doi：10.3969/j.issn.1005-7854.2022.04.011

基于深度学习的浮选精矿品位预测方法

赵玉华[1,2] 杨文旺[1,2] 武 涛[1,2]
（1. 北矿机电科技有限责任公司，北京 100160；
2. 矿冶科技集团有限公司，北京 100160；）

摘 要：矿浆品位是浮选工艺中关键参数之一，其对于指导生产、节约药剂、控制产品质量和提高回收率等方面都起着非常关键的作用。为了在线预测浮选精矿品位，解决荧光分析仪检测滞后的问题，研究出了一种不需要主观提取特征的基于深度学习的精矿品位在线预测模型，模型的输入为浮选泡沫图像序列、原矿品位值和尾矿品位值，输出为精矿品位值，属于回归问题。对比了主干网络分别为 VGG-16、ResNet-50 和 MobileNet-V2 时预测结果的差异，实验结果显示 VGG-16 的预测精度和鲁棒性最好，平均预测精度达到 12.48%。

关键词：图像序列；深度学习；精矿品位；浮选泡沫
中图分类号：TD952；TP272 **文献标志码：**A **文章编号：**1005-7854(2022)04-0070-06

Prediction method of flotation concentrate grade based on deep learning

ZHAO Yu-hua[1,2] YANG Wen-wang[1,2] WU Tao[1,2]
(1. BGRIMM Machinery and Automation Technology Co. Ltd., Beijing 100160, China;
2. BGRIMM Technology Group, Beijing 100160, China)

Abstract: The pulp grade is one of the key parameters in the flotation process, which plays a key role in guiding production, saving chemicals, controlling product quality and improving recovery. In order to predict the flotation concentrate grade online and solve the problem of the detection lag of the fluorescence analyzer, a deep learning-based online prediction model of concentrate grade without subjective extraction of features is developed. The value and tailings grade value are input, and the output concentrate grade value is a regression problem. Comparing the differences in the prediction results when the backbone network is VGG-16, ResNet-50 and MobileNet-V2, the experimental results show that VGG-16 has the best prediction accuracy and robustness, with an average prediction accuracy of 12.48%.

Key words: image sequence; deep learning; concentrate grade; flotation foam

据相关统计，国内 90%以上的有色金属矿物会采取浮选工艺。由于浮选工艺流程内部耦合度高、时间周期长、浮选结果的影响因素多，在走向自动化、信息化、智能化的道路上仍有巨大的阻力[1]。国内外无数学者尝试搭建出一个完善的数学模型来描述浮选生产流程中复杂的物理化学过程，但是由于各种原因研究进展缓慢。第一，浮选生产过程是一个高度的非线性过程，而对非线性问题的建模理论研究应用于浮选过程效果不好；第二，尽管浮选过程中部分可以进行结构化建模，但是浮选过程整体上还是一个非结构化问题，如果将浮选各环节结构化建模后整合成整体模型，建模效果与实际的浮选生产相差较大并且违反了浮选系统的原理。所以通过“黑箱”建模方法，建立输入与输出之间的数学模型，对浮选生产的信息化和智能化具有重大研究价值。

近年来很多学者致力于在线矿浆品位分析，这对于指导生产、节约药剂、控制产品质量和提高回收率等方面都起着非常关键的作用。M·瓜里尼

收稿日期：2022-03-25
第一作者：赵玉华，高级工程师，主要研究选矿设备的智能化。E-mail：zhaoyuhua@bgrimm.com

等[2]提取颜色特征 B 均值、G 均值、R 均值和 H 均值、S 均值、V 均值、形态特征泡沫尺寸、平均形状系数等，并且将以上特征参数与精矿品位作相关性分析，可以采用浮选泡沫的图像特征参数来作为训练模型的输入数据，从而获得精矿品位预测模型。魏利君提出了多数据相关性分析算法，进行了单一浮选槽的浮选泡沫图像特征与精矿品位的相关性分析，以及多个浮选槽的浮选泡沫图像特征之间的相关性分析，然后使用基于改进粒子群的支持向量机算法来建立精矿品位预测模型[3]。李启福等选取颜色特征、纹理特征、形态特征和速度特征作为训练模型的输入数据，应用滑窗样条偏最小二乘算法建立精矿品位的回归预测模型[4]。

从以上案例不难发现，目前一般的基于机器视觉的精矿品位预测，均是通过研究特定的泡沫图像处理方法提取泡沫表面的一个或者多个视觉特征，进而通过大量的样本统计分析这些视觉特征与精矿品位的相互关系，建立相应的关系模型，建模算法从最初的最小二乘法、相关似然法等经典算法发展到了支持向量机、神经网络等机器学习算法。虽然模型借助机器学习技术实现“黑箱”操作，然而依然需要提取一些主观认为密切相关的视觉特征，比如颜色、纹理、形态、速度等，这些特征是否合理，是否充分，目前没有相关的理论支撑。近年来深度学习技术在各行各业广泛使用，其不需要人为提取特征的优势，给浮选生产的信息化和智能化输入新的血液，本文研究出了一种基于深度学习的浮选精矿品位在线预测模型，模型的输入为浮选泡沫图像序列、原矿品位值和尾矿品位值，输出为精矿品位值，属于回归问题。对比了主干网络分别为 VGG-16、ResNet-50 和 MobileNet-V2 时预测结果的差异，实验结果显示 VGG-16 的预测精度和鲁棒性最好，平均预测精度达到 12.48%。

1 深度学习原理

传统机器学习常通过“特征工程”针对不同任务设计特定特征以实现对数据的特征提取，比如在传统计算机视觉领域，常用全局特征描述子和局部特征描述子对图像进行表示，但是实际工程中的学习任务复杂多变，针对具体任务设计生成特定特征复杂费力且缺乏泛化性和鲁棒性，难以扩展运用于其他任务。深度学习是机器学习的一个分支领域，是从原始数据中自动学习特征表示的一种新方法，强调从连续的层(Layer)中进行学习，这些层的输出对应着越来越有意义、越来越抽象的表示。

深度学习模型每一层对其输入数据所进行的操作保存在该层的权重(Weight)中，其本质是一个向量或多维矩阵。深度学习模型训练过程即为模型每一层找到合适的权重值，使得模型输出与其目标相适应。模型的训练过程由损失函数(Loss function)和优化器(Optimizer)进行控制。损失函数，又称目标函数(Objective function)，其输入是模型预测值与真实目标值，然后计算一个距离值(损失值)用于衡量该模型在样本数据上的效果好坏。优化器基于损失函数计算的损失作为反馈信号对权重进行调整更新，以降低模型预测值与真实目标值的距离。模型训练初始对每一层的权重进行随机赋值，其预测值与真实目标值自然相差甚远，体现在损失值很高。随着训练样本的输入，每一层权重值也逐步的向正确的方向进行调整，同时损失也逐渐降低，即模型的训练过程(见图 1)。

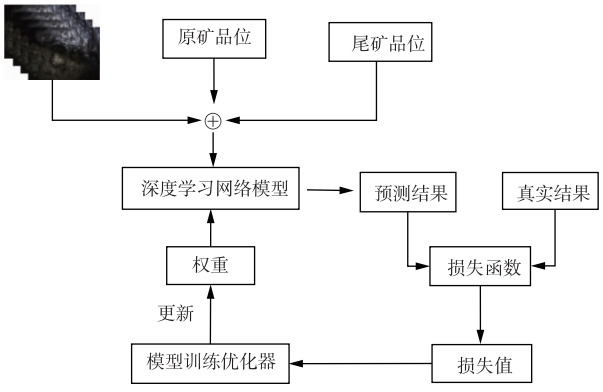

图 1 深度学习模型训练过程

Fig. 1 Deep learning model training process

精矿品位预测要得到的模型是：

f（图像序列，原矿品位，尾矿品位）＝精矿品位

可将其视为单目标回归任务，很多机器学习模型都能解决单目标回归任务，但是由于输入中有图像序列，为了防止参数过大，实验中用到的网络模型是从 CNN 发展出来的 VGG-16[5]网络、ResNet-50[6]网络和 MobileNet-V2[7]网络。

2 数据采集和预处理

德兴铜矿作为我国规模最大的铜矿，多年来在资源综合回收利用方面做了大量有成效的工作，但是受装备技术水平的制约，每年损失在尾矿中的铜

金属仍然有 10%左右。江西铜业股份有限公司与矿冶科技集团有限公司联合开展尾矿再选提升回收率工业试验项目，依托矿冶科技集团有限公司单槽容积为 680 m^3的世界第一大浮选机成套装备技术，在德兴铜矿泗洲选矿厂一期 18 000 t/天磨浮系列生产线建立起工业试验系统。本文的研究工作是在这台 680 m^3浮选机上进行的。

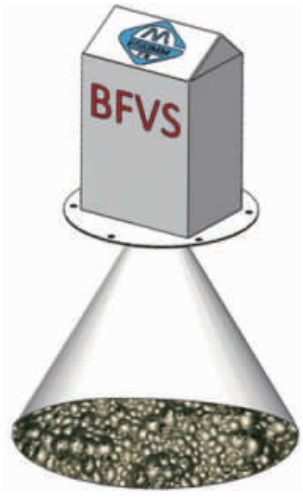

图 2 浮选泡沫图像采集仪

Fig. 2 Flotation froth image acquisition instrument

浮选泡沫图像仪(见图 2)主要由工业 CCD 数码相机、高亮点光源以及几字型支架和保护外罩组成。将泡沫图像仪安装于浮选机溢流堰正上方，通过采集装置内的高清工业照相机将连续的泡沫序列 Images 传输至图像处理工作站，图像的每一个像素的色彩空间为 RGB 空间。

实验中发现采用拍摄的图像序列直接训练模型的收敛速度很慢，预测精度也不高，需要对图片进行了数据预处理与增强，处理过程包括对图像数据进行缩放、对所有数据进行归一化、遮盖无贡献部分图像。

1)图像缩放

为了直接利用预训练模型对任务进行处理，对图像进行缩放以适配预训练网络模型的输入大小，将图像由原来 1 278×958 大小缩放为 224×224，具体的缩放是通过双线性插值来实现的。在数学上，双线性插值是有两个变量的插值函数的线性插值扩展，其核心思想是在两个方向分别进行一次线性插值。

假设已知函数 f 在 $Q_{11}=(x_1,y_1)$,$Q_{12}=(x_1,y_2)$,$Q_{21}=(x_2,y_1)$,$Q_{22}=(x_2,y_2)$ 四个点的值，则点 p 的值可以计算为：

$$f(x,y)\approx\frac{f(Q_{11})}{(x_2-x_1)(y_2-y_1)}(x_2-x)(y_2-y)+\frac{f(Q_{21})}{(x_2-x_1)(y_2-y_1)}(x-x_1)(y_2-y)+\frac{f(Q_{12})}{(x_2-x_1)(y_2-y_1)}(x_2-x)(y-y_1)+\frac{f(Q_{22})}{(x_2-x_1)(y_2-y_1)}(x-x_1)(y-y_1) \tag{1}$$

2)数据归一化

使用 Z-score 标准化的方法对所有数据进行归一化处理，使得经过处理的数据符合标准正态分布，即均值为 0，标准差为 1，转化函数见式(2)。

$$x^*=\frac{x-\mu}{\sigma} \tag{2}$$

式中，μ 为样本数据的均值；σ 为样本数据的标准差。

3)图像遮盖

输入图像如图 3 所示。图像中红线以上图像对结果预测没有帮助，因此，通过掩码设计，对红线以上部分图像进行遮盖。具体来说，直接将上半部分图像像素设置为整幅图像像素值的平均数(式 3)。

$$\mu=\sum_{i=1}^{H}\sum_{j=1}^{W}v_{ij} \tag{3}$$

其中，H 和 W 为图像的高和宽的大小；v_{ij} 为图像中第 i 行第 j 列的像素值。

图 3 图像遮盖

Fig. 3 Image coverage

根据现场荧光取样装置的设置，精矿荧光阀门开启后存储 3 s 75 帧的图像，精矿荧光阀门关闭后读取原矿品位、精矿品位、尾矿品位。

从 75 张图片中随机抽取 25 张作为输入，经过缩放后按照通道维度拼接为 1 张 25×3 通道维度的图像，直接送入预训练模型，预训练模型输出图片序列对应的特征表示向量，最后，拼接原矿、尾矿品位值，送入 3 层全连接网络进行精矿品位回归预测(图 4)。

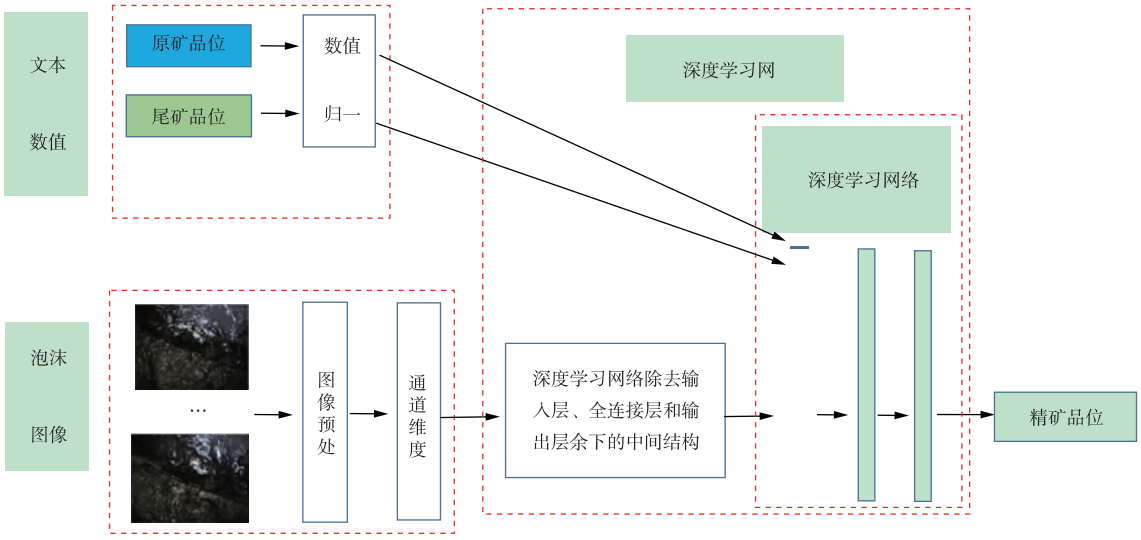

图 4　深度学习模型和数值信息处理

Fig. 4　Deep learning model and numerical information processing

3　实验方法和结果

使用 Python3.8 编程语言、PyTorch1.9.0 深度学习框架，结合 Intel(R) Xeon(R) Gold 5218 CPU @ 2.30GHz 处理器，在 Ubuntu18.04 操作系统下进行实验。使用 Tesla V100 显卡、CUDA11.4 和 cuDNN8.2.2 调用 GPU 进行加速。迭代次数 N 取 150，使用 Adam 梯度下降，学习率取 0.000 1，batch 大小为 96。

实验中共标注了 802 个训练样本，每个训练样本有 75 张图片和 2 个输入标量，随机采样 25 张图片作为训练数据。为进行模型训练与验证，将其按照训练、验证集 8∶2 分配，即：训练集 641 个样本，验证集 161 个样本。

图 5、6 和图 7 分别展示了 VGG-16、ResNet-50 和 MobileNet-V2 在训练过程中，训练、验证损失变化和预测结果与标注值的差值图。从结果上看，三个模型的训练集损失曲线和交叉验证集损失曲线都随着迭代次数增加逐步下降并趋于平缓，但 VGG-16 的 2 个曲线重合度更好，模型的拟合能力更高一些。为了得到更多信息，进一步对数据进行统计分析，得到表 1。表 1 中 R_2 为决定系数，又称拟合优度，其值越大表明自变量对因变量的解释程度越高，模型的鲁棒性也越高。平均绝对误差、均方误差、最大差值都从不同侧面反映出了预测精度，其值越小越好。表 1 再一次证明 VGG-16 在预测精度和鲁棒性上表现都是最好的。

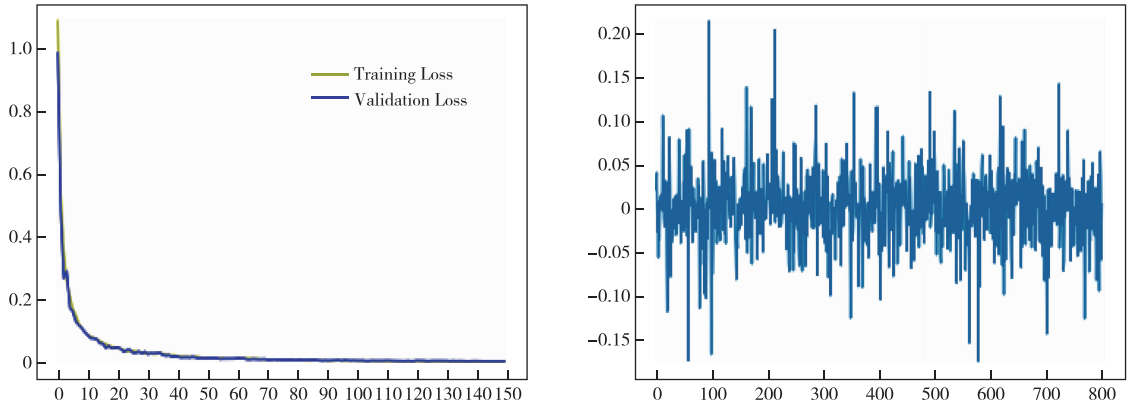

图 5　VGG-16 训练中损失变化和差值图

Fig. 5　Loss Change and difference in vgg-16 training

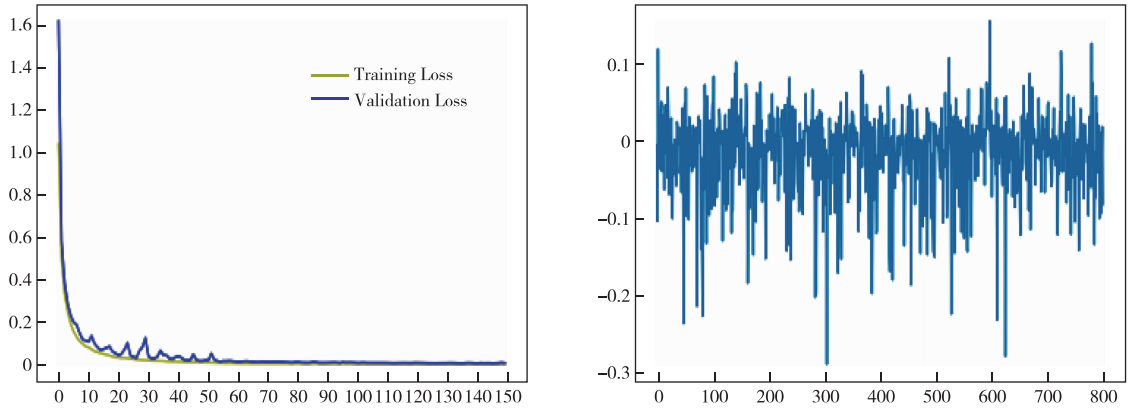

图 6　ResNet-50 训练中损失变化和差值图

Fig. 6　Loss Change and difference in ResNet-50 training

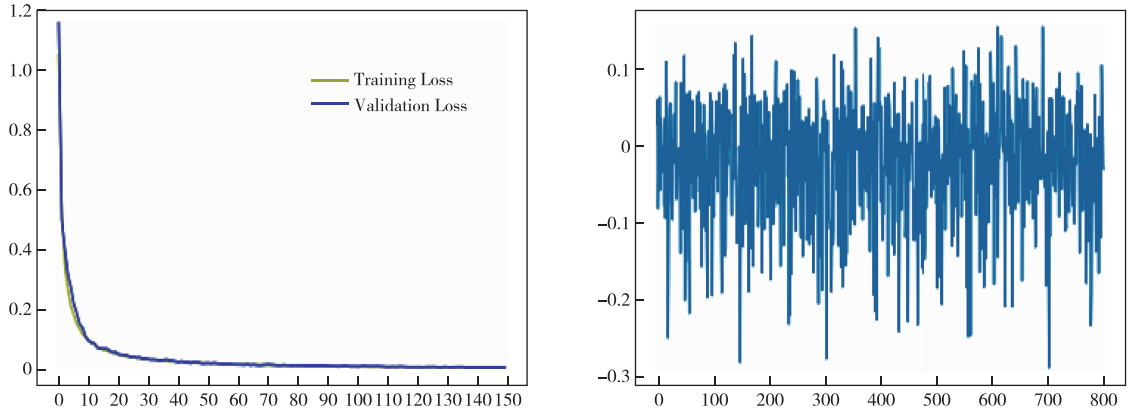

图 7　MobileNet-V2 训练中损失变化和差值图

Fig. 7　Loss Change and difference in MobileNet-V2 training

表 1　精矿品位预测结果的数据分析

Table 1　Data Analysis of concentrate grade prediction results

模型	平均绝对误差	均方误差	R_2决定系数	最大差值	最小差值	平均差值	平均预测精度/%
VGG-16	0.030 9	0.001 8	0.843 1	0.213 1	0.000 0	0.000 5	12.48
Res Net-50	0.039 5	0.003 3	0.713 7	0.288 3	0.000 0	−0.016 7	16.38
Mobile Net-V2	0.077 3	0.009 0	0.220 0	0.295 3	0.000 0	0.021 3	32.56

4　结论

1）一般的基于机器视觉的精矿品位预测，均是通过研究特定的泡沫图像处理方法提取泡沫表面的一个或者多个视觉特征，进而通过大量的样本统计分析这些视觉特征与精矿品位的相互关系，建立相应的关系模型，实际上泡沫图像序列暗含了浮选泡沫的颜色、纹理、速度等信息，加上原矿品位和尾矿品位对信息的补充，借助深度学习技术预测精矿品位是一种行之有效的解决方案。

2）在德兴铜矿尾矿再选的 680 m^3 浮选机上，网络模型 VGG-16 在解决浮选泡沫图像序列精矿品位预测问题上，其预测精度和鲁棒性表现更好。

3）在深度学习的训练过程中，训练数据是很重要的，提高训练样本集的数量，会使预测精度和鲁棒性得到进一步提升。

参考文献

[1]　WATT J S. On-stream analysis of metalliferous ore slurries [J]. International Journal of Applied Radiation & Isotopes, 1983, 34(1): 309-331.

[2]　M·瓜里尼，左焕莹. 图像处理技术用于评估矿物浮选过程的质量[J]. 国外金属矿选矿，1999(12)：38-41.

（下转第 101 页）