问题,不易陷入局部最优,但计算量大,导致成本增加
		回收率		捕收剂用量	
	[93]	精矿品位	二进制编码的 NSGA-II	浮选油用量	
		回收率		多级浮选槽精矿比例	
	[6]	精矿品位	多目标优化萤火虫算法	多级浮选槽尾矿比例	
		尾矿品位		浮选时间	
回收率	捕收剂	抑制剂	空气流量		

## 5 结论

针对矿物浮选过程,本文概述了其在建模、控制、优化方法方面的发展,可以看出浮选过程中的相关设备、控制理论、控制方法等在过去数十年来取得了长足的进展。

1) 建模方法. 在工业浮选中,存在矿浆品位、回收率、浮选药剂、浮选槽液位以及经济成本等泡沫浮选过程的关键技术指标,但是通过离线检测通常需要较长时间,导致调节滞后. 随着数据驱动以及计算机技术的广泛应用,建立准确的浮选过程相关指标的预测模型,对实现浮选过程的优化控制起到重要作用. 泡沫浮选中,泡沫视频等输入数据的采样率大大高于使用特殊检测设备获得的标记品位数据,采样率的不同会导致一些数据未被标记,但是这些未匹配时间序列数据也可以反映品位等的变化趋势. 如何解决时间序列不匹配问题以提高建模精度仍是未来值得深入探究的一个问题。

2) 控制方法. 通过合适的控制方法,可以提高控制性能,达到最大化收益,最小化成本的目的,并将节约巨大的资源. 目前已经产生了多种控制方法,从有模型到无模型,从基于经验到自主探索,从人工观察到使用计算机视觉,都标志着浮选控制领域的进一步完善. 良好的控制策略包括整个过程的生产和业务部分,也即全流程控制,此外,强化学习或深度学习在数据处理及智能性上有着传统控制方法难以达到的优势,这可能是未来的方向,同时存在着巨大的挑战。

3) 优化方法. 目前的主流技术已经从早年的传统方法、单目标优化向着机器学习方法、多目标优化的方向转变. 该领域的重大改进与视频处理和计

算机支持技术的突破、软计算方法的利用以及其他方面的进展有关. 针对日益复杂的工业要求和浮选对象动态变化的特点,基于动态多目标优化的多设定值实时计算与即时跟踪控制尤为重要. 考虑到浮选过程控制领域的新思路、新途径越来越多地出现,以上方面在未来仍存在很大的发展空间。

## 参考文献:

- [1] United States Geological Survey. Mineral commodity summaries 2021 [R/OL] [2022-08-27]. <http://pubs.er.usgs.gov/publication/mcs2021>.
- [2] 中华人民共和国自然资源部. 中国矿产资源报告 2021 [R/OL] [2022-08-27]. [https://m.mnr.gov.cn/sj/sjfw/kc\\_19263/zgkczybg/202111/P020211105382622991767.pdf](https://m.mnr.gov.cn/sj/sjfw/kc_19263/zgkczybg/202111/P020211105382622991767.pdf).
- [3] NASSERI S, KHALESİ M R, RAMEZANI A, et al. An adaptive decoupling control design for flotation column: a comparative study against model predictive control [J/OL]. IETE Journal of Research, 2020; 1-14 [2022-08-27]. <https://doi.org/10.1080/03772063.2020.1785340>.
- [4] 姜艺, 范家璐, 贾瑶, 等. 数据驱动的浮选过程运行反馈解耦控制方法[J]. 自动化学报, 2019, 45(4): 759-770.  
JIANG Y, FAN J L, JIA Y, et al. Data-driven flotation process operational feedback decoupling control [J]. Acta Automatica Sinica, 2019, 45(4): 759-770. (in Chinese)
- [5] 范家璐, 张也维, 柴天佑. 一类工业过程运行反馈优化控制方法[J]. 自动化学报, 2015, 41(10): 1754-1761.  
FAN J L, ZHANG Y W, CHAI T Y. Optimal operational feedback control for a class of industrial processes [J]. Acta Automatica Sinica, 2015, 41(10): 1754-1761. (in



- Chinese)
- [6] BARROZO M A S, LOBATO F S. Multi-objective optimization of column flotation of an igneous phosphate ore [J]. *International Journal of Mineral Processing*, 2016, 146: 82-89.
- [7] YU G, CHAI T, LUO X. Multiobjective production planning optimization using hybrid evolutionary algorithms for mineral processing [J]. *IEEE Transactions on Evolutionary Computation*, 2011, 15(4): 487-514.
- [8] ZHANG H, TANG Z, XIE Y, et al. Grouped time series networks for grade monitoring of zinc tailings with multisource features [J/OL]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 2512511 [2022-08-27]. <https://doi.org/10.1080/10.1109/TIM.2021.3103572>.
- [9] WANG K, PANG L, LI X, et al. An improved RNN modeling algorithm for flotation process of copper-silver ore [C] // *The 34th Chinese Control and Decision Conference*. Piscataway: IEEE, 2022: 5232-5237.
- [10] WANG W, BERGHOLM F, YANG B. Froth delineation based on image classification[J]. *Minerals Engineering*, 2003, 16(11): 1183-1192.
- [11] CEN L, WU Y, HU J, et al. Application of density-based clustering algorithm and capsule network to performance monitoring of antimony flotation process [J/OL]. *Minerals Engineering*, 2022, 184: 107603 [2022-08-27]. <https://doi.org/10.1016/j.mineng.2022.107603>.
- [12] FORTUNA J, CAPSON D. Improved support vector classification using PCA and ICA feature space modification[J]. *Pattern Recognition*, 2004, 37(6): 1117-1129.
- [13] 任会峰, 阳春华, 周璇, 等. 基于泡沫图像特征加权 SVM 的浮选工况识别[J]. *浙江大学学报(工学版)*, 2011, 45(12): 2115-2119.
- REN H F, YANG C H, ZHOU X, et al. Froth image feature weighted SVM based working condition recognition for flotation process [J]. *Journal of Zhejiang University (Engineering Science)*, 2011, 45(12): 2115-2119. (in Chinese)
- [14] 阳春华, 任会峰, 桂卫华, 等. 基于泡沫纹理信度分配 SVM 的矿物浮选工况识别[J]. *仪器仪表学报*, 2011, 32(10): 2205-2209.
- YANG C H, REN H F, GUI W H, et al. Performance recognition using texture credit distributed SVM for froth flotation process [J]. *Chinese Journal of Scientific Instrument*, 2011, 32(10): 2205-2209. (in Chinese)
- [15] ZARIE M, JAHEDSARAVANI A, MASSINAEI M. Flotation froth image classification using convolutional neural networks [J/OL]. *Minerals Engineering*, 2020, 155: 106443 [2022-08-27]. <https://doi.org/10.1016/j.mineng.2020.106443>.
- [16] FU Y, ALDRICH C. Flotation froth image recognition with convolutional neural networks [J]. *Minerals Engineering*, 2019, 132: 183-190.
- [17] 保江, 谢永芳, 刘金平, 等. 基于复原图像特征与深度视觉特征融合的铋粗选异常工况识别[J]. *控制理论与应用*, 2020, 37(6): 1207-1217.
- BAO J, XIE Y F, LIU J P, et al. Fault condition recognition based on restored image features and deep visual features [J]. *Control Theory and Applications*, 2020, 37(6): 1207-1217. (in Chinese)
- [18] 陈青, 朱俊宇, 唐朝晖, 等. 动态纹理建模在硫浮选工况的识别分析[J]. *计算机与应用化学*, 2013, 30(10): 1117-1121.
- CHEN Q, ZHU J Y, TANG Z H, et al. Flotation state classification applying dynamic textures analysis [J]. *Computers and Applied Chemistry*, 2013, 30(10): 1117-1121. (in Chinese)
- [19] TIAN C, TANG Z, ZHANG H, et al. Operating condition recognition in zinc flotation using statistic and temporal correlation features [J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-12.
- [20] 刘美丽, 唐朝晖, 王晓丽, 等. 基于多信息融合与可拓理论的铋浮选工况识别方法[J]. *中南大学学报(自然科学版)*, 2015, 46(12): 4512-4519.
- LIU M L, TANG Z H, WANG X L, et al. Performance recognition of antimony flotation based on multi-information fusion and extension theory [J]. *Journal of Central South University (Science and Technology)*, 2015, 46(12): 4512-4520. (in Chinese)
- [21] 卢明, 谢永芳, 彭涛, 等. 局部颜色特征与工艺参数融合的铜浮选入矿类型识别[J]. *控制理论与应用*, 2014, 31(10): 1360-1367.
- LU M, XIE Y F, PENG T, et al. Identification of type of copper flotation feeding ore using fusion information of local color features and process parameters [J]. *Control Theory and Applications*, 2014, 31(10): 1360-1367. (in Chinese)
- [22] CAO W, WANG R, FAN M, et al. A new froth image

- classification method based on the MRMR-SSGMM hybrid model for recognition of reagent dosage condition in the coal flotation process [J]. *Applied Intelligence*, 2022, 52(1): 732-752.
- [23] ZHU J, WANG Y K. Application of image recognition system in flotation process [C] // *Proceedings of the 7th World Congress on Intelligent Control and Automation*. Piscataway: IEEE, 2008: 655-659.
- [24] ZHANG J, TANG Z, XIE Y, et al. Data-driven adaptive modeling method for industrial processes and its application in flotation reagent control [J]. *ISA Transactions*, 2021, 108: 305-316.
- [25] YAN H, WANG F, HE D, et al. An operational adjustment framework for a complex industrial process based on hybrid Bayesian network [J]. *IEEE Transactions on Automation Science and Engineering*, 2020, 17(4): 1699-1710.
- [26] YAN H, WANG F, HE D, et al. Bayesian network-based modeling and operational adjustment of plantwide flotation industrial process [J]. *Industrial & Engineering Chemistry Research*, 2020, 59(5): 2025-2035.
- [27] YAN H, WANG Q, WANG Z, et al. Estimation of copper concentrate grade for copper flotation [C/OL] // *The 5th IFAC Workshop on Mining, Mineral and Metal Processing*. Amsterdam: Elsevier, 2018, 51(21): 94-98 [2022-08-27]. <https://doi.org/10.1016/j.ifacol.2018.09.398>.
- [28] 马恩杰,白锐,柴天佑. 基于加权支持向量机的选矿生产指标预报模型 [J]. *系统仿真学报*, 2008(8): 2220-2223, 2227.  
MA E J, BAI R, CHAI T Y. Prediction model for production index of mineral process based on weighted support vector machine [J]. *Journal of System Simulation*, 2008, 20(8): 2220-2223, 2227. (in Chinese)
- [29] 周开军,阳春华,牟学民,等. 基于泡沫特征与 LS-SVM 的浮选回收率预测 [J]. *仪器仪表学报*, 2009, 30(6): 1295-1300.  
ZHOU K J, YANG C H, MOU X M, et al. Flotation recovery prediction based on froth features and LS-SVM [J]. *Chinese Journal of Scientific Instrument*, 2009, 30(6): 1295-1300. (in Chinese)
- [30] 黄佳炜,林俊. 基于泡沫图像处理的精矿品位预测 [D]. 长沙: 湖南师范大学, 2021: 21-37.  
HUANG J W, LIN J. Prediction of concentrate grade based on foam image processing [D]. Changsha: Hunan Normal University, 2021: 21-37. (in Chinese)
- [31] 吴佳,谢永芳,阳春华,等. 基于泡沫图像特征的金锑浮选入矿品位估计 [J]. *控制理论与应用*, 2015, 32(2): 262-266.  
WU J, XIE Y F, YANG C H, et al. Mineral concentration estimation of feed ore in gold and stibium flotation based on froth image features [J]. *Control Theory and Applications*, 2015, 32(2): 262-266. (in Chinese)
- [32] POPLI K, AFACAN A, LIU Q, et al. Development of online soft sensors and dynamic fundamental model-based process monitoring for complex sulfide ore flotation [J]. *Minerals Engineering*, 2018, 124: 10-27.
- [33] 杨新,张陶红,余刚,等. 基于 ANFIS 的选矿产品成本预测模型 [J]. *系统仿真学报*, 2007, 19(24): 5688-5691.  
YANG X, ZHANG T H, YU G, et al. Mineral processing product cost forecasting model based on ANFIS [J]. *Journal of System Simulation*, 2007, 19(24): 5688-5691. (in Chinese)
- [34] 杨刚,王建民. 基于 GRA-GS BP 选矿成本预测的研究 [J]. *中国钨业*, 2017, 32(3): 71-78.  
YANG G, WANG J M. Research on cost prediction based on GRA-GS BP beneficiation [J]. *China Tungsten Industry*, 2017, 32(3): 71-78. (in Chinese)
- [35] 桂卫华,陈志鹏,何明芳,等. 基于相关向量机的硫泡沫浮选液位软测量 [J]. *控制工程*, 2014, 21(1): 1-4.  
GUI W H, CHEN Z P, HE M F, et al. Soft sensor of sulfur flotation froth level based on relevance vector machine [J]. *Control Engineering of China*, 2014, 21(1): 1-4. (in Chinese)
- [36] TRONCOSO G C, SUAREZ S A. Pulp level control of a flotation circuit using a model predictive control strategy [J]. *Revista Iberoamericana De Automatica E Informatica Industrial*, 2017, 14(3): 234-245.
- [37] 王玉昆,党金梗. 基于 KPCA 与 ILSFA-LSSVM 的浮选加药控制模型 [J]. *控制工程*, 2017, 24(2): 326-330.  
WANG Y K, DANG J G. Flotation dosing control model based on KPCA and ILSFA-LSSVM [J]. *Control Engineering of China*, 2017, 24(2): 326-330. (in Chinese)
- [38] HORN Z C, AURET L, MCCOY J T, et al. Performance of convolutional neural networks for feature extraction in

- froth flotation sensing [C/OL] // The 20th World Congress of the International Federation of Automatic Control. Amsterdam: Elsevier, 2017, 50(2): 13-18 [2022-08-27]. <https://www.sciencedirect.com/science/article/pii/S2405896317335346>.
- [39] FU Y, ALDRICH C. Froth image analysis by use of transfer learning and convolutional neural networks[J]. *Minerals Engineering*, 2018, 115: 68-78.
- [40] ZHANG J, TANG Z, XIE Y, et al. Convolutional memory network-based flotation performance monitoring [J/OL]. *Minerals Engineering*, 2020, 151: 106332 [2022-08-27]. <https://doi.org/10.1016/j.mineng.2020.106332>.
- [41] WEN Z, ZHOU C, PAN J, et al. Deep learning-based ash content prediction of coal flotation concentrate using convolutional neural network [J/OL]. *Minerals Engineering*, 2021, 174: 107251 [2022-08-27]. <https://doi.org/10.1016/j.mineng.2021.107251>.
- [42] PU Y, SZMIGIEL A, CHEN J, et al. FlotationNet: a hierarchical deep learning network for froth flotation recovery prediction[J]. *Powder Technology*, 2020, 375: 317-326.
- [43] AI M, XIE Y, TANG Z, et al. Two-stream deep feature-based froth flotation monitoring using visual attention clues[J/OL]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 9502114 [2022-08-27]. <https://doi.org/10.1016/10.1109/TIM.2020.3026456>.
- [44] ZHANG H, TANG Z, XIE Y, et al. Grade prediction of zinc tailings using an encoder-decoder model in froth flotation [J/OL]. *Minerals Engineering*, 2021, 172: 107173 [2022-08-27]. <https://doi.org/10.1016/j.mineng.2021.107173>.
- [45] ZHANG H, TANG Z, XIE Y, et al. Long short-term memory-based grade monitoring in froth flotation using a froth video sequence [J/OL]. *Minerals Engineering*, 2021, 160: 106677 [2022-08-27]. <https://doi.org/10.1016/j.mineng.2020.106677>.
- [46] ZHANG H, TANG Z, XIE Y, et al. Feature reconstruction-regression network: a light-weight deep neural network for performance monitoring in the froth flotation [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(12): 8406-8417.
- [47] ZHANG H, TANG Z, XIE Y, et al. Siamese time series and difference networks for performance monitoring in the froth flotation process [J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(4): 2539-2549.
- [48] 曹斌芳, 谢永芳, 阳春华, 等. 基于多源数据的铝土矿浮选生产指标集成建模方法[J]. *控制理论与应用*, 2014, 31(9): 1252-1261.
- CAO B F, XIE Y F, YANG C H, et al. Integrated modeling for production index of bauxite flotation based on multi-source data[J]. *Control Theory and Applications*, 2014, 31(9): 1252-1261. (in Chinese)
- [49] 李启福, 王雅琳. 铝土矿泡沫浮选过程精矿品位预测模型的研究[D]. 长沙: 中南大学, 2012: 38-49.
- LI Q F, WANG Y L. Modeling for the prediction of the concentrate grade in bauxite froth flotation process[D]. Changsha: Central South University, 2012: 38-49. (in Chinese)
- [50] SUN B, YANG W, HE M, et al. An integrated multi-mode model of froth flotation cell based on fusion of flotation kinetics and froth image features [J/OL]. *Minerals Engineering*, 2021, 172: 107169 [2022-08-27]. <https://doi.org/10.1016/j.mineng.2021.107169>.
- [51] QUINTANILLA P, NEETHLING S J, BRITO-PARADA P R. Modelling for froth flotation control: a review[J/OL]. *Minerals Engineering*, 2021, 162: 106718 [2022-08-27]. <https://doi.org/10.1016/j.mineng.2020.106718>.
- [52] 席裕庚, 李德伟, 林妹. 模型预测控制——现状与挑战[J]. *自动化学报*, 2013, 39(3): 222-236.
- XI Y G, LI D W, LIN S. Model predictive control-status and challenges [J]. *Acta Automatica Sinica*, 2013, 39(3): 222-236. (in Chinese)
- [53] MAYNE D Q. Model predictive control: recent developments and future promise[J]. *Automatica*, 2014, 50(12): 2967-2986.
- [54] GARCÍA C E, PRETT D M, MORARI M. Model predictive control: theory and practice—a survey [J]. *Automatica*, 1989, 25(3): 335-348.
- [55] BROOKS K S, KOORTS R. Model predictive control of a zinc flotation bank using online X-ray fluorescence analysers[C/OL] // IFAC World Congress. Amsterdam: Elsevier, 2017, 50(1): 10214-10219 [2022-08-27]. <https://doi.org/10.1016/j.ifacol.2017.08.1772>.
- [56] PUTZ E, CIPRIANO A. Hybrid model predictive control for flotation plants[J]. *Minerals Engineering*, 2015, 70: 26-35.



- [57] 闵娟,黄之初. 多变量解耦控制方法[J]. 控制工程, 2005(增刊2): 129-131.  
MIN J, HUANG Z C. Methods of multivariable decoupling control[J]. Control Engineering, 2005(Suppl 2): 129-131. (in Chinese)
- [58] JIANG Y, JIA Y, FAN J, et al. Compensation-signal-based dual-rate operational feedback decoupling control for flotation processes [J]. IEEE Transactions on Industrial Electronics, 2022, 69(8): 8306-8316.
- [59] STENLUND B, MEDVEDEV A. Level control of cascade coupled flotation tanks[J]. Control Engineering Practice, 2002, 10(4): 443-448.
- [60] LI H, CHAI T, FU J, et al. Adaptive decoupling control of pulp levels in flotation cells [J]. Asian Journal of Control, 2013, 15(5): 1434-1447.
- [61] 王丰富, 柴天佑. 自适应模糊控制理论的研究综述 [J]. 控制工程, 2006, 13(3): 193-198.  
WANG Y F, CHAI T Y. Present status and future developments of adaptive fuzzy control [J]. Control Engineering of China, 2006, 13(3): 193-198. (in Chinese)
- [62] ZADEH L A, KLIR G J, YUAN B. Fuzzy sets, fuzzy logic, and fuzzy systems: selected papers [M/OL]. Singapore: World Scientific, 1996: 326-363 [2022-08-27]. [https://www.worldscientific.com/doi/abs/10.1142/9789814261302\\_0021](https://www.worldscientific.com/doi/abs/10.1142/9789814261302_0021).
- [63] SARAVANI A J, MEHRSHAD N, MASSINAEI M. Fuzzy-based modeling and control of an industrial flotation column [J]. Chemical Engineering Communications, 2014, 201(7): 896-908.
- [64] NUÑEZ F, TAPIA L, CIPRIANO A. Hierarchical hybrid fuzzy strategy for column flotation control [J]. Minerals Engineering, 2010, 23(2): 117-124.
- [65] WANG W X, STEPHANSSON O, WAN S C. On-line system setup in a cellar of a flotation plant [C] // 15th International Conference on Pattern Recognition. Piscataway: IEEE, 2000: 791-794.
- [66] MARAIS C, ALDRICH C. Estimation of platinum flotation grades from froth image data [J]. Minerals Engineering, 2011, 24(5): 433-441.
- [67] BONIFAZI G, SERRANTI S, VOLPE F, et al. Characterisation of flotation froth colour and structure by machine vision [J]. Computers & Geosciences, 2001, 27(9): 1111-1117.
- [68] CIPRIANO A, GUARINI M, VIDAL R, et al. A real time visual sensor for supervision of flotation cells [J]. Minerals Engineering, 1998, 11(6): 489-499.
- [69] JAHEDSARAVANI A, MARHABAN M H, MASSINAEI M, et al. Froth-based modeling and control of a batch flotation process [J]. International Journal of Mineral Processing, 2016, 146: 90-96.
- [70] RAMIREZ-BELTRAN N D, JACKSON H. Application of neural networks to chemical process control [J]. Computers & Industrial Engineering, 1999, 37(1/2): 387-390.
- [71] MOHANTY S. Artificial neural network based system identification and model predictive control of a flotation column [J]. Journal of Process Control, 2009, 19(6): 991-999.
- [72] CUBILLOS F A, LIMA E L. Identification and optimizing control of a rougher flotation circuit using an adaptable hybrid-neural model [J]. Minerals Engineering, 1997, 10(7): 707-721.
- [73] AI M, XIE Y, TANG Z, et al. Deep learning feature-based setpoint generation and optimal control for flotation processes [J]. Information Sciences, 2021, 578: 644-658.
- [74] JIANG Y, FAN J, CHAI T, et al. Data-driven flotation industrial process operational optimal control based on reinforcement learning [J]. IEEE Transactions on Industrial Informatics, 2018, 14(5): 1974-1989.
- [75] BELLMAN R. The theory of dynamic programming [J]. Bulletin of the American Mathematical Society, 1954, 60(6): 503-515.
- [76] MALDONADO M, SBARBARO D, LIZAMA E. Optimal control of a rougher flotation process based on dynamic programming [J]. Minerals Engineering, 2007, 20(3): 221-232.
- [77] MALDONADO M, ARAYA R, FINCH J. Optimizing flotation bank performance by recovery profiling [J]. Minerals Engineering, 2011, 24(8): 939-943.
- [78] LI Z, HUANG M, GUI W, et al. Data-driven adaptive optimal control for flotation processes with delayed feedback and disturbance [J/OL]. IEEE Access, 2019, 7: 163138-163149 [2022-08-27]. <https://doi.org/10.1109/ACCESS.2019.2952396>.
- [79] HE M. Data-driven approximated optimal control of sulfur flotation process [J/OL]. Complexity, 2019: 4754508 [2022-08-27]. <https://doi.org/10.1155/2019/4754508>.

- [80] WANG S, REN X, NA J, et al. Extended-state-observer-based funnel control for nonlinear servomechanisms with prescribed tracking performance [J]. *IEEE Transactions on Automation Science and Engineering*, 2017, 14(1): 98-108.
- [81] LI Z, HUANG M, ZHU J, et al. Learning-based adaptive optimal control for flotation processes subject to input constraints [J/OL]. *IEEE Transactions on Control Systems Technology*, 2022; 1-13 [2022-08-27]. <https://doi.org/10.1109/TCST.2022.3171110>.
- [82] KAARTINEN J, HÄTÖNEN J, HYÖTYNIEMI H, et al. Machine-vision-based control of zinc flotation—a case study [J]. *Control Engineering Practice*, 2006, 14(12): 1455-1466.
- [83] AI M, XIE Y, XIE S, et al. Fuzzy association rule-based set-point adaptive optimization and control for the flotation process [J/OL]. *Neural Computing and Applications*, 2020, 32(17): 14019-14029 [2022-08-27]. <https://doi.org/10.1007/s00521-020-04801-1>.
- [84] AI M, XIE Y, XIE S, et al. Data-driven-based adaptive fuzzy neural network control for the antimony flotation plant [J]. *Journal of the Franklin Institute*, 2019, 356(12): 5944-5960.
- [85] LI J, CHAI T, LEWIS F L, et al. Off-policy q-learning: set-point design for optimizing dual-rate rougher flotation operational processes [J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(5): 4092-4102.
- [86] CHAI T, GENG Z-X, YUE H, et al. A hybrid intelligent optimal control method for complex flotation process [J]. *International Journal of Systems Science*, 2009, 40(9): 945-960.
- [87] DONG Z, WANG R, FAN M, et al. Switching and optimizing control for coal flotation process based on a hybrid model [J/OL]. *Plos One*, 2017, 12(10): e0186553 [2022-08-27]. <https://doi.org/10.1371/journal.pone.0186553>.
- [88] ZHANG J, TANG Z, XIE Y, et al. Generative adversarial network-based image-level optimal setpoint calculation for flotation reagents control [J/OL]. *Expert Systems with Applications*, 2022, 197: 116790 [2022-08-27]. <https://doi.org/10.1016/j.eswa.2022.116790>.
- [89] WEI Q, LIU D, SHI G. A novel dual iterative Q-learning method for optimal battery management in smart residential environments [J/OL]. *IEEE Transactions on Industrial Electronics*, 2015, 62(4): 2509-2518 [2022-08-27]. <https://doi.org/10.1109/TIE.2014.2361485>.
- [90] KIUMARSI B, LEWIS P L, JIANG Z P.  $H_\infty$  control of linear discrete-time systems: off-policy reinforcement learning [J]. *Automatica*, 2017, 78: 144-152.
- [91] JIANG Y, FAN J, CHAI T, et al. Dual-rate operational optimal control for flotation industrial process with unknown operational model [J/OL]. *IEEE Transactions on Industrial Electronics*, 2019, 66(6): 4587-4599 [2022-08-27]. <https://doi.org/10.1109/TIE.2018.2856198>.
- [92] ZHANG W, YUAN Q, JIA S, et al. Multi-objective optimization of forth flotation process: an application in gold ore [J/OL]. *Sustainability*, 2021, 13(15): 8314 [2022-08-27]. <https://doi.org/10.3390/su13158314>.
- [93] GURIA C, VERMA M, MEHROTRA S P, et al. Multi-objective optimal synthesis and design of froth flotation circuits for mineral processing, using the jumping gene adaptation of genetic algorithm [J]. *Industrial & Engineering Chemistry Research*, 2005, 44(8): 2621-2633.
- [94] NANDA S J, PANDA G. A survey on nature inspired metaheuristic algorithms for partitional clustering [J]. *Swarm and Evolutionary Computation*, 2014, 16: 1-18.

(责任编辑 郑筱梅)