基于3D点云数据的多槽煤泥浮选泡沫工况识别方法*

李品钰,王然风,付翔,刘洋,张长明,秦新凯,窦治衡

(太原理工大学 矿业工程学院, 山西 太原 030024)

摘要:针对传统二维图像在煤泥浮选泡沫识别中存在空间信息丢失及单槽数据片面性问题,提出一种基于三维点云数据的多槽特征融合方法。该方法通过图漾红外双目FM855-E1工业相机采集浮选机每个浮选槽的泡沫三维点云数据,采用预处理与数据增强技术优化数据集,利用非共享权重的PointNet网络提取各槽高维特征,经多层感知机降维后,通过拼接函数融合为多槽泡沫特征,最终由多层感知机和Softmax函数实现工况类别判定。试验结果表明:多槽网络的分类准确率达94.89%,显著优于其他网络,损失值降低至0.216 9,具有良好的鲁棒性和泛化能力。研究证明,多槽泡沫特征融合显著提升了浮选工况识别精度,为煤泥浮选智能化提供了高可靠性的三维视觉解决方案。

关键词:矿物浮选;计算机视觉;点云数据;多槽浮选泡沫分类网络;PointNet网络

中图分类号:TD94 **文献标识码**:A **文章编号**:1005-2763(2026)01-0246-09

Identification Method of Froth Conditions in the Multi-Cell of Coal Slime Flotation Based on 3D Point Cloud Data

LI Pinyu, *WANG Ranfeng*, *FU Xiang*, *LIU Yang*, *ZHANG Changming*, *QIN Xinkai*, *DOU Zhiheng*

(College of Mining Engineering, Taiyuan University of Technology, Taiyuan, Shanxi 030024, China)

Abstract: Aiming at the problems of spatial information loss in traditional 2D images and the one-sidedness of single-cell data during the identification of coal slime flotation froth, a multi-cell feature fusion method based on 3D point cloud data was proposed. The Percipio Infrared Binocular FM855-E1 industrial camera was used to collect the 3D point cloud data of the froth surfaces from each flotation cell. Preprocessing and data augmentation techniques were adopted to optimize the dataset. A PointNet network with non-shared weights was utilized to extract the high-dimensional features of each cell. After dimensionality reduction by a multi-layer perceptron, these features were fused into multi-cell forth features through a concatenation function. Finally, the working condition categories were determined by a combination of a multi-layer perceptron and the Softmax function. The experimental results show that the classification accuracy of the multi-cell network reaches 94.89%, which is higher than other networks, the loss value is reduced to 0.216 9, with excellent robustness and generalization ability. It is proved that the multi-cell forth feature fusion method can significantly improve the recognition accuracy of flotation conditions, and provide a high-reliability three-dimensional visual solution for the intelligent flotation of coal slime.

Key words: Mineral flotation, Computer vision, Point cloud data, Multi-cell flotation forth classification network, PointNet network

0 引言

泡沫浮选是煤泥浮选中应用最广泛的细粒煤分选方法之一。目前,选煤厂普遍依赖于人工的经验判断来评估浮选泡沫状态及生产工况,但使用人工识别的方式存在耗时长、不稳定等弊端。煤泥浮选智能化开发是提高煤泥浮选效率、促进煤泥浮选发展的重要研究方向[1]。在煤泥浮选的背景下,使用计算机视觉代替人类视觉对浮选泡沫进行判断,能够解决浮选过程中因直观操作造成的生产不稳定、指标波动等问题[2-3]。

目前,针对煤泥浮选智能化的研究多数是采用计算机视觉对浮选泡沫图像进行研究和分析。MOOLMAN D W等[4]使用基于图像颜色分析和

* **收稿日期**:2025-02-09

基金项目:国家自然科学基金项目(52274157);内蒙古自治区重点专项项目(2022EEDSKJXM010);山西省重点研发计划项目(202102100401015)

作者简介:李品钰(1999—),女,山东泰安人,硕士研究生,主要研究方向为矿物加工智能化检测。E-mail:leepinyu@126.com

通信作者:王然风(1970—),男,山西长子人,博士,副教授,主要研究方向为智能化开采与分选。E-mail:wrf197010@126.com

快速傅里叶变换的技术来处理浮选泡沫图像,并从表面泡沫的视觉特征中提取全局特征,结果表明,图像处理系统可以区分较粗糙泡沫中的不同铜含量。HE Mingfang 等[5]提出了一种基于固定核基的非参数核估计方法,构建了基于多项式核的稀疏多核最小二乘支持向量机分类器的正态核与多项式支持向量机分类器的组合,实现了性能分类。桂卫华等[6]通过对浮选泡沫图像进行空间颜色转换后计算颜色共生矩阵,将其归一化后提取特征统计量并设计纹理复杂度,用于描述泡沫纹理状况。KISTNER M 等[7]利用高阶统计规律的基元和复杂多尺度小波表示对泡沫纹理进行建模,并应用于工业铂族金属泡沫浮选和传送带上的煤颗粒等图像数据集识别中,显著提高了识别精度。上述研究都是通过机器学习对浮选泡沫图像进行处理,计算机硬件的进步使得深度学习发展迅速,深度学习算法能够模拟人脑的处理方式,从图像中提取特征。在浮选泡沫图像处理中,卷积神经网络能够直接提取图像特征,与传统的机器学习相比,有更高的准确率[8-9],在图像处理领域占据主导地位。WEN Zhiping 等[10]使用卷积神经网络构建了预测煤浮选精矿灰分的浮选软传感器;FU Y 等[11]使用预训练的神经网络架构从工业图像数据中估算泡沫等级;WANG Xiaoli 等[12]将泡沫图像分割为单个泡沫图像,使用 k-means 聚类分配标签,通过卷积神经网络提取每个气泡图像的像素集特征,再利用加权均值移位算法融合气泡图像的形态特征向量和像素集特征,计算泡沫图像中各种类型气泡的频率,以及形成泡沫图像的气泡频率集。

煤泥浮选泡沫是三维立体物体,存在丰富的空间特征,不同工况下浮选泡沫的体积和起伏状态不同[13]。图像采集过程是将三维空间转换为二维平面图,但在转换过程中丢失了相关三维空间信息,且图像作为二维数据,无法直接提供深度信息,限制其在理解场景的三维结构和空间关系方面的能力。因此,通过图像处理浮选泡沫场景存在局限性,而使用三维点云数据能够得到更全面的空间信息[14]。

针对上述问题,本文提出一种基于 3D 点云数据的煤泥浮选工况识别方法,该方法使用多槽浮选泡沫三维数据,使得提取的泡沫特征更加全面,能更准确地代表整个浮选机状态。首先对浮选泡沫三维模型进行预处理以去除模糊数据,再对正常数据进行数据增强以扩展数据库。随后,点云特征提取单元对每个浮选槽的泡沫三维模型进行特征提取,再将得到的单槽特征融合成全部浮选槽的泡沫特征。最后,使用多层感知机对多槽泡沫特征进行分类,实现对不同工况泡沫的识别与分类。

1 浮选泡沫 3D 点云数据采集系统

点云是一种三维空间中的点的集合,每个点在三维坐标系统中都有唯一的坐标表示,点云数据包括 X、Y、Z 3 个坐标值和颜色、法线坐标等其他信息。点云数据没有固定的网格结构,由许多独立的点组成,具有三维细节表达能力强等优势。将泡沫点云数据表示为 3D 点的集合$\{x_k \mid k=1,\cdots,n\}$,其中每个点 x_k 是其坐标(x,y,z)加上其他的特征通道,泡沫点云数据具有无序性,即点云与图像的像素阵列不同,它是一组没有特定顺序的点;点之间的相互作用,即点云来自具有距离度量的空间,每个点不是孤立的,相邻的点形成了一个有意义的子集;变换不变性,即当点云发生旋转或平移后,其实际意义是不变的。

由于点云数据非结构化的特性,其包含了庞大的信息量,这使得传统算法在处理点云数据时面临巨大的挑战,难以满足实际需求,限制了点云数据在实际中的广泛使用。深度学习模型具有自动学习数据特征的能力,能够从复杂的数据中提取出有用的信息,同时具有较好的泛化能力,能够快速处理大量数据,大大提高了数据处理的效率。浮选泡沫点云数据用于描述煤泥浮选过程中的泡沫分布和表面特性,其数据量庞大且结构复杂,传统算法难以有效处理,因此,使用深度学习模型处理浮选泡沫点云数据是十分有必要的。深度学习模型能够自动提取浮选泡沫点云数据中的关键特征,提高数据处理的效率和精度,为矿物加工领域提供了有力的技术支持。

浮选泡沫点云数据的采集处理系统主要由立体相机、相机支架、数据存储及计算机处理系统组成,如图 1 所示。立体相机选用的是图漾红外双目 FM855-E1 工业相机,该相机属于结构光双目立体相机,此类相机基于光学重构三维模型的原理[15],利用主动视觉的方法获取浮选泡沫的点云数据[16],由红外光发射模组、红外光接收模组、镜头模组和处理芯片组成。红外光发射模组用于发射经过特殊编码的不可见红外光,而红外光接收模组用于接收被测物体反射回来的结构光。镜头模组采用普通 RGB 相机,用于拍摄二维平面图片。处理芯片则计算红外接收模组所获取的信息,得到点云模型。该

相机工作原理是红外发射模组将带有特殊编码的结构光投射到被测三维物体表面,结构光在被测物体表面发生畸变后反射,被红外接收器捕获,处理芯片根据发射端和接收端的信息计算深度信息,获取点云数据。为了保证数据传输的高速传输和重建过程的微小延迟,此相机采用了高速的网络接口技术,能够快速传输数据,实现对浮选泡沫的低延时点云数据获取。

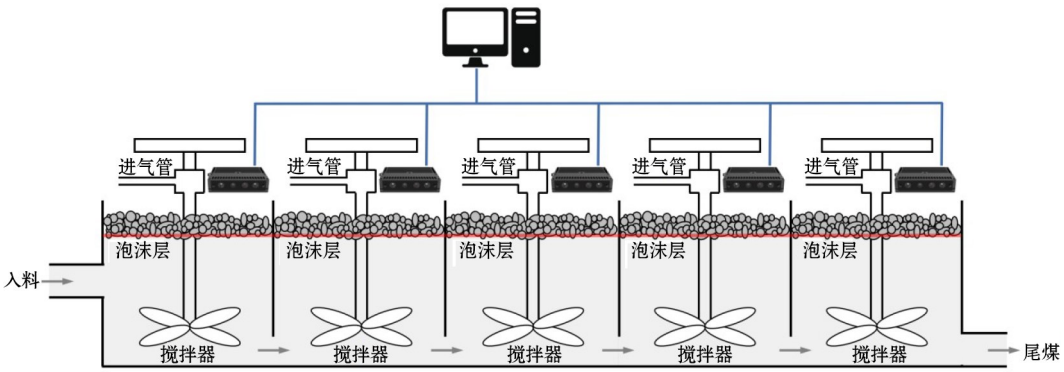


图 1 泡沫点云数据采集系统

Fig.1 Acquisition system for froth point cloud data

2 煤泥浮选泡沫三维模型分类算法

2.1 基于 3D 点云的多槽浮选泡沫分类网络结构设计

在实际生产中,浮选操作员通过观察全部浮选槽[17]的泡沫形态对整台浮选机的生产状况做出判断,单一观察某个浮选槽是片面的,无法反映出整台浮选机的生产状况。因此,使用浮选全部浮选槽的泡沫作为研究对象更为合理。本文设计一个多槽浮选泡沫特征融合的网络,该网络使用 PointNet 网络[18]提取单个浮选槽的泡沫特征,使用特征融合函数将得到的全部单槽特征拼接为多槽泡沫特征,而后送入分类网络进行分类。由于使用浮选机的全流程泡沫点云数据作为输入训练模型,得到的模型能够更精准地评估浮选泡沫的状态,进而优化加药量的调整过程。以五槽浮选机为例,该网络结构如图 2 所示。

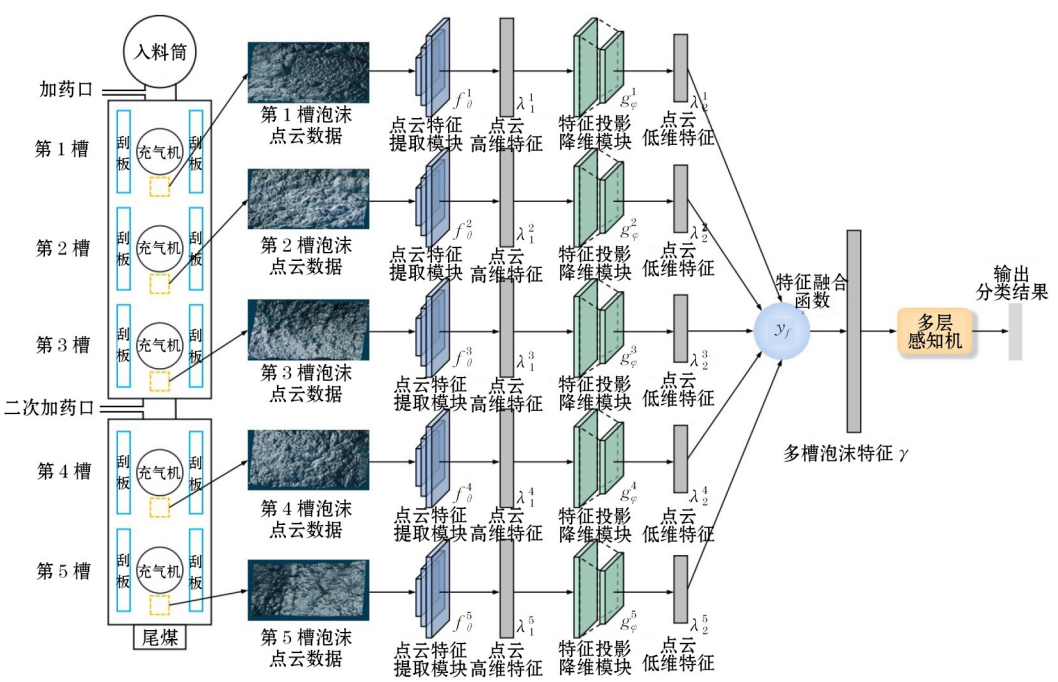


图 2 基于 3D 点云数据的多槽浮选泡沫分类网络结构

Fig.2 Network structure of multi-cell flotation foam classification based on 3D point cloud data

五槽浮选机有 5 个浮选槽,所以该网络由 5 个支路组成,分别提取 5 个浮选槽的点云特征,不同支路对输入点云进行相同操作,但权值不共享,即每个支路的网络参数是不同的。设 f_θ 为点云特征提取模块,该模块使用 PointNet 网络将输入点云进行旋转、升维和池化等操作,得到维度为 1 024 的点云高维特征 $\lambda_1^i, i=1,2,3,4,5$ 为浮选槽数;g_φ 为特征投影降维模块,由一个两层的多层感知机组成,将高维特征投影到 256 维度的投影空间中,它在不变空间中产生一个 256 维的特征投影向量,得到低维点云特征 $\lambda_2^i, i=1,2,3,4,5$ 为浮选槽数;y_f 为特征融合函数,使用特征融合能够丰富模型的表达能力,提高模型的稳定性,特征融合方式有多种,该网络使用拼接方式对点云特征进行融合,y_f 为 CONCAT()拼接函数,使用特征拼接得到一个 1 280 维空间的多槽泡沫特征 γ。最后,通过多层感知机 MLP 和 Softmax 函数对多槽泡沫特征 γ 进行分类,输出分类结果。

2.2 基于 PointNet 网络的点云特征提取模块 f_θ 设计

本文选用 PointNet 网络作为点云特征提取模块,PointNet 网络能够直接处理无序的点云数据,通过对每个点进行编码,学习到全局特征,从而实现对整个点云的理解和处理。它能够保持点云的置换不变性和旋转不变性,使网络在处理不同排列或旋转的点云时能够得到相同的结果。基于 PointNet 网络的浮选泡沫特征提取模块网络结构如图 3 所示。

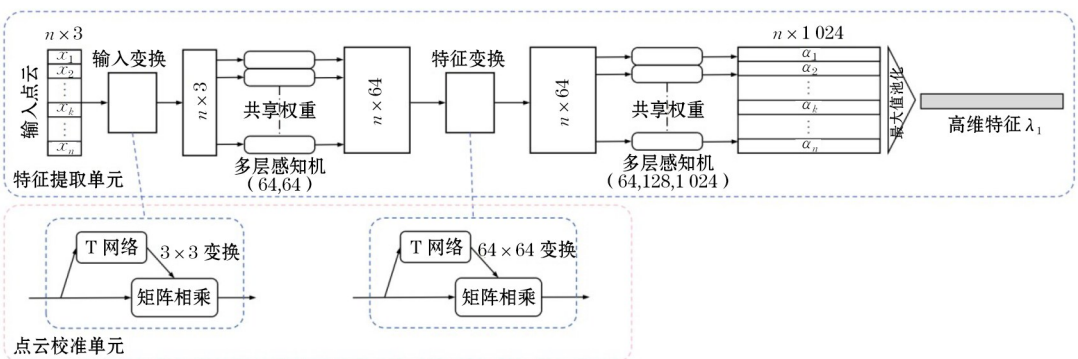


图 3 基于 PointNet 网络的浮选泡沫特征提取模块 f_θ 网络结构

Fig.3 Network structure of flotation froth feature extraction module f_θ based on PointNet network

针对点云的无序性和点之间的相互作用特性,在设计点云特征提取模块 f_θ 时选择对称函数处理输入点云,对称函数的定义如下:

$$f(x_1,x_2,\cdots,x_n)\equiv f(x_{\pi 1},x_{\pi 2},\cdots,x_{\pi n}),x_k=\mathbb{R}^D \tag{1}$$

式中:$x_1,x_2,\cdots,x_n$ 为输入泡沫点云模型的 3D 点;$\mathbb{R}^D$ 表示 D 维实数空间;$f(\ )$为对称函数;$(x_{\pi 1},x_{\pi 2},\cdots,x_{\pi n})$为$(x_1,x_2,\cdots,x_n)$的任意一种不同排列。

由式(1)可知,对称函数的输出值不随输入的排列顺序而改变。常见的对称函数有累加函数等,点云特征提取模块 f_θ 选择的对称函数为最大值函数:

$$f(x_1,x_2,\cdots,x_n)=\max\{x_1,x_2,\cdots,x_n\} \tag{2}$$

仅使用最大值函数处理泡沫点云数据会导致网络学习不够全面,丢失重要信息,因此,基于 PointNet 网络的点云特征提取模块 f_θ 构建高维空间映射网络,将每个 3D 点映射到高维空间后再进行对称函数操作,能够减少损失的特征,使网络更加丰富,增强稳定性。得到的泡沫点云高维特征 $\boldsymbol{\lambda}_1$ 表示为:

$$\boldsymbol{\lambda}_1=\max(h(x_1),\cdots,h(x_n)) \tag{3}$$

式中:$h()$为升维函数,在此模块中使用多层感知机进行升维;max()为最大值函数。

根据点云的变换不变性,点云特征提取模块 f_θ 期望学习到的高维特征不受点云变换的影响。因此,网络引入旋转矩阵,使得所有输入泡沫点云对齐到同一个规范空间。点云特征提取模块 f_θ 通过 T 网络预测仿射变换矩阵,并使用该变换处理输入的泡沫点云模型。同理,网络对升维后的点特征应用另一个对齐网络,并预测一个特征变换矩阵来对齐不同输入的点云升维特征。

由上述可知,点云特征提取器 f_θ 具有两大单元:点云校准单元使用对齐网络用于校准点云方向;特征提取单元使用共享权重的多层感知机将输入点云映射到维数相同的同一特征空间。最大值池化层作为对称函数来聚合所有输入点的信息。将一个泡沫点云数据表示为 3D 点的集合$\{x_k\mid k=1,\cdots,n\}$,

该点云数据共有 n 个点,每个点 x_k 坐标为(x,y,z)。该泡沫点云数据的高维特征表示为 $\boldsymbol{\lambda}_1$:

$$\boldsymbol{\alpha}_k = h_2(\boldsymbol{T}_2 \cdot h_1(\boldsymbol{T}_1 \cdot x_k)) \tag{4}$$

$$\boldsymbol{\lambda}_1 = \max(\boldsymbol{\alpha}_1, \cdots, \boldsymbol{\alpha}_n) \tag{5}$$

式中:$\boldsymbol{T}_1$ 和 $\boldsymbol{T}_2$ 为两个维数不同的仿射变换矩阵,该矩阵通过两个不同的 T 网络训练得到;使用 $h()$升维函数对 x_k 进行两次升维后得到高维点 $\boldsymbol{\alpha}_k$,维度为 1 024。使用 max()最大值函数选出所有高维点 $\boldsymbol{\alpha}_k$ 中每个维度的最大值,从而得到该泡沫点云数据的高维特征 $\boldsymbol{\lambda}_1$,特征维度为 1 024。

2.3 特征投影降维模块 g_φ 设计

在高维度数据上进行计算会加大计算量和内存消耗,增加计算时长,不利于对数据进行实时处理,对高维数据进行降维操作能够减少特征数量,提高算法的运行效率。因此,使用特征投影模块 g_φ 将 1 024维的高维特征 $\boldsymbol{\lambda}_1$ 投影到低维空间中,得到一个 256 维的低维特征 $\boldsymbol{\lambda}_2$:

$$\boldsymbol{\lambda}_2 = g_\varphi(\boldsymbol{\lambda}_1) \tag{6}$$

式中,$g_\varphi()$为两层感知机。该两层感知机由输入层、隐藏层、输出层组成,每一层全连接到下一层,结构如图 4 所示。图 4 左端为输入的高维特征 $\boldsymbol{\lambda}_1$,右端为降维后输出的低维特征 $\boldsymbol{\lambda}_2$。

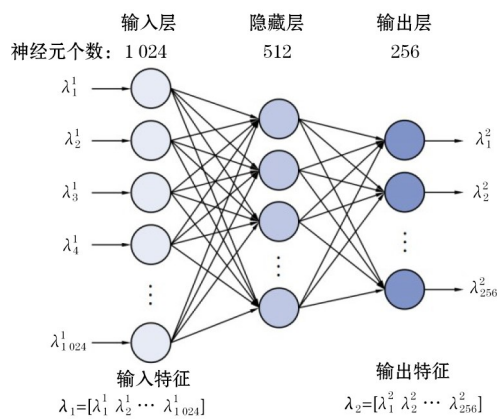


图 4 特征投影模块 g_φ 网络结构

Fig.4 Network structure of feature projection module g_φ

使用特征融合函数 y_f 对降维后的单槽特征 $\boldsymbol{\lambda}_2$ 进行特征融合,得到浮选机的多槽泡沫特征 γ。特征融合方式有多种,本文使用级联操作对单槽特征 $\boldsymbol{\lambda}_2$ 进行融合,y_f 选择 CONCAT()拼接函数,得到浮选机泡沫的多槽泡沫特征 γ 表示如下:

$$\gamma = \mathrm{CONCAT}(\lambda_2^1, \lambda_2^2, \lambda_2^3, \lambda_2^4, \lambda_2^5) \tag{7}$$

式中:$i=1,2,3,4,5$ 为浮选槽的槽数;γ 的特征维数为 $256\times5=1\ 280$。

通过上述计算,得到浮选机的多槽泡沫泡沫特征 γ,γ 包含了每个浮选槽的泡沫特征,与单个浮选槽的泡沫数据相比,浮选机全部浮选槽的泡沫特征蕴含了更为丰富的信息,能够更准确地描绘出当前浮选机的整体泡沫状态,从而使得训练模型学习到更全面的知识,有利于提高模型的准确率,增加模型鲁棒性,并在复杂工况下表现出优异性能。

2.4 分类网络的构建

使用多层感知机和 Softmax 函数对多槽泡沫特征 γ 进行分类。使用多层感知机将多槽泡沫特征映射为分类任务的预测结果,即 1 280 维的多槽泡沫特征经多层感知机后输出为 3 维的分类值向量 $\boldsymbol{z}$。Softmax 函数将分类值向量 $\boldsymbol{z}$ 转换为概率分布,并选取概率值最高的标签作为网络输出结果,实现对泡沫点云模型的分类。图 5 为 Softmax 函数结构,计算公式为:

$$p_i = \frac{\exp(z_i)}{\sum_{j=1}^{3}\exp(z_j)}, i=1,2,3, j=1,2,3 \tag{8}$$

式中:z_i、z_j 为分类值向量 $\boldsymbol{z}$ 的第 i 维值、第 j 维值;p_i 为 Softmax 函数得到的第 i 类的概率值。

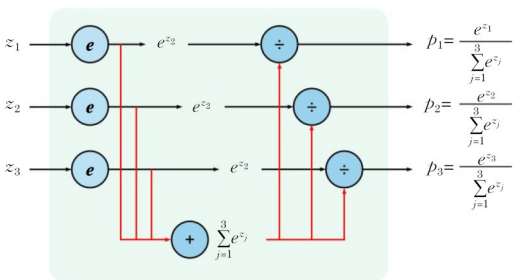


图 5 Softmax 结构

Fig.5 Softmax structure

3 泡沫分类样本获取与模型训练流程

在浮选过程中,药剂量与浮选泡沫的形态密切相关[19]。本研究针对三种工况下的药剂添加量进行数据采集,分别为起泡剂与捕收剂比例正常、捕收剂较多、捕收剂较少,得到三种工况下的泡沫点云模型,如图 6 所示。图 6(a)表示起泡剂和捕收剂比例正常工况的泡沫模型,泡沫处于最佳状态,大小适中且分布均匀,具有较强的稳定性,能够有效地捕获有用煤炭颗粒,提高了有用矿物的回收率。图 6(b)为捕收剂较多工况的泡沫模型,泡沫形态偏小且密集,浮选泡沫流动性差,泡沫中包含了过多的非目标矿物,增加了精矿中的杂质

含量,降低了矿物的品质。图 6(c)为捕收剂添加较少工况的泡沫模型,煤炭颗粒因吸附能力减弱,泡沫含有过多的水分,导致泡沫形态较大且稳定性不足,容易塌陷,浮选泡沫流速增快,精煤回收率下降[20]。

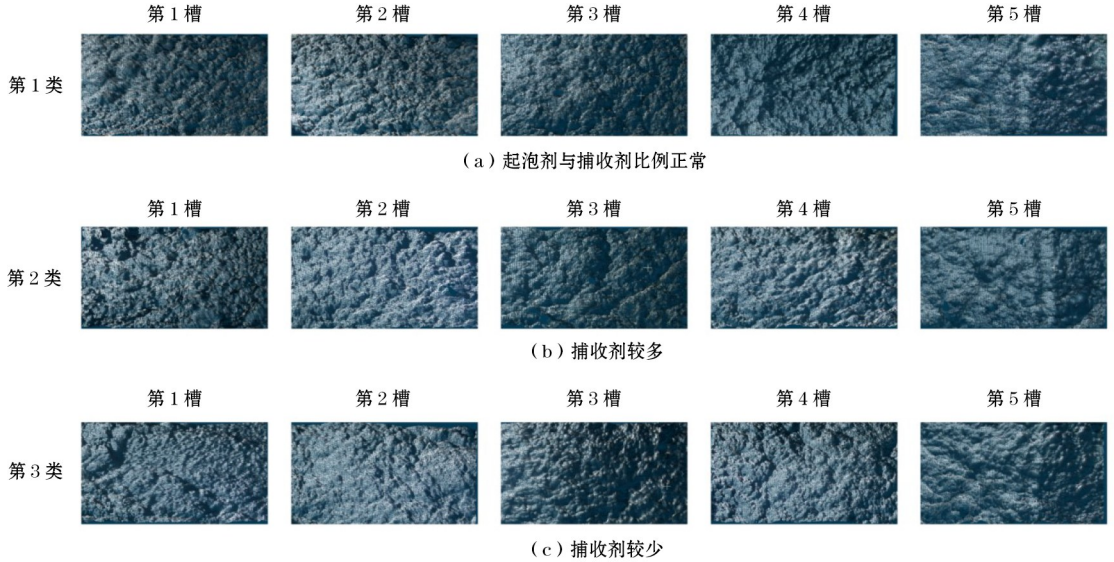


图 6 不同加药比例下的浮选泡沫模型

Fig.6 Flotation froth model under different dosing ratios

由于生产过程中浮选泡沫处于流动状态,采集到的泡沫模型存在边界信息模糊、有噪声点等问题,需要先对原始数据进行预处理,以去除异常三维模型。由于采集数据量有限,对泡沫三维模型进行数据增强能够提高模型的鲁棒性,避免过拟合。因此,对预处理后的数据进行了一系列数据增强操作,包括旋转、移动和缩放。在实际操作中,对每个数据的处理方式都是随机的,并且旋转角度、移动距离、缩放比例都是随机选取的,目的是为了使泡沫模型的差异最大化,得到的扩展数据集更加丰富,使得模型能够在训练过程中获得更好的稳定性和更高的准确性。原始数据集与扩展数据集的数量分布见表 1。

表 1 原始数据集与扩展数据集的泡沫模型数量

Table 1 Number of foam models of the original and extended datasets

数据集	工况	第 1 槽数据量/个	第 2 槽数据量/个	第 3 槽数据量/个	第 4 槽数据量/个	第 5 槽数据量/个
原始数据集	第 1 类	244	207	227	309	275
	第 2 类	205	225	227	309	243
	第 3 类	241	192	268	258	262
扩展数据集	第 1 类	1 944	1 656	1 816	2 472	2 200
	第 2 类	1 640	1 800	1 792	2 472	1 944
	第 3 类	1 928	1 536	2 144	2 064	2 096

考虑到三维模型的数据量庞大,数据存储及计算机处理系统搭建的是 NVIDIA GeForce RTX 3090(GPU 处理器)和 Core i9 12900K(CPU 处理器),在 Windows 11 操作系统上使用 Anaconda 平台构建基于 Python 3.8 的开发环境,实现了数据的高效处理。这一配置确保了整个浮选泡沫三维建模系统可以高效、稳定运行,满足工业级应用的要求。

本文训练模型流程如图 7 所示。

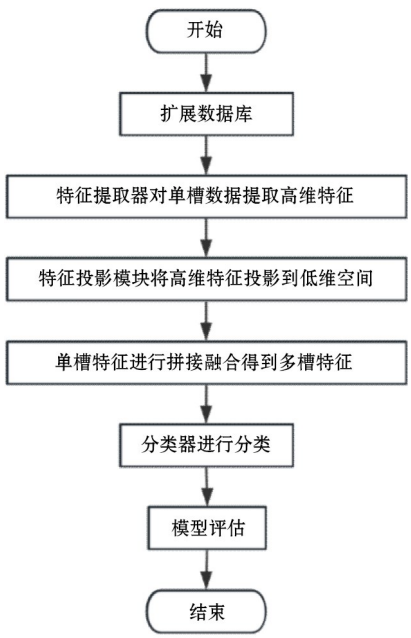


图 7 模型训练流程

Fig.7 Model training process

4 试验结果与分析

以山西太原某选煤厂为研究对象,开展了基于三维点云数据的多槽泡沫网络模型的应用试验与性能评估。该选煤厂选用五槽浮选机进行作业。由于刮板旁挂出的泡沫区域较小,流动速度过快,不易拍摄,而充气机旁的泡沫流速适中且区域较大,故选择充气机旁的泡沫区域作为拍摄区域。浮选过程虽然是动态变化的,但浮选泡沫的流速相对稳定,这意味着工况的转换并不频繁。浮选泡沫的流速通常保持在 0.8~2.4 cm/s 之间,因此选择每 0.5 s 对浮选泡沫采一次样,从而建立泡沫的三维模型数据库。将原始数据库进行数据增强后得到扩展数据库,使用扩展数据库的 80%作为训练集,剩余 20%数据用于测试。本文使用损失值和总体准确率作为评价指标,批量大小为 16,使用 dropout 层减少神经元之间的依赖关系,减少过拟合风险,提高模型的稳定性,将网络进行 100 次迭代后得到浮选泡沫识别模型。

采用对比试验对多槽融合网络进行性能评估,网络一仅使用 PointNet 网络识别单槽浮选泡沫;网络二融合两个浮选槽的泡沫特征进行泡沫识别;网络三则使用 3 个浮选槽的泡沫数据作为输入进行融合和分类。

表 2 列出了网络一、网络二、网络三和多槽分类网络的煤泥浮选泡沫分类准确率。其中,多槽分类网络的准确率达到了 94.89%,相对其他三种网络,准确率分别提高了 27.30,48.14,10.54 个百分点;多槽分类网络的损失值为 0.216 9,相较其他网络的损失值分别降低了 53.98%、65.42%、9.96%。由此可知,多槽分类网络具有稳定的识别能力,网络模型的预测数据与实际数据之间的差距最小。

表 2 不同网络的准确率与损失值

Table 2 Accuracy and loss values of different networks

网络	准确率/%	损失值
网络一	67.59	0.471 3
网络二	46.75	0.627 2
网络三	84.35	0.240 9
多槽分类网络	94.89	0.216 9

为更好地评估各网络性能,本文使用测试集数据绘制混淆矩阵[21],分析 4 种网络在测试集上的浮选泡沫识别结果,得到的混淆矩阵如图 8 所示。

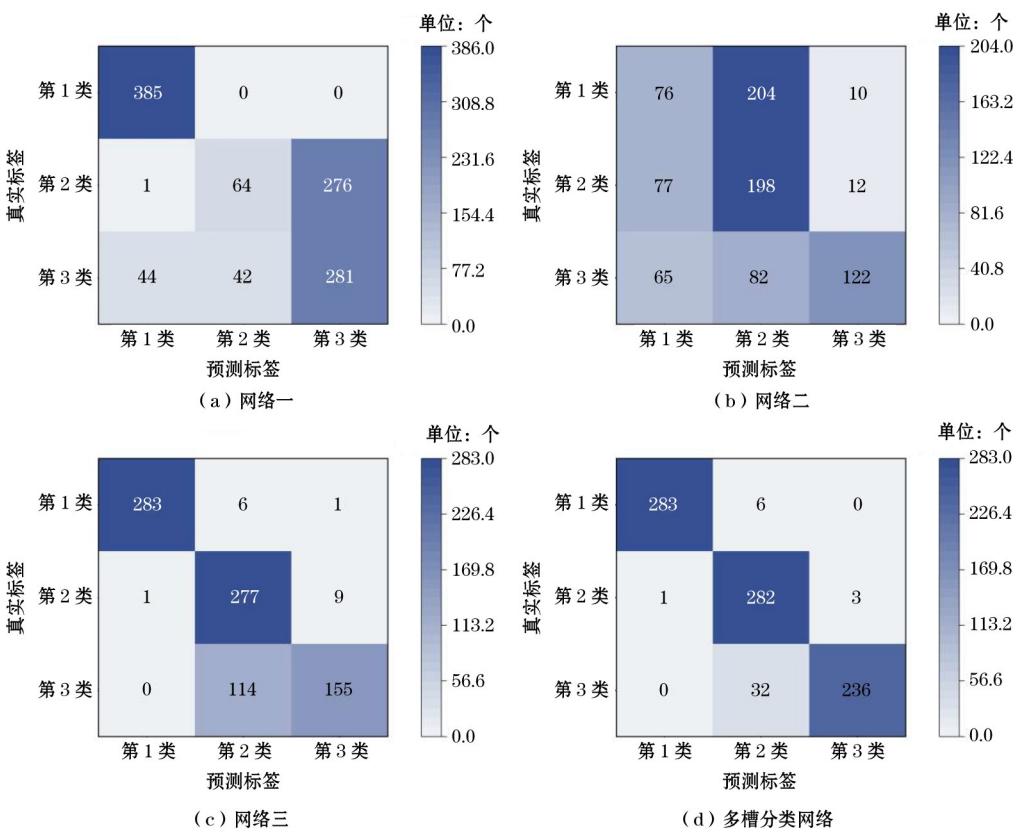


图 8 不同网络的混淆矩阵

Fig.8 Confusion matrices of different networks

由图8可知,网络一有730个泡沫点云模型被成功识别,有363个泡沫点云模型被识别为错误类型,有80.94%的第2类泡沫模型被识别为第3类泡沫模型,这是由于第2类和第3类泡沫模型在形态上较为相似,区分难度较大。网络二有396个泡沫点云模型被成功识别,有450个泡沫点云模型被识别为错误类型,第1类泡沫模型的识别准确率仅为26.21%。网络三有715个泡沫点云模型被成功识别,有131个泡沫点云模型被识别为错误类型,第3类仅有57.62%的泡沫模型识别正确,其余泡沫模型全部被错误识别为第2类。多槽分类网络有801个泡沫点云模型被成功识别,仅42个泡沫点云模型被识别为错误类型,各类泡沫模型的识别准确率极高,其中第3类泡沫模型的识别准确率大幅提升,达到了88.06%。

基于以上分析,可以得出:多槽浮选泡沫分类网络在泡沫点云模型的识别上表现出极高的准确性,远超其他网络。这证明了该网络模型在不同工况下的泡沫识别能力表现良好,具有优异的网络性能,该模型能够适用于浮选过程中泡沫类别的准确识别。

5 结论

(1) 针对煤泥浮选泡沫识别中传统二维图像丢失空间信息、单槽数据表征局限等问题,本文提出了基于三维点云数据的多槽浮选泡沫工况识别方法。该方法通过图漾FM855-E1工业相机采集多槽浮选泡沫点云,构建包含3类典型加药工况的三维泡沫模型数据集,有效保留了泡沫的空间形态与分布特征。

(2) 设计了一种非共享权重的多分支PointNet特征提取网络,分别提取各浮选槽的泡沫高维特征,经多层感知机降维后,通过级联融合生成多槽泡沫特征,最终由分类网络输出工况类别。该结构实现了从局部到全局的特征级融合,增强了模型对整机工况的整体感知能力。

(3) 应用试验结果表明,所提多槽泡沫网络的分类准确率达到94.89%,显著高于其他网络,损失值降至0.216 9,各类别识别准确率均衡且误判率低。模型具有良好的鲁棒性与泛化能力,证明了利用三维点云进行多槽泡沫特征融合在浮选工况识别中的有效性与优越性,可为煤泥浮选过程的智能监控与工况识别提供新的三维视觉解决方案。

参考文献(References):

[1] 周博文,王然风,付翔.基于浮选尾煤图像的灰分检测试验研究[J].矿业研究与开发,2021,41(8):172-177.
ZHOU Bowen, WANG Ranfeng, FU Xiang. Experimental research on ash content detection based on coal flotation tailings images[J]. Mining Research and Development, 2021,41(8):172-177.

[2] 魏凯,王然风,王珺,等.基于质心-凸包-自适应聚类法的浮选泡沫动态特征提取[J].工矿自动化,2024,50(8):151-160.
WEI Kai, WANG Ranfeng, WANG Jun, et al. Dynamic feature extraction for flotation froth based on centroid-convex hull-adaptive clustering[J]. Journal of Mine Automation,2024,50(8):151-160.

[3] 桂卫华,阳春华,徐德刚,等.基于机器视觉的矿物浮选过程监控技术研究进展[J].自动化学报,2013,39(11):1879-1888.
GUI Weihua, YANG Chunhua, XU Degang, et al. Machine-vision-based online measuring and controlling technologies for mineral flotation: a review[J]. Acta Automatica Sinica, 2013,39(11):1879-1888.

[4] MOOLMAN D W, ALDRICH C, VANDEVENTER J S J, et al. Digital image processing as a tool for on-line monitoring of froth in flotation plants[J]. Minerals Engineering, 1994, 7(9):1149-1164.

[5] HE Mingfang, YANG Chunhua, WANG Xiaoli, et al. Nonparametric density estimation of froth colour texture distribution for monitoring sulphur flotation process[J]. Minerals Engineering, 2013, 53:203-212.

[6] 桂卫华,廖茜,阳春华,等.一种新的浮选泡沫图像纹理特征提取方法[J].中国科技论文,2012,7(4):277-281.
GUI Weihua, LIAO Qian, YANG Chunhua, et al. A new texture extraction method for flotation froth images[J]. China Sciencepaper,2012,7(4):277-281.

[7] KISTNER M, JEMWA G T, ALDRICH C. Monitoring of mineral processing systems by using textural image analysis [J]. Minerals Engineering, 2013, 52:169-177.

[8] ZARIE M, JAHEDSARAVANI A, MASSINAEI M. Flotation froth image classification using convolutional neural networks[J]. Minerals Engineering, 2020, 155:106443.

[9] FU Yihao, ALDRICH Chris. Froth image analysis by use of transfer learning and convolutional neural networks[J]. Minerals Engineering, 2018, 115:68-78.

[10] WEN Zhiping, ZHOU Changkui, PAN Jinhe, et al. Deep learning-based ash content prediction of coal flotation concentrate using convolutional neural network[J]. Minerals Engineering, 2021, 174:107251.

[11] FU Y, ALDRICH C. Flotation froth image recognition with convolutional neural networks[J]. Minerals Engineering, 2019, 132:183-190.

[12] WANG Xiaoli, SONG Chen, YANG Chunhua, 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.

[13] ZHANG Jin, TANG Zhaohui, AI Mingxi, et al. Nonlinear modeling of the relationship between reagent dosage and flotation froth surface image by Hammerstein-Wiener model [J]. Minerals Engineering, 2018, 120:19-28.

[14] GUO Yulan, WANG Hanyun, HU Qingyong, et al. Deep learning for 3D point clouds:a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 43 (12):4338-4364.

[15] 卢荣胜,史艳琼,胡海兵.机器人视觉三维成像技术综述[J].激光与光电子学进展,2020,57(4):1-19.
LU Rongsheng, SHI Yanqiong, HU Haibing. Review of three-dimensional imaging techniques for robotic vision[J]. Laser & Optoelectronics Progress,2020, 57(4):1-19.

[16] 李宏伟.结构光三维视觉检测关键技术研究[D].哈尔滨:哈尔滨工程大学,2006.
LI Hongwei. Research on key techniques of structured light 3-D measurement [D]. Harbin: Harbin Engineering University, 2006.

[17] 肖巧斌,曾新民.浅谈硫化铜镍矿选矿厂浮选生产操作[J].矿业工程,2016, 14(5):32-33.
XIAO Qiaobin, ZENG Xinmin. Discussion on industrial production and operation of copper-nickel sulphide ore beneficiation plant[J]. Mining Engineering, 2016, 14(5):32-33.

[18] QI C R, SU H, MO K, et al. Pointnet:deep learning on point sets for 3D classification and segmentation [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York:IEEE,2017:652-660.

[19] 张海洋,王旭,陆博,等.浮选生产过程泡沫状态与药剂控制关系研究[J].黄金,2024,45(3):32-36.
ZHANG Haiyang, WANG Xu, LU Bo, et al. Study on the relationship between froth state and reagent control in flotation operation process[J]. Gold,2024,45(3):32-36.

[20] 曹文艳,王然风,樊民强,等.基于半监督聚类的煤泥浮选泡沫图像分类方法[J].工矿自动化,2019,45(7):38-42+65.
CAO Wenyan, WANG Ranfeng, FAN Minqiang, et al. Coal slime flotation foam image classification method based on semi-supervised clustering [J]. Journal of Mine Automation,2019,45(7):38-42+65.

[21] 张开放,苏华友,窦勇.一种基于混淆矩阵的多分类任务准确率评估新方法[J].计算机工程与科学,2021,43(11):1910-1919.
ZHANG Kaifang, SU Huayou, DOU Yong. A new multi-classification task accuracy evaluation method based on confusion matrix[J]. Computer Engineering & Science, 2021,43(11):1910-1919.