

# 基于激光雷达的双通道伪彩图像煤矸识别方法

王言, 邢冀川\*, 王遥志

北京理工大学光电学院, 北京 100081

**摘要** 煤矸石快速精准的识别对提升煤炭产能有着极大的影响,而现有的煤矸识别分选方法在分选设备、准确率以及效率上尚有不足。提出了一种基于深度学习的激光雷达双通道伪彩图像煤矸识别方法。首先,基于激光雷达距离通道信息,设定高度阈值去除目标矿石以外的干扰信息;其次,对原始点云数据降维投影,以快速获得煤矸反射强度信息和表面纹理特征;然后,对降维处理后的强度通道与距离通道进行融合,构建煤矸双通道伪彩图像数据集;在此基础上,针对伪彩数据集对经典稠密连接网络(DenseNet-121)进行优化,利用优化后的 DenseNet-40 网络进行模型训练及测试,测试结果表明:该模型对煤矸的识别率达 94.56%,证明激光雷达采集的双通道伪彩图像在矿石识别领域具有科研和工程应用价值。

**关键词** 煤矸识别; 激光雷达; 双通道图像; 深度学习

中图分类号 TH6; TN958.98

文献标志码 A

DOI: 10.3788/LOP223222

## Coal and Gangue Recognition Method Based on Dual-Channel Pseudocolor Image by Lidar

Wang Yan, Xing Jichuan\*, Wang Yaozhi

School of Optoelectronics, Beijing Institute of Technology, Beijing 100081, China

**Abstract** The recognition accuracy and efficiency of coal and gangue have a great impact on coal-production capacity but the existing recognition and separation methods of these minerals still have deficiencies in terms of separation equipment, accuracy, and efficiency. Herein, a coal and gangue recognition method is presented based on two-channel pseudocolor lidar images and deep learning. Firstly, a height threshold is set to remove the interference information from the target ore based on the lidar distance channel information. Concurrently, the original point-cloud data are projected in a reduced dimension to quickly obtain the reflection intensity information and surface texture features of coal gangue. The intensity and distance channels after dimensional reduction are then fused to construct the dual-channel pseudocolor image dataset for coal and gangue. On this basis, the DenseNet-121 is optimized for the pseudocolor dataset, and the DenseNet-40 network is used for model training and testing. The results show that the recognition accuracy of coal gangue is 94.56%, which proves that the two-channel pseudo-color image acquired by lidar has scientific and engineering value in the field of ore recognition.

**Key words** coal-gangue recognition; lidar; dual channel image; deep learning

## 1 引言

煤炭是中国的重要能源之一,2020年中国煤炭资源的采出量为 $3.84 \times 10^9$  t,位居世界首位<sup>[1-2]</sup>。在煤矿的开采过程中,会开采出大量的固体污染物,其中矸石是最主要的一种,其混杂在煤中会降低煤的燃烧质量,还会加重污染排放。因此,区分煤矸石,尤其是块状的分选尤为重要。

煤与矸石的分选主要有人工方法和机械方法。人工分选具有较高的识别精度,但识别效率较低,且工作现场环境恶劣,易损害操作人员的身心健康<sup>[3]</sup>。机械分选主要有重介质法、跳汰法、风力法以及一些智能化分选方法比如工业相机分选法和射线法,其中传统工业相机成像分选法操作简单、成本较低,但受环境影响较大,对光源的均匀性要求高,后续的区域分割算法处理难度较大<sup>[4-8]</sup>;射线法则不需要额外的可见光源,对

收稿日期: 2022-12-01; 修回日期: 2023-01-03; 录用日期: 2023-02-06; 网络首发日期: 2023-02-16

通信作者: \*michaelhsing@bit.edu.cn

小尺寸(30~100 mm)的煤矸石有良好的识别效果<sup>[9-12]</sup>,但其设备运行需要高压电源,设备昂贵、维护成本高,且射线带来的辐射对操作人员的健康威胁较大,难以应用到实际生产环境中。

如图 1 所示,在实际生产环境中,采集环境较为复杂,分选地点空间狭窄,复杂的采集系统搭建难度较

高;生产过程中煤和矸石会被磕碰产生的细小颗粒或其他无关物体包围,引起煤和矸石的粘连。使用相机作为数据采集设备时,为了保证其采集质量,通常需要建立暗室并配备合适的光源;此外,还需要额外的图像分割算法,其分割质量直接影响后续的识别和分类效果。




图 1 生产环境和工业相机数据示例图。(a)数据采集环境;(b)工业相机采集数据

Fig. 1 Example maps of production environment and industrial camera data. (a) Data collection environment; (b) data acquisition by industrial camera

激光雷达作为一种主动成像设备,不受光源的影响,无需建立一个稳定、均匀的照明环境<sup>[13]</sup>,能够通过点云实时获取待测目标物精确的三维空间信息,其回波强度数据可以反映物体表面的纹理特征,并实现全天时的测量,被广泛应用于地形测绘、环境监测、数字城市建设、自动驾驶以及目标识别等领域<sup>[14]</sup>。2011年,激光雷达的强度信息被用于地质勘探中的岩石分类<sup>[15]</sup>。Lee等<sup>[16]</sup>利用激光雷达进行地层扫描,使用  $k$ -means 和支持向量机(SVM)对回波强度数据进行分类,激光雷达对泥岩和砂岩的检测精度达 90%。赵子默等<sup>[17]</sup>提出利用激光雷达反射强度进行煤矸识别,其识别率达 92.13%。传统的利用激光雷达对煤矸石进行识别,其识别率较低,难以实现精准识别。

近年来,我国数字图像智能识别技术发展迅速,许多新技术应用到煤矸石的分类和识别中。传统的机器视觉分类方法利用如定向梯度直方图(HOG)、尺度不变特征变换(SIFT)、局部二值模式(LBP)等局部特征提取方法,其描述算子生成过程冗长,且难以对图像全部特征进行提取。利用深度学习神经网络,可以通过迭代学习自动选择最佳特征参数,大大提高识别效率和识别精度。Su等<sup>[18]</sup>于 2018 年提出使用深度学习神经网络来对煤矸石图像进行分类。李曼等<sup>[19]</sup>采用 3 种自动阈值分割方法对工业相机采集的煤矸石图像进行二值化处理,并结合灰度、纹理和对比度等特征对分类器进行训练,最终煤和矸石的识别率达到 88.3% 和 90.0%。李鹏祥等<sup>[20]</sup>采用卷积神经网络(CNN)的 X 射线透射选矿系统,识别准确率可达 99.34%。其中,射线法的煤矸识别率已经达到了较高的水平,但射线对工人的身心健康影响较大,且射线系统安装复杂,通

常难以应用到生产线。

煤矸石分选技术对特征提取以及实时性要求较高。提出一种基于激光雷达的双通道伪彩图像识别模型,将煤矸石的强度数据与距离点云数据相融合,经预处理后得到双通道伪彩色图像,可同时反映煤矸石表面反射激光的强度信息、物理轮廓信息和表面纹理信息等特征;避免了传统的工业相机对光源的高要求、低识别率以及射线法中系统安装复杂等问题;对所提的双通道伪彩数据集,网络过深有时会产生过拟合的问题,作为模型压缩的方法之一,模型剪枝技术已被证明是一种有效的方法<sup>[21]</sup>,可在不损失精度的情况下减小模型体积<sup>[22]</sup>。针对激光雷达伪彩数据集,对 DenseNet-121 进行优化,采用优化后的 DenseNet-40 网络构建高效、精确、智能的选矸模型,所述网络训练时间短、识别速度快,能较好地应用于实际生产。

## 2 材料与方法

### 2.1 实验数据采集

本实验的数据采集系统如图 2 所示。为保障采集系统运转的稳定性,降低激光雷达的工作负荷,在传送带两侧安装对射式光电开关,煤矸石随传送带运动触发光电开关,控制激光雷达进行数据采集,得到煤矸石数据。本研究中的双通道伪彩图像数据采集于山东省蒋庄煤矿生产线。

实验环境传送带宽度为 1.2 m,可供安装的高度不得大于 1.5 m,传送带传输速率为 0.3 m/s。针对激光雷达的扫描角度范围、角分辨率、扫描频率来进行选型,结合实际现场情况,采用 SICK 公司的 LMS4000 激光雷达作为本项目采集设备,设备主要参数如表 1 所示。




图 2 采集系统示意图

Fig. 2 Schematic diagram of acquisition system

表 1 LMS4000 参数

Table 1 Parameters of LMS4000

Parameter	Value
Scanning frequency /Hz	600
Laser wavelength /nm	660
Scanning range /( $^{\circ}$ )	70
Angular resolution /( $^{\circ}$ )	0.0833
Working distance /m	0.7-3
Measurement accuracy /mm	$\pm 1$

### 2.2 激光雷达理论分析

本实验将激光雷达强度信息结合距离信息用于煤矸石的识别,激光雷达采集到的距离点云与强度点云示意图,如图 3 所示。




图 3 点云图像。(a)距离点云;(b)强度点云

Fig. 3 Point cloud images. (a) Distance point cloud; (b) intensity point cloud

为了简化模型,目标物可以近似为一个扩展的朗伯反射体。激光雷达的射程方程可表示为

$$P_r = P_e D^2 T^2 \eta_r \eta_t \frac{\rho \cos \theta}{4R^2}, \quad (1)$$

式中: $\rho$ 为目标反射率; $\theta$ 为激光雷达光束发散角; $P_e$ 为激光输出功率; $P_r$ 为接收的激光功率; $\eta_r$ 为发射系统透过率; $\eta_t$ 为接收系统透过率; $D$ 为激光接收系统孔径; $T$ 为大气透过率; $R$ 为距离值。本实验的扫描距离较短,可以忽略大气传输系数,其强度  $I$  可由目标回波的发光功率决定,  $I$  可表示为

$$I = f(P_r), \quad (2)$$

式中: $f(\cdot)$ 为特定的转换函数,用于表示其接收到的功率信号  $P_r$  转换为一个电压信号,然后转换为一个整数校准的过程。强度值通常用接收信号的峰值幅度表示,故  $I$  可表示为

$$I = C P_e D^2 T^2 \eta_r \eta_t \frac{\rho \cos \theta}{4R^2}, \quad (3)$$

式中: $C$ 为常数,表示强度值与接收功率之间的线性关系。实验中激光雷达位置和激光方向固定, $\theta$ 、 $R$ 、 $D$ 为确定值,此时反射强度  $I$  与  $\rho$  呈正相关。煤与矸石不同的反射率可用于煤与矸石的识别。煤、矸石的强度图像如图 4 所示。




图 4 煤与矸石强度图像。(a)煤;(b)矸石

Fig. 4 Image of coal and gangue strength. (a) Coal; (b) gangue

岩石反射率较高,但其表面通常覆盖着泥和煤粉,运输过程中的碰撞会裸出其内部的岩石部分,在图 4(a)中表现为斑点。煤的反射率、表面粗糙程度、含水量不同,在图 4(b)中表现为空洞。二者具有较明显的区分度,这是煤矸石基于深度学习神经网络进行识别分类的基础。

激光雷达一次完整扫描采集的所有距离信息数据点的集合称为距离点云,距离点云即根据目标物反射回的每个点所包含的距离信息和角度信息,再经坐标转换得到其相对真实世界的映射坐标 $(x, y, z)$ 。每个点云坐标绘制在三维坐标中的距离点云示意图,如图 5 所示。




图 5 距离点云示意图

Fig. 5 Example of distance point cloud

图 5 中大体积的矸石显然为识别的主要目标,根据距离信息可以很好地去除目标附近的干扰信息,同时距离信息能很好地描述目标的体积与轮廓信息。

### 2.3 图像处理

激光雷达采集到的原始数据中,含有传送带、碰撞产生的细小颗粒以及煤粉等杂物,且原始的三维点云图数据量大,难以实现快速识别,故需对点云数据进行

预处理,其流程如图 6 所示。

实际生产中,传送带上通常会有许多磕碰产生的细小颗粒,这些细小颗粒会影响识别的效果。对此,利用激光雷达距离通道获取距离信息,首先设置一定高度阈值去除传送带背景,高于传送带一定高度阈值的数据将被保留,而剩余部分将被剔除;然后通过膨胀、腐蚀等形态学方法去除小块矿石等干扰信息,如图 7 所示。

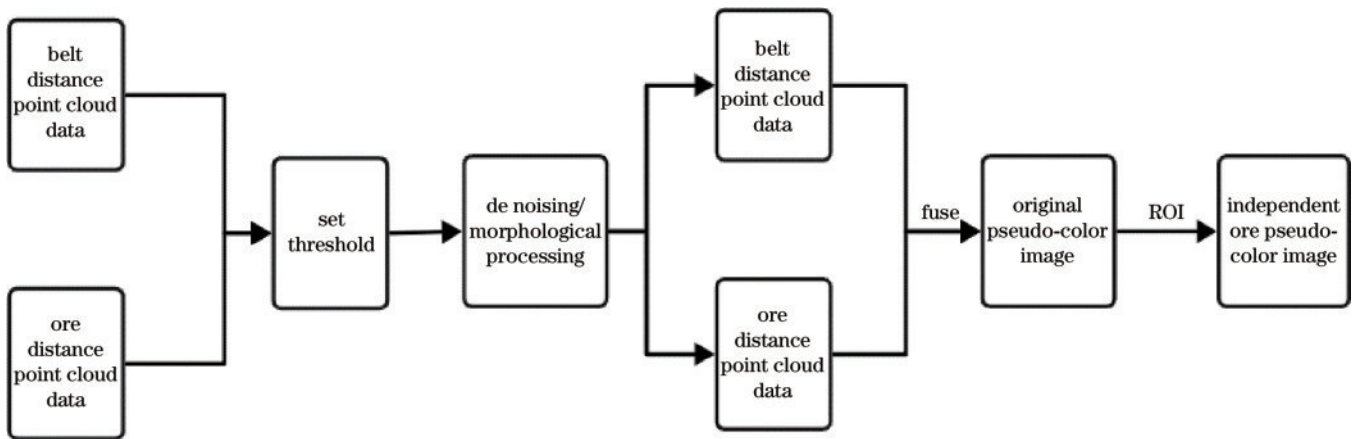


图 6 图像预处理过程

Fig. 6 Process of image preprocessing

去噪后,对双通道信息进行降维投影,融合形成伪彩图像,实际投影效果如图 8 所示。其中,用圆点颜色

表示采集获得的每个点云的强度值,从顶部投影形成强度点云俯视图,忽略每个点之间的空间位置信息,每




图 7 背景去噪。(a)去除前;(b)去除后  
Fig. 7 Background denoising. (a) Before removal; (b) after removal

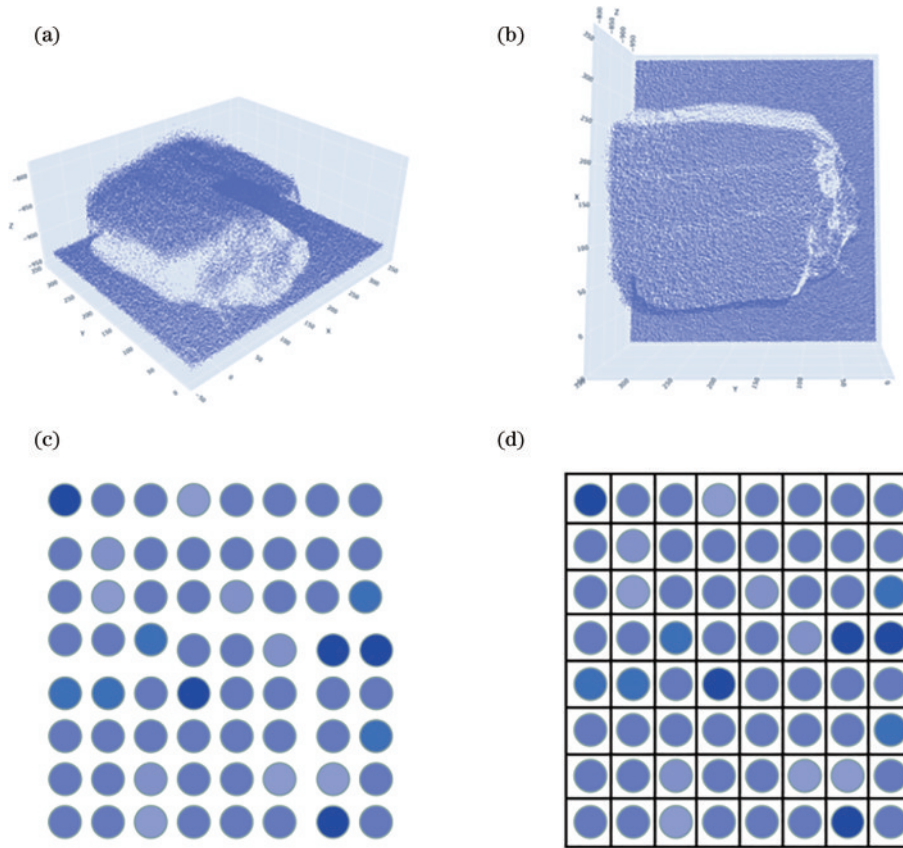


图 8 点云图像生成流程。(a)原始点云图;(b)点云俯视图;(c)真实点云投影图;(d)二维强度像素图像  
Fig. 8 Point cloud image generation process. (a) Original point cloud map; (b) vertical view of point cloud; (c) real point cloud projection; (d) two dimension intensity pixel image

一个点云的强度值分别映射到二维图像中每个像素的像素值,得到反射率图。同理,距离点云值与强度点云值一一对应,可得到距离点云图。此处理方式忽略了每个点的实际空间位置,保留了点与点之间的相对位置,降低数据量的同时,反射强度信息和物体表面体积纹理信息均被保留,以便后续处理。

通过上述处理,可以得到距离点云与强度点云,如图 9 所示。通过原始点云的二维投影得到强度信息矩阵  $C_0$  和距离信息矩阵  $C_1$ 。强度图像只包含强度信息,距离图像只包含距离信息。将  $C_0$  和  $C_1$  进行叠加、融合,得到一个包含距离信息和反射率信息的双通道图

像,如图 9(c) 所示。

### 2.4 神经网络识别模型

近年来,深度学习作为图像处理和自然语言识别的研究热点,深度神经网络尤其是 CNN 在图像分类任务中取得了突破<sup>[23]</sup>。随着研究的深入,网络层数过深会导致误差函数在反向传播过程中出现梯度消失现象<sup>[24]</sup>,使前几层网络层无法完成权重更新,不能精确的学习到图像的特征<sup>[25]</sup>。2016 年 He 等<sup>[26]</sup>在 CNN 的基础上设计了残差神经网络(ResNet),有效地解决了深层 CNN 的梯度消失问题。Huang 等于 2017 年提出的稠密连接网络(DenseNet),是 ResNet 的延伸。与 ResNet 相

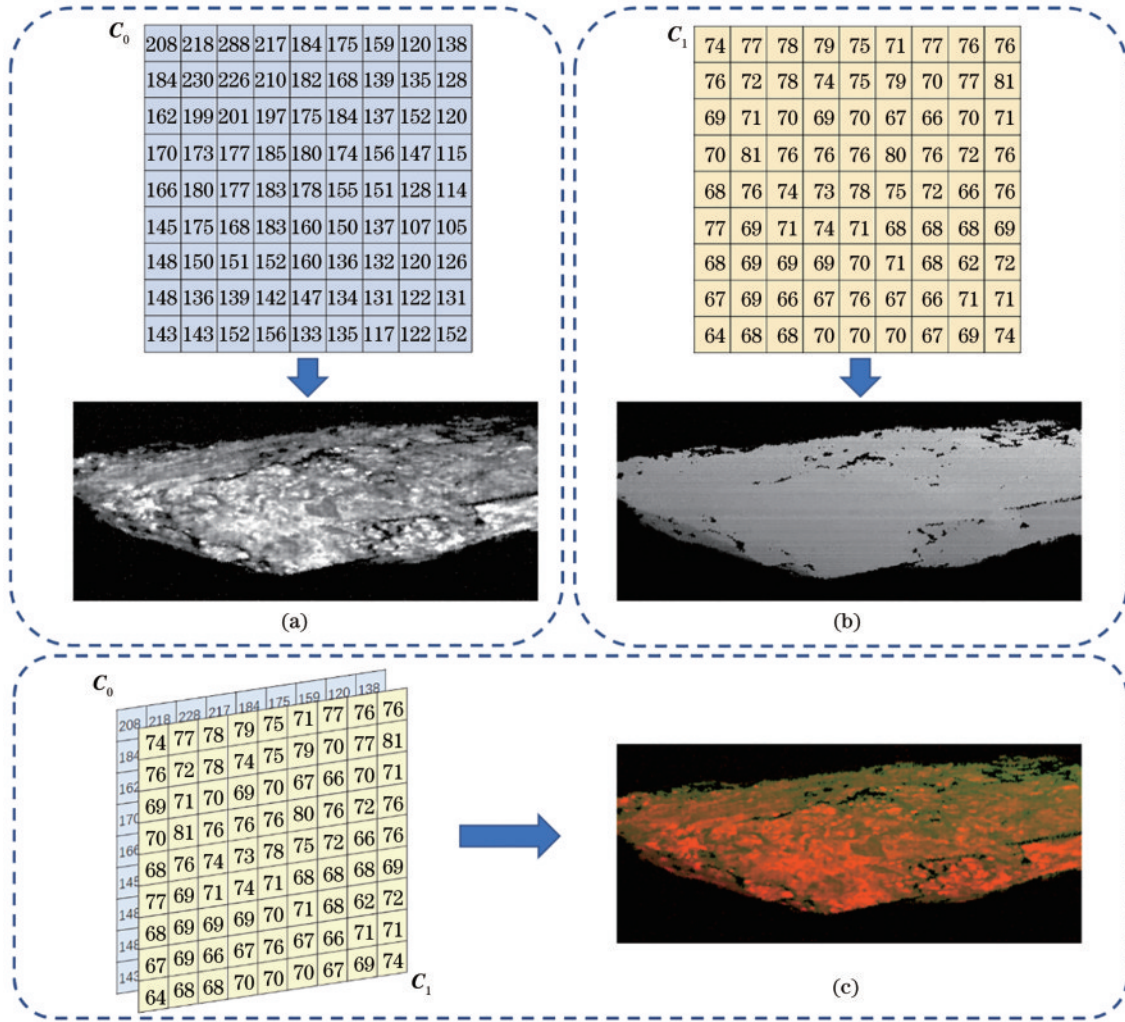


图 9 双通道伪彩图像生成过程。(a)强度点云图;(b)距离点云图;(c)双通道伪彩图像

Fig. 9 Dual channel pseudo color image generation process. (a) Intensity point cloud; (b) distance point cloud; (c) dual channel pseudo color image

比, DenseNet 采用了密集连接的结构, 通过重用特征, 显著减少了参数数量, 每层网络的计算量随之减少, 在

保证识别精度的同时, 降低了在工业应用中所需的计算时间。DenseNet-121 网络结构, 如图 10 所示。




图 10 DenseNet-121 网络结构

Fig. 10 DenseNet-121 network structure

由图 10 可知, DenseNet-121 网络含有 4 个稠密块, 稠密块内部实现层与层之间的稠密连接, 稠密块之间由过渡层链接, 由  $1 \times 1$  的卷积层和  $2 \times 2$  的池化层构成, 这样可以减少计算量, 提升计算效率。DenseNet 通过短连接的方式, 缓解了网络层数加深所引起的梯度消失问题, 大大提高网络层次。所述的激光雷达双通道伪彩图像数据与色彩模式 (RGB) 图像相比, 减少了一个通道的信息, 在图像识别领域属于简单二分类

问题, 过深的网络层次会导致过拟合等问题, 从而降低识别率。原始的 DenseNet-121 网络识别速度较慢, 不能满足工业生产中对实时性的要求。

为了提高特征提取的速度和准确性, 在保证识别率的基础上, 对 DenseNet-121 进行剪枝。剪枝后得到的 DenseNet-40 网络结构参数, 如表 2 所示 ( $s$  为步长)。优化后的 DenseNet 保留了 DenseNet 稠密连接的思想, 稠密块之间仍采用 Transition 降维处理, 以降低数

表 2 DenseNet-40 和 DenseN-121 网络结构参数  
Table 2 Parameters of DenseNet-40 and DenseN-121

Layer	Output size	DenseNet-40	DenseNet-121
Convolution	112×112	7×7Conv, s=2	7×7Conv, s=2
Pooling	56×56	3×3max pool, s=2	3×3max pool, s=2
Dense block(1)	56×56	$\begin{bmatrix} 1 \times 1\text{Conv} \\ 3 \times 3\text{Conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1\text{Conv} \\ 3 \times 3\text{Conv} \end{bmatrix} \times 6$
Transition layer(1)	56×56	1×1Conv	1×1Conv
	28×28	2×2average pool, s=2	2×2average pool, s=2
Dense block(2)	28×28	$\begin{bmatrix} 1 \times 1\text{Conv} \\ 3 \times 3\text{Conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1\text{Conv} \\ 3 \times 3\text{Conv} \end{bmatrix} \times 12$
Transition layer(2)	28×28	1×1Conv	1×1Conv
	14×14	2×2average pool, s=2	2×2average pool, s=2
Dense block(3)	14×14	$\begin{bmatrix} 1 \times 1\text{Conv} \\ 3 \times 3\text{Conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1\text{Conv} \\ 3 \times 3\text{Conv} \end{bmatrix} \times 24$
Transition layer(3)	14×14		1×1Conv
	7×7		2×2average pool, s=2
Dense block(4)	7×7		$\begin{bmatrix} 1 \times 1\text{Conv} \\ 3 \times 3\text{Conv} \end{bmatrix} \times 16$
Classification layer	1×1	7×7global average pool	7×7global average pool
		1000D fully-connector, softmax	1000D fully-connector, softmax

据量;但不再使用4层深度稠密块,而是重用3个相同的较浅稠密块来减少每个稠密块的深度,从而减少网络的层数。最终,网络层总数减少至40层,与DenseNet-121相比,优化后的网络减少了大量的参数<sup>[27]</sup>。

深度学习中,通常用浮点运算数(FLOPs)来衡量算法或模型的复杂度。对一个卷积层而言,假设其大小为 $h \times w \times c \times n$ ,其中 $h$ 为通道深度, $w$ 为通道宽度, $c$ 为输入通道数, $n$ 为输出通道数,输出的特征图尺寸为 $H' \times W'$ ,则该卷积层的FLOPs为 $H' \times W' \times n \times (h \times w \times c + 1)$ 。常见CNN的FLOPs与参数量,如表3所示。

表 3 常见模型复杂度与参数量

Table 3 FLOPs and parameter quantity of common models

Model	Size /10 <sup>6</sup>	FLOPs /10 <sup>9</sup>
AlexNet	61.0	0.7
GoogleNet	7.0	1.6
VGG-19	144.0	15.5
ResNet50	25.0	3.9
DenseNet40	0.2	1.3
DenseNet121	8.0	5.7

### 3 分析与讨论

实验时,将预处理好的双通道伪彩图像输入剪枝的DenseNet-40网络模型进行训练。图11为数据集中

使用的一些双通道伪彩图像。激光雷达数据训练集由7300块煤、矸石组成,测试集由1000块煤、矸石组成。

通过引入精准率 $P$ 、召回率 $R$ 、F1分数( $F_1$ )<sup>[28]</sup>来评估网络的识别性能。这些指标可以忽略由不平衡样本引起的识别率偏差。 $P$ 、 $R$ 、 $F_1$ 可表示为

$$P = \frac{T_p}{T_p + F_p}, \quad (4)$$

$$R = \frac{T_p}{T_p + F_n}, \quad (5)$$

$$F_1 = 2 \frac{P \times R}{P + R}, \quad (6)$$

式中: $T_p$ 为真阳性,即正样本被模型预测为正; $F_p$ 为假阳性,即负样本被模型预测为正; $F_n$ 为假阴性,即正样本被模型预测为负。 $F_1$ 为 $P$ 和 $R$ 的调和平均值,可以验证 $P$ 和 $R$ 的稳定性。用于训练的计算机参数为Intel i7-11700K CPU,NVIDA GeForce GTX 2080Ti,模型训练设置Epoch为100,Batch size为8,使用Adam优化器,学习率 $L_r=0.0001$ ,实验以7:1的比例重复交叉验证10次。利用所采集的激光雷达双通道伪彩数据集对常见的深度学习网络模型进行训练,实验结果如图12所示,实验数据如表4所示。

实验结果表明,网络层数的增加,并不一定能提升识别性能,当DenseNet网络层数增加至201层时,出现了明显的过拟合现象。其他经典图像分类网络与所提的网络相比,准确率都有所下降。




图 11 实验所用双通道伪彩图像。(a)煤;(b)矸石

Fig. 11 Dual channel pseudo color image used in the experiment. (a) Coal; (b) gangue

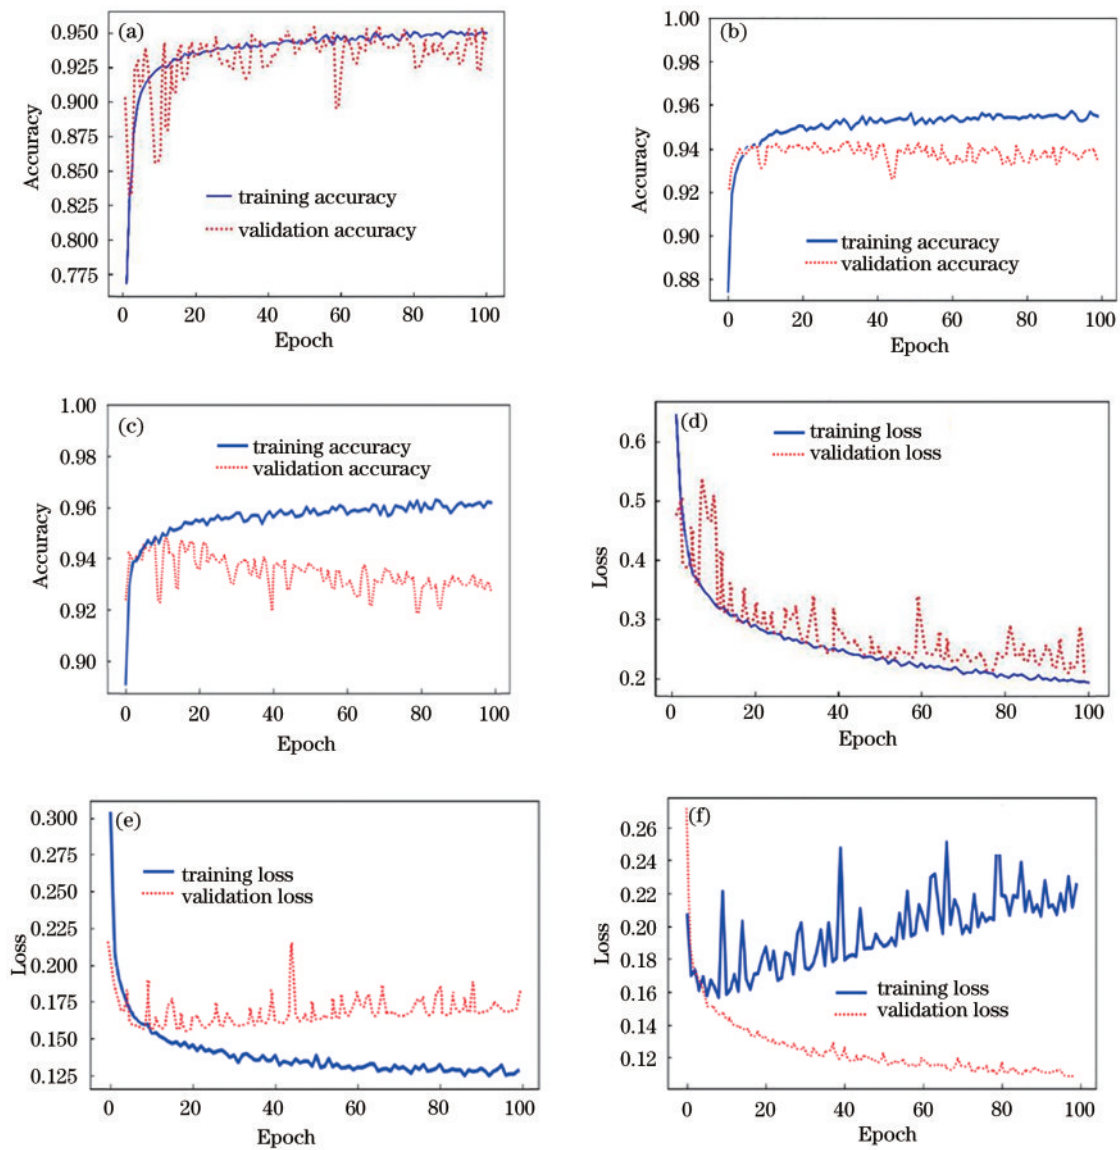


图 12 训练准确率和训练损失曲线。(a) (d)DenseNet-40;(b) (e)DenseNet-121;(c) (f)DenseNet-201

Fig. 12 Training accuracy and training loss curves. (a) (d) DenseNet-40; (b) (e) DenseNet-121; (c) (f) DenseNet-201



表 4 交叉验证平均结果

Table 4 Cross validation average results

Model	Accuracy / %	P	R	F <sub>1</sub>
DenseNet-40	94.56	0.96	0.97	0.97
DenseNet-121	93.49	0.91	0.97	0.94
DenseNet-201	92.74	0.90	0.96	0.93
ResNet-101	83.53	0.82	0.86	0.84
VGG-19	92.54	0.90	0.95	0.93
Xception	90.24	0.89	0.92	0.90

## 4 结 论

从原始的人工分拣方法、到传统的跳汰法、再到后来的工业相机分选法,识别技术逐步发展,煤矸石分拣的效率和精度都有着很大的提升。由于实际生产中环境复杂,传统方法对机械振动适应性较差,且易造成操作人员的损伤等问题,提出了利用激光雷达双通道融合成像的煤矸石识别方法。通过对三维点云反射强度进行二维投影,并生成图像,将距离信息通道和反射率信息通道灵活融合,形成双通道伪彩图像。结合优化后的 DenseNet-40 模型对煤矸石双通道数据集进行识别,识别率达到 94.56%。

将本文方法与目前流行的工业相机分选法进行相比,激光雷达在主动探测、环境适应性强、不需要均匀光照、多维度(反射强度和距离信息)等方面具有自身优势<sup>[29-30]</sup>;根据反射率信息对煤和矸石快速区分,而距离信息则能反应煤和矸石的物理轮廓信息,以分割背景杂物,快速去除干扰信息对识别的影响;能有效解决工业相机分选法对照明的要求高、设备稳定性差以及识别率较低等问题。

本实验中所采用的激光雷达的精度为±1.5 mm,由于激光雷达精度的限制,双通道图像中的距离通道难以准确描述煤和煤矸石表面的纹理。后续可考虑采用更高精度的激光雷达,并融合多种信息如相机图像数据与激光雷达数据,来提升识别效果。

## 参 考 文 献

- [1] 谢和平, 吴立新, 郑德志. 2025 年中国能源消费及煤炭需求预测[J]. 煤炭学报, 2019, 44(7): 1949-1960.  
Xie H P, Wu L X, Zheng D Z. Prediction on the energy consumption and coal demand of China in 2025[J]. Journal of China Coal Society, 2019, 44(7): 1949-1960.
- [2] 杨家威. 提高煤炭资源回收率措施分析[J]. 能源与节能, 2022(4): 25-27.  
Yang J W. Measures to improve recovery rate of coal resources[J]. Energy and Energy Conservation, 2022(4): 25-27.
- [3] Leonard R, Zufikar R, Stansbury R. Coal mining and lung disease in the 21st century[J]. Current Opinion in Pulmonary Medicine, 2020, 26(2): 135-141.
- [4] Sun Z Y, Lu W H, Xuan P C, et al. Separation of

gangue from coal based on supplementary texture by morphology[J]. International Journal of Coal Preparation and Utilization, 2022, 42(3): 221-237.

- [5] 张颢腾, 巩志强, 王振波, 等. 神木原煤及其热解半焦的燃烧与污染物排放规律研究[J]. 化学反应工程与工艺, 2020, 36(2): 183-192.  
Zhang H T, Gong Z Q, Wang Z B, et al. Study on combustion and pollutant emission of Shenmu raw coal and its pyrolytic semi-coke[J]. Chemical Reaction Engineering and Technology, 2020, 36(2): 183-192.
- [6] Su L L, Cao X G, Ma H W, et al. Research on coal gangue identification by using convolutional neural network[C]//2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), May 25-27, 2018, Xi'an, China. New York: IEEE Press, 2018: 810-814.
- [7] Li D J, Zhang Z X, Xu Z H, et al. An image-based hierarchical deep learning framework for coal and gangue detection[J]. IEEE Access, 2019, 7: 184686-184699.
- [8] Pu Y Y, Apel D B, Szmigiel A, et al. Image recognition of coal and coal gangue using a convolutional neural network and transfer learning[J]. Energies, 2019, 12(9): 1735.
- [9] Paranhos R S, dos Santos E G, Veras M M, et al. Performance analysis of optical and X-Ray transmitter sensors for limestone classification in the South of Brazil [J]. Journal of Materials Research and Technology, 2020, 9(2): 1305-1313.
- [10] Robben, Wotruba. Sensor-based ore sorting technology in mining: past, present and future[J]. Minerals, 2019, 9(9): 523.
- [11] Zhang N B, Liu C Y. Radiation characteristics of natural gamma-ray from coal and gangue for recognition in top coal caving[J]. Scientific Reports, 2018, 8(1): 1-9.
- [12] 马宪民, 蒋勇. 煤与矸石识别的数字图像处理方法探讨[J]. 煤矿机电, 2004(5): 9-11.  
Ma X M, Jiang Y. Digital image processing method of coal gangues[J]. Colliery Mechanical & Electrical Technology, 2004(5): 9-11.
- [13] 侯峰. LIDAR 详细介绍及其应用举例综述[J]. 科技广场, 2014(4): 95-100.  
Hou F. Thorough introduction of LIDAR and overview of its application[J]. Science Mosaic, 2014(4): 95-100.
- [14] 龚威, 史硕, 陈博文, 等. 机载高光谱激光雷达成像技术发展与应用[J]. 光学学报, 2022, 42(12): 1200002.  
Gong W, Shi S, Chen B W, et al. Development and application of airborne hyperspectral LiDAR imaging technology[J]. Acta Optica Sinica, 2022, 42(12): 1200002.
- [15] Song J H, Han S H, Yu K Y, et al. Assessing the possibility of land-cover classification using lidar intensity data[J]. International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences, 2002, 34(3/B): 259-262.
- [16] Liu X Y, Zhang Z Y, Peterson J, et al. LiDAR-derived high quality ground control information and DEM for image orthorectification[J]. GeoInformatica, 2007, 11(1): 37-53.

- [17] 赵子默. 基于激光雷达成像的煤矸智能分选技术研究[D]. 西安: 西安工业大学, 2021.  
Zhao Z M. Intelligent separation technology of coal and gangue based on LiDAR imaging[D]. Xi'an: Xi'an Technological University, 2021.
- [18] Su L L, Cao X G, Ma H W, et al. Research on coal gangue identification by using convolutional neural network[C]//2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), May 25-27, 2018, Xi'an, China. New York: IEEE Press, 2018: 810-814.
- [19] 李曼, 段雍, 曹现刚, 等. 煤矸分选机器人图像识别方法和系统[J]. 煤炭学报, 2020, 45(10): 3636-3644.  
Li M, Duan Y, Cao X G, et al. Image identification method and system for coal and gangue sorting robot[J]. Journal of China Coal Society, 2020, 45(10): 3636-3644.
- [20] 李鹏祥, 刘慧博. 基于卷积神经网络的煤矸识别系统的研究[J]. 自动化应用, 2021(9): 8-14, 19.  
Li P X, Liu H B. Research on coal gangue recognition system based on convolutional neural network[J]. Automation Application, 2021(9): 8-14, 19.
- [21] Gale T, Elsen E, Hooker S. The state of sparsity in deep neural networks[EB/OL]. (2019-02-25) [2022-11-05]. <https://arxiv.org/abs/1902.09574>.
- [22] 洪亮, 高尚, 李翔. 基于网络特征的分层剪枝方法[J]. 吉林大学学报(理学版), 2022, 60(6): 1407-1415.  
Hong L, Gao S, Li X. Layer-wise pruning method based on network characteristics[J]. Journal of Jilin University (Science Edition), 2022, 60(6): 1407-1415.
- [23] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [24] 张宸鹏. 回复式神经网络若干关键问题研究[D]. 成都: 电子科技大学, 2021.  
Zhang C P. Research on some key problems of recurrent neural networks[D]. Chengdu: University of Electronic Science and Technology of China, 2021.
- [25] Xu K S, Wang H L, Tang P J. Image captioning with deep LSTM based on sequential residual[C]//2017 IEEE International Conference on Multimedia and Expo (ICME), July 10-14, 2017, Hong Kong, China. New York: IEEE Press, 2017: 361-366.
- [26] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [27] Xing J C, Zhao Z M, Wang Y Z, et al. Coal and gangue identification method based on the intensity image of lidar and DenseNet[J]. Applied Optics, 2021, 60(22): 6566-6572.
- [28] Goutte C, Gaussier E. A probabilistic interpretation of precision, recall and *F*-score, with implication for evaluation[M]//Losada D E, Fernández-Luna J M. Advances in Information Retrieval. Lecture notes in computer science. Berlin: Springer, 2005, 3408: 345-359.
- [29] 宋卫虎. 基于深度学习的煤矸识别研究与实现[D]. 邯郸: 河北工程大学, 2021.  
Song W H. Research and implementation of coal and gangue identification based on deep learning[D]. Handan: Hebei University of Engineering, 2021.
- [30] 徐志强, 吕子奇, 王卫东, 等. 煤矸智能分选的机器视觉识别方法与优化[J]. 煤炭学报, 2020, 45(6): 2207-2216.  
Xu Z Q, Lü Z Q, Wang W D, et al. Machine vision recognition method and optimization for intelligent separation of coal and gangue[J]. Journal of China Coal Society, 2020, 45(6): 2207-2216.