

基于多光谱成像和改进 YOLO v4 的煤矸石检测

来文豪, 周孟然*, 胡锋, 卞凯, 宋红萍

安徽理工大学电气与信息工程学院, 安徽 淮南 232000

摘要 煤矸石分离对环境保护和资源高效利用具有重要意义, 因此, 提出了一种基于多光谱成像技术和目标检测的煤矸石智能分离方法。首先, 在实验室搭建了煤矸石多光谱采集系统, 共采集 850 组多光谱数据; 其次, 研究了多光谱中各波段煤矸石的识别率及相关性, 从 25 个波段中选出 3 个波段构成伪 RGB (Red, Green, Blue) 图像; 最后, 用改进的目标检测模型 YOLO v4.1 检测煤矸石。实验结果表明, YOLO v4.1 在测试集上检测煤和煤矸石的平均精度均值为 98.26%, 检测时间约为 4.18 s。该方法不仅能准确识别出煤和煤矸石, 还能获取两者的相对位置和大小, 对煤矸石的分离操作具有重要意义。

关键词 光谱学; 多光谱成像; 波段选择; 目标检测; 煤矸石智能分离

中图分类号 O433.5

文献标志码 A

doi: 10.3788/AOS202040.2411001

Coal Gangue Detection Based on Multi-Spectral Imaging and Improved YOLO v4

Lai Wenhao, Zhou Mengran*, Hu Feng, Bian Kai, Song Hongping

College of Electrical and Information Engineering, Anhui University of Science and Technology,
Huainan, Anhui 232000, China

Abstract The separation of coal gangue from coal is of great significance for environmental protection and resource-saving. Therefore, this article proposes an intelligent separation method for coal gangue based on multi-spectral imaging technology and object detection. First, a multi-spectral data acquisition system for coal and coal gangue is set up in the laboratory, and 850 groups of multispectral data are collected. Second, by studying the coal gangue recognition rate and the correlation of each band of multi-spectral data, three bands from 25 bands are selected to form a pseudo-RGB (Red, Green, and Blue) image. Finally, the improved object detection model YOLO v4.1 is used to detect coal gangue. Experimental results show that the the mean average precision of YOLO v4.1 for coal and coal gangue detection on the test set is 98.26%, and the detection time is about 4.18 s. The method can not only precisely identify coal and coal gangue, but also obtain their relative position and size, which is important for the seperation operation of coal gangue.

Key words spectroscopy; multispectral imaging; bands selection; object detection; coal gangue intelligent separation

OCIS codes 110.4234; 100.4996; 150.1135

1 引 言

从第一次工业革命开始煤炭就在人类能源中扮演了重要角色, 相比 2017 年, 2018 年的煤炭消耗量增长了 1.4%, 是近十年平均增速的 2 倍^[1], 这意味着未来人类每年仍需开采大量的煤炭。煤炭开采过程中不可避免地会掺杂煤矸石, 原煤中煤矸石的含量超过 10%^[2]。煤矸石含有可挥发的重金属元素,

如 As, Cd, Cu, Ni, Se, Sn 和 Zn^[3-4], 有些矿区的煤矸石还包含大量的 S 元素^[5]。煤中掺杂的煤矸石不仅会降低其燃烧效率、造成能源浪费, 还会增加废物的排放, 加剧环境污染。因此, 从煤中分离出煤矸石对资源的高效利用和环境保护具有重要意义。最初, 煤矸石由人工进行分离, 该过程中劳动者非常辛苦且效率低。因此, 人们提出了一种基于密度差异的湿选法分离煤和煤矸石^[6], 但需要消耗大量的水, 造

收稿日期: 2020-06-28; 修回日期: 2020-08-18; 录用日期: 2020-09-08

基金项目: 国家重点研发计划(2018YFC0604503)、安徽理工大学 2019 年博士创新基金(2019CX1005)

* E-mail: mrzhou8521@163.com

成水资源的浪费。干选法是一类不使用水的煤矸石分离技术^[7],如重介法^[8]、射线识别法^[9-10]和机器视觉识别法^[11-12]。重介法分选效率高,但系统复杂、成本昂贵;射线法的系统相对简单,但会产生辐射,有害于操作人员的身体健康;基于机器视觉的煤矸石分离技术利用算法识别煤矸石,也被称为智能分离法。计算机 CPU 和 GPU 性能的显著提升^[13],为大规模视觉识别的实现提供了硬件基础。此外,人工智能和深度学习技术也得到快速发展,如深度残差网络(ResNet)^[14]在 2015 年的大规模视觉识别挑战赛(ILSVRC)top5 数据集中的误差为 3.57%,小于人眼的识别误差。

相比 RGB(Red,Green,Blue)图像,多光谱图像的波段较宽,且数据量远远小于高光谱图像。在医学^[15]和食品^[16]等领域有着广泛应用,但其在煤矸石分离中的应用研究较少。Hu 等^[17]利用人工特征验证了多光谱成像技术对煤矸石识别的可行性。Lai 等^[18]基于学习特征研究了多光谱不同波段的煤矸石识别性能。这些研究在一定程度上推动了智能分离煤矸石的发展,但也只是将煤与煤矸石的识别作为二分类问题研究,无法识别煤与煤矸石在同一张光谱图像中的情况。此外,上述方法只能确认图像中有没有煤矸石,无法得知煤矸石的位置信息,难以实现分离操作。因此,将多光谱技术用于煤矸石分离还有待进一步研究。目标检测是机器视觉领域的重要研究方向^[19],主要目的是获取图像中物体的位置。随着深度学习的发展,目标检测在多个领域中得到了广泛的应用^[20]。如区域卷积神经网络(RCNN)^[21]在 Pascal VOC 2012 数据集上的目标检测平均精度均值(mAP)为 53.3%,相比之前最好的结果提升了 30%。目前,基于深度学习的目标检测模型可分为两类,一类是以 RCNN 为代表的两步(two-stage)^[22-23]检测法,另一类是以 YOLO(You only look once)^[24]为代表的单步(one-stage)检测法。YOLO 的原理简单,对计算机的性能要求低,容易实现^[25]。为追求更高的性能,人们又相继提出了 YOLO v2^[26],YOLO v3^[27]和 YOLO v4^[28]。相比其他版本,YOLO v4 的检测性能更优秀。

综上所述,本文将 YOLO v4 用于煤矸石检测,为煤矸石的智能分离提供位置信息。针对已有识别方法无法定位图像中的煤矸石问题,提出了一种基于多光谱成像和改进 YOLO v4 的煤矸石识别和定位方法,可在分离时提供煤矸石的位置信息。尽管 YOLO v4 的检测性能优异,但其设计是面向大规模

视觉挑战赛,在实际任务中,具有较大的改进空间。因此,通过改进 YOLO v4,实现更高效的煤矸石检测,对煤炭清洁利用和煤矿的自动化建设具有现实意义。

2 实验设备与方法

2.1 设备和数据采集

多光谱成像技术带宽大,受可见光的影响非常小,实时性好。因此,可将多光谱成像技术用于检测煤矸石,实验室搭建的光谱采集系统如图 1 所示。多光谱数据采集系统由光源、滤光片、镜头、光谱成像仪和计算机组成。其中,椭圆圈出的部分为多光谱成像仪,光源为 SUMITA OPTICAL GLASS 公司生产的 LS-LHA。滤波设备只允许波长为 675~975 nm 的光通过,由 Edmund Optics(American)生产。多光谱成像仪为 XIMEA 公司生产的 MQ022HG-IM-SM5X5-NIR,共 25 个波段,每个波段都可获得一个分辨率为 409 pixel×216 pixel 的光谱图。进行光谱采集时,成像仪通过 USB3.0 接口由计算机控制。成像仪的曝光时间为 16.007 ms。从安徽淮南矿区获取实验所用的煤矸石和煤块,在实验室采集数据,实验步骤:1)在实验室搭建数据采集平台,打开设备并初始化;2)利用上位机软件 HSIImager 通过 USB3.0 接口控制多光谱成像仪;3)为设备设置合适的参数;4)进行数据采集。

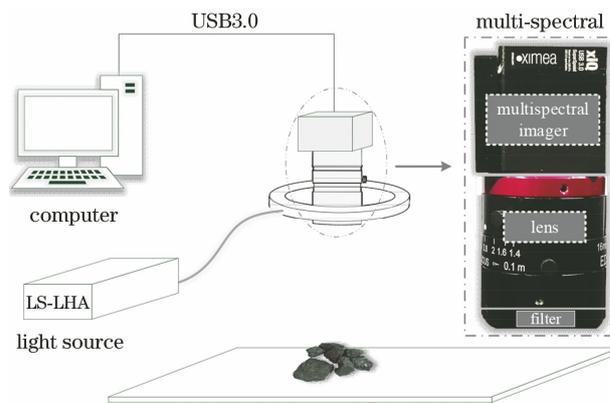


图 1 多光谱数据采集系统

Fig. 1 System of multi-spectral data acquisition

为提高检测精度,不仅需要采集包含多个煤块或煤矸石块的光谱图像数据,还需采集煤和煤矸石的混合多光谱数据。煤和煤矸石的光谱数据采集信息如表 1 所示,其中,mix 为煤和煤矸石出现在同一张多光谱图像中的情况。

实验得到的煤和煤矸石光谱图像如图 2 所示,左侧为一组光谱图像,共包含 25 个波段,每个波段

表 1 煤和煤矸石的数据信息

Table 1 Data information of coal and coal gangue

Sample	Number of lumps			Total
	1	2	3	
Coal	175	75	50	300
Coal gangue	175	75	50	300
Mix	—	100	150	250

都能可视化为一个分辨率为 $216 \text{ pixel} \times 409 \text{ pixel}$ 的灰度图像。右侧为多光谱图像中波段 1 的光谱图,其中,虚线框为煤块,实线框为煤矸石。

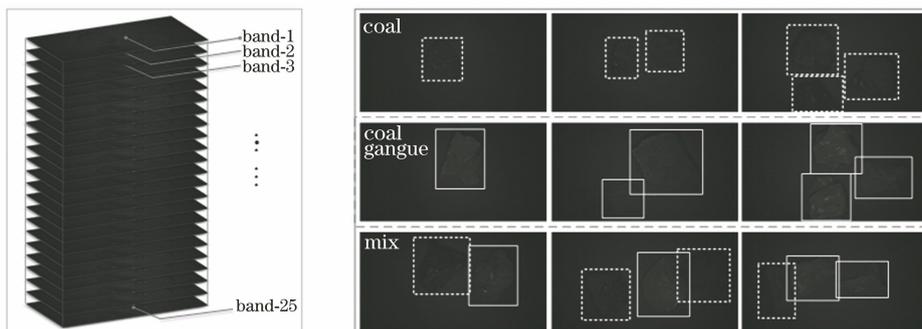


图 2 煤和煤矸石的多光谱图像

Fig. 2 Multi-spectral image of coal and coal gangue

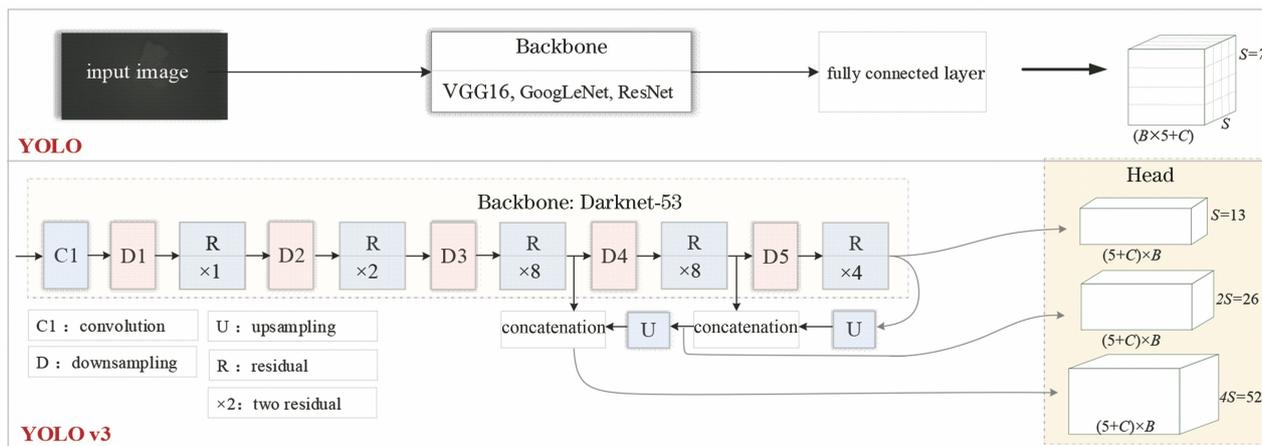


图 3 YOLO 和 YOLO v3 模型的结构

Fig. 3 Structures of YOLO and YOLO v3 models

类别数, B 为每个网格单元预测的边界框数。每个边界框需要预测 5 个变量,分别为边界框的坐标 (x, y) ,边界框的宽、高 (w, h) 以及置信度。

为提高模型对不同大小目标的检测性能, YOLO v3 上加入了多尺度网格,但网络层数越深,模型的容量也就越大,特征学习能力越强。为获取更多的输入图像特征, YOLO v3 模型用 Darknet-53 提取图像特征。在深层网络中,容易出现梯度消失

2.2 YOLO 目标检测的原理

1) YOLO 的检测机制

YOLO v4 是 YOLO 的改进版本,揭示 YOLO v4 的检测机制,需从基本的 YOLO 模型开始。YOLO 将目标检测转换为一个回归问题,在模型中分类和边框回归同时进行,也被称为一阶段检测。YOLO 的检测原理如图 3 所示,输入的图像经主干网络 (Backbone) 提取特征后由全连接层映射到一个维度为 $S \times S \times (B \times 5 + C)$ 的张量。Backbone 可以是任何卷积神经网络 (CNN) 模型,如视觉几何组网络 (VGGNet) 和 GoogLeNet。 $S \times S$ 为网格数, C 为

和爆炸,增加了网络的训练难度。Darknet-53 通过残差连接^[17],使网络更容易训练,收敛速度更快。Darknet-53 的下采样均是步长为 2 的卷积操作。YOLO v3 的输入图像尺寸为 $416 \text{ pixel} \times 416 \text{ pixel}$ 时,网格的尺寸分别为 $13 \text{ pixel} \times 13 \text{ pixel}$ 、 $26 \text{ pixel} \times 26 \text{ pixel}$ 和 $52 \text{ pixel} \times 52 \text{ pixel}$,每个网格的长为 $(5 + C) \times B$ 。在 YOLO v3 中,每个尺度网格的 B 为 3,共使用 9 个锚框。

YOLO v4 为优化的 YOLO v3,目的是提高系统中神经网络的运行速度,同时优化并行计算。输入图像的分辨率分别为 $416 \text{ pixel} \times 416 \text{ pixel}$ 、 $512 \text{ pixel} \times 512 \text{ pixel}$ 和 $608 \text{ pixel} \times 608 \text{ pixel}$,研究表明,高分辨率的输入图像有利于提高检测精度。YOLO v4 的主干网络是用 CSP (Cross stage partial)改进的 Darknet-53(CSPDarknet-53)。其边界框回归仍使用 YOLO v3,且头部(Head)没有改进。主干网络和检测头部由颈部(Neck)连接,Neck 主要由金字塔池化(SPP)和路径聚合网络(PAN)构成。CSP^[29]通过对梯度流的分裂使梯度流通过不同的网络路径传播,目的是减少计算量的同时实现更丰富的梯度组合,从而提高推理速度和准确性。SPP^[30]用多个不同尺度的池化窗口采样特征图,然后进行融合汇合,且输出特征的尺寸相同。因此,基于 SPP 的 CNN 模型可允许输入多种尺度的图像。PAN^[31]通过自下向上的路径增强在较低层中准确的定位信息流,建立底层特征和高层特征之间的信息路径,从而增强整个特征的层次架构。

2) 改进的 YOLO v4

YOLO v4 的设计是面向大规模视觉挑战赛,其网络采用 3 种尺度,以实现多种尺度目标的检测。为了实现更高的检测精度,可输入更大分辨率的图像。实验使用的多光谱成像仪每个通道光谱图像的分辨率为 $409 \text{ pixel} \times 216 \text{ pixel}$,改进的 YOLO v4 (YOLO v4.1)在输入图像分辨率较小的情况下,依然具有优异的检测性能。

YOLO v4.1 的主干网络基于 CSPDarknet-53,并与其有着相同的深度,记为 Backbone1,可直接使用 YOLO v4 的预训练权重,Backbone1、Neck 和 Head 的结构和改进如图 4 所示。其中,Add 为两个特征层的相加操作,Backbone1 是步长为 2 的 3 次下采样和步长为 3 的 1 次下采样,即 4 次下采样操作。输入图像的分辨率为 $408 \text{ pixel} \times 408 \text{ pixel}$,输出特征图的尺寸分别为 $17 \text{ pixel} \times 17 \text{ pixel}$ 和 $51 \text{ pixel} \times 51 \text{ pixel}$ 。此外,通过短路连接改进 SPP (RSPP),Head 输出的网格有两种尺度(奇数),分别为 17×17 和 51×51 ,每个尺度的网格采用 4 个锚框。

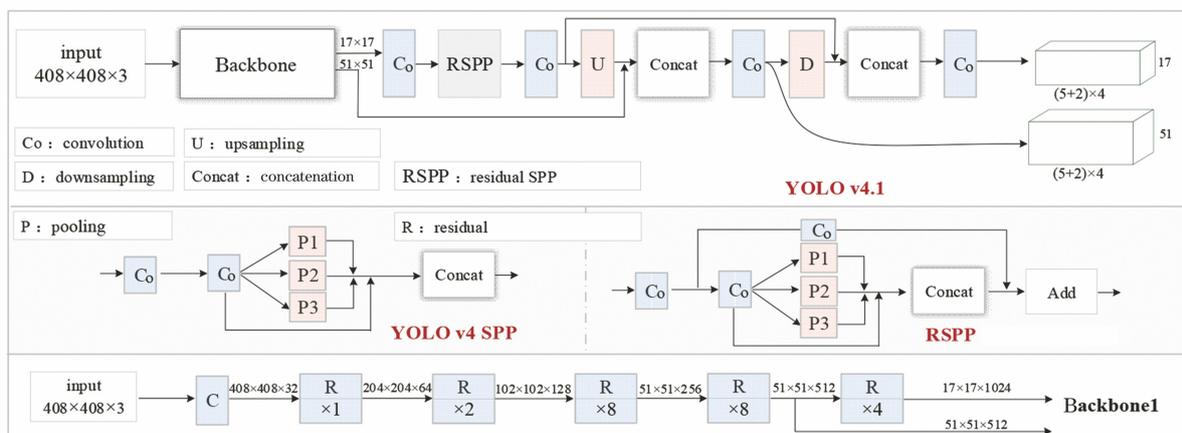


图 4 YOLO v4.1 的原理图

Fig. 4 Schematic diagram of YOLO v4.1

3 实验和结果分析

为尽可能地提高检测速度,从每组多光谱图像的 25 个波段中选择 3 波段用于 YOLO v4.1 检测。根据识别率和相关性选择波段,首先研究不同波段的煤矸石识别率,预选出识别率相对较高的波段;然后分析预选波段间的相关性,选出 3 个相关系数最小的波段作为组合波段用于检测研究。

3.1 多光谱波段选择

1) 不同波段煤矸石的识别准确率

原始光谱图像的分辨率为 $216 \text{ pixel} \times 409 \text{ pixel}$,YOLO v4.1 输入图像的分辨率最高为

$408 \text{ pixel} \times 408 \text{ pixel}$ 。分析各波段煤矸石的识别率时,输入光谱图像的分辨率为 $204 \text{ pixel} \times 408 \text{ pixel}$ 。为了尽可能地保留每个波段的光谱信息,用于煤和煤矸石识别的光谱数据不进行任何特征处理。

集成学习^[32]是一种强学习机,由多个弱学习机通过 Boosting 或 Bagging 构建,分类性能优异,且对高维数据的鲁棒性好。原始光谱数据是图像,维度较高。因此,将集成学习用于研究不同波段的煤矸石识别性能。

自适应增强(AdaBoost)^[33]和随机森林(RF)^[34]是集成学习中的两个经典算法,其弱学习机都是分类回归树(CART)^[35]。RF 是以 CART 为弱分类器

的一个集成学习模型,每棵树都依赖于独立抽样,分类时,每棵树都投票并返回得票数最多的类,最终以得票数多的类别作为预测类别。AdaBoost 由多个弱学习机集成,前一个弱学习机错分的样本在下一个弱学习机中会得到加强,每轮中加入一个新的弱学习机,直到得到某个预定的错误率(足够小)或达到预定的最大迭代次数。为尽可能地提升网络对不同波段煤矸石的识别性能,将 AdaBoost、RF 和 CART 用于煤矸石识别。

文献[17]和文献[18]以二分类的形式研究不同波段煤矸石的识别率,当煤和煤矸石在同一图像中

时会引起误识别。因此,将煤和煤矸石混合出现在同一光谱图像中也作为一类。将数据按 4:1 的比例随机划分为训练集和测试集,所有算法对每个波段煤和煤矸石的识别都独立重复 20 次,每次识别时随机选取训练数据。不同波段煤矸石的平均识别准确率如图 5 所示。可以发现,同一算法不同波段、相同波段不同算法的煤矸石识别准确率均存在差异。煤和煤矸石的二分类中,AdaBoost 和 RF 对不同波段煤矸石的识别率相近,且相对较高。将煤和煤矸石的混合也作为一类时,AdaBoost、RF 和 CART 对不同波段煤矸石的识别准确率均有所降低。

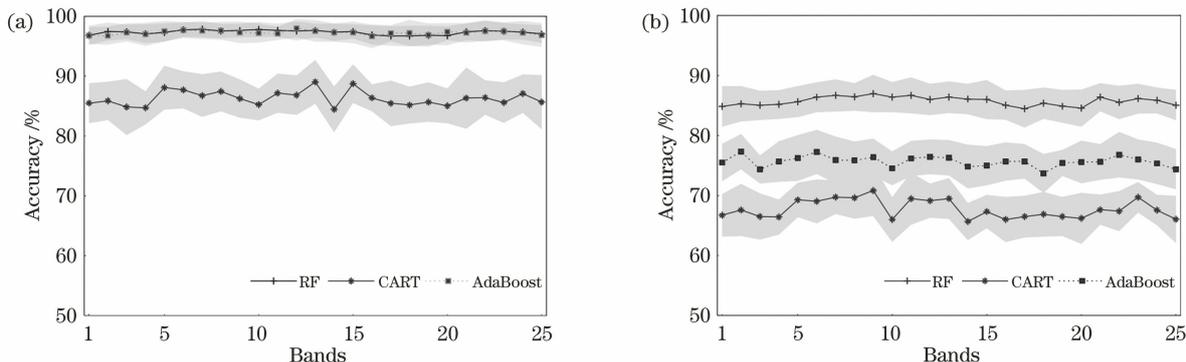


图 5 不同波段的平均识别准确率。(a)煤和煤矸石的二分类;(b)煤、煤矸石以及其混合图像的三分类

Fig. 5 Average recognition accuracy in different bands. (a) Two classes of coal and coal gangue; (b) three classes of coal, coal gangue, and mix

图 5 中,阴影部分表示识别准确率的标准差,AdaBoost、RF 和 CART 算法的最优识别结果如表 2 所示。可以发现,不同算法的最大平均识别准确率对应的波段不完全相同,且 RF 对煤、煤矸石和 mix 的最大平均识别准确率远大于 AdaBoost 和 CART。因此,选取 RF 识别率最高的波段,然后分析其相关性。

对于煤和煤矸石的二分类,RF 对波段 9 的平

均识别准确率为 97.6%,略小于波段 6、7、10。对于三分类,波段 6、7、10 的平均识别准确率分别为 86.4%、86.7%和 86.4%,不同波段识别准确率的差值相对标准差是非常小的,因此,将波段 6、7、9 和 10 作为组合波段的预选波段。此外,由于部分波段的平均识别准确率与最大平均识别准确率的差值较小,因此平均识别准确率相对高的波段全部被选择,并分析其相关性,预选取的波段如表 3 所示。

表 2 AdaBoost、RF 和 CART 的识别结果

Table 2 Recognition results of AdaBoost, RF, and CART

Algorithm	Coal and coal gangue		Coal, coal gangue, and mix	
	Maximum average accuracy / %	Band	Maximum average accuracy / %	Band
RF	97.8	6,7,10	87.0	9
CART	89.0	13	70.8	9
AdaBoost	98.0	12	77.3	2,6

表 3 预选波段

Table 3 Pre-selected band

Band	9	7	11	6	8	10	13	21
Average accuracy	87.0	86.7	86.7	86.4	86.4	86.4	86.4	86.4

unit: %

2) 预选波段的相关性分析

相关性是描述两个矩阵的相似程度,相关性的分析可用于特征选择、降低冗余信息^[36]。因此,被广泛应用于数据挖掘领域和特征选择。实验从预选波段中选择相关系数最小的三个波段,将选定的光谱图像作为 RGB 图像进行检测。预选波段的相关系数混淆矩阵如图 6 所示,图中的相关系数是实验获取的所有光谱数据(850 组)的均值。可以发现,尽管多光谱成像仪的各波段光谱数据相关性相对较

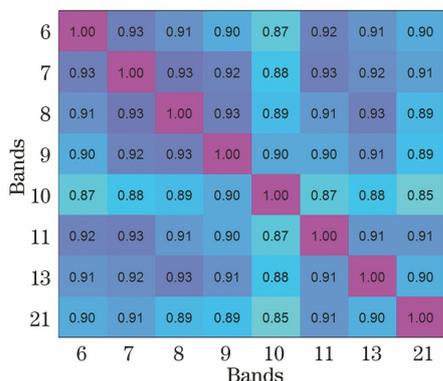


图 6 相关系数的混淆矩阵

Fig. 6 Confusion matrix of correlation coefficients

大,但不同波段的光谱图像依然存在差异。其中,波段 10 和波段 21 的相关系数最小,为 0.85。根据混淆矩阵,选取相关系数和最小的 3 个波段(波段 6、10 和 21 的相关系数和最小,为 2.62),用于煤矸石检测。

3.2 基于 YOLO v4.1 的煤矸石检测

将 850 组多光谱图像划分为训练集、验证集和测试集,每个数据集中的组合波段光谱图像分别为 700、60 和 90 张。为验证 YOLO v4.1 的性能,将原始 YOLO v4 也用于检测。原始 YOLO v4 输入图像的分辨率为 416 pixel×416 pixel、512 pixel×512 pixel 和 608 pixel×608 pixel。所有模型加载预训练权重后,训练 60 个 Epoch,训练的批大小为 4,学习率为 0.00025。将测试数据用训练好的模型测试,结果如图 7 所示,其中,横坐标上的 408 为 YOLO v4.1,416、512 和 608 为输入图像分辨率分别为 416 pixel×416 pixel、512 pixel×512 pixel 和 608 pixel×608 pixel 的 YOLO v4。可以发现,YOLO v4 输入光谱图像的分辨率越高,对煤或煤矸石的 mAP 越高。YOLO v4.1 对煤和煤矸石的 mAP 最优,分别为 98.73%和 97.78%。

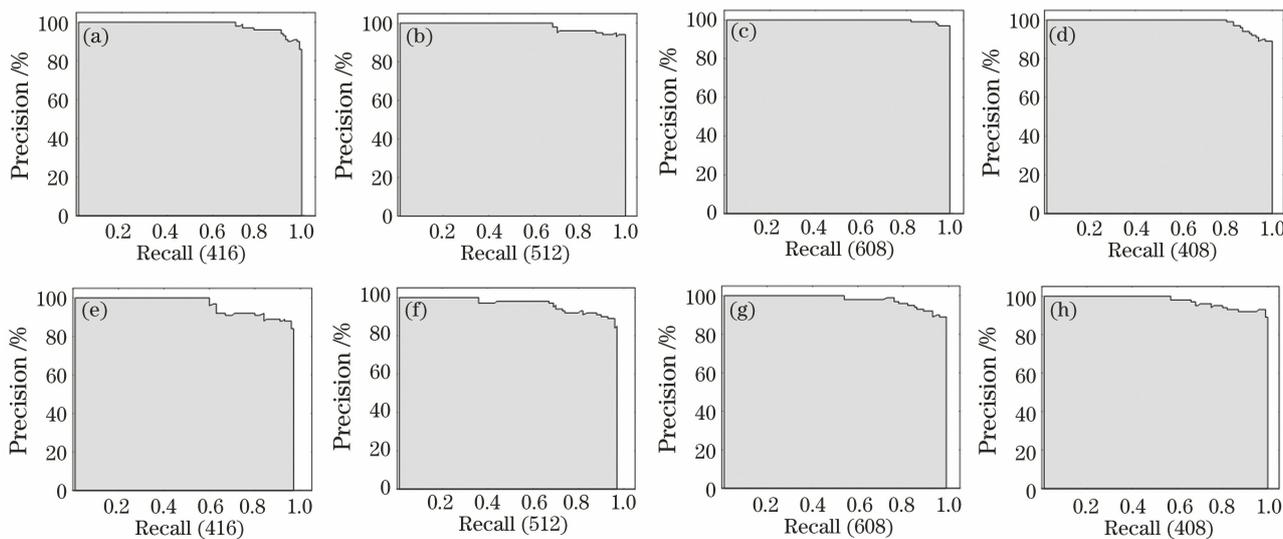


图 7 测试结果。(a)煤 416;(b)煤 512;(c)煤 608;(d)煤 408; (e)煤矸石 416;(f)煤矸石 512; (g)煤矸石 608;(h)煤矸石 408

Fig. 7 Test results. (a) Coal416; (b) coal512; (c) coal608; (d) coal408; (e) coal gangue416; (f) coal gangue512; (g) coal gangue608; (h) coal gangue408

各模型的测试时间如表 4 所示,可以发现, YOLO v4 输入的图像分辨率越高,煤或煤矸石的检测性能越好,但检测时间也会显著增大。输入图像的分辨率从 416 pixel×416 pixel 增加到 608 pixel×608 pixel 时,检测煤矸石的 mAP 提升了 3.80%,所用时间增加了 75.8%,这表明 YOLO v4 输入的

图像分辨率增加引起的时间消耗远大于对煤矸石检测精度提升带来的收益。而 YOLO v4.1 的 mAP 为 98.26%,对煤矸石检测精度为 97.78%,检测精度与输入分辨率为 608 pixel×608 pixel 的 YOLO v4 相当,且 90 组多光谱图像的检测时间仅为 4.18 s。

表 4 检测模型的测试结果

Table 4 Test results of each detection model

Detection model	Input resolution / (pixel×pixel)	Average precision		mAP / %	Test time / s
		Coal / %	Coal gangue / %		
YOLO v4.1	408×408	98.73	97.78	98.26	4.18
	416×416	97.47	93.49	95.48	3.43
YOLO v4	512×512	98.61	93.87	96.24	4.33
	608×608	98.59	97.04	97.81	6.07

综上所述, YOLO v4.1 的检测精度较高, 且检测速度也相对较快, YOLO v4.1 在测试集上的部分检测结果如图 8 所示, 其中, 置信度低的预测边界框已被过滤。可以发现, 当多个煤块或煤矸石在一张

光谱图像中, 甚至一些煤或煤矸石发生重叠时, YOLO v4.1 依然能准确识别和定位, 这表明 YOLO v4.1 在煤矸石检测中的性能较好。

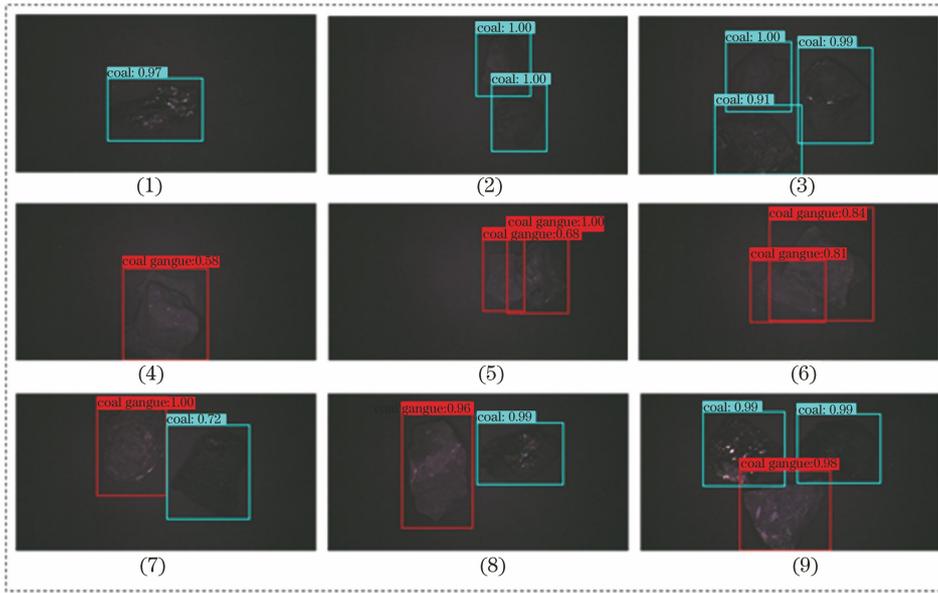


图 8 YOLO v4.1 的检测结果

Fig. 8 Detection result of YOLO v4.1

图 8 中煤或煤矸石的边界框坐标和得分如表 5 所示, 其中, (x_{lt}, y_{lt}) 为边界框的左上角坐标, (x_{rb}, y_{rb}) 为边界框的右下角坐标, 标签“c”和“g”分别表示煤和煤矸石。获得边界框的坐标后可得到煤矸石

的位置, 还可以通过边界框坐标获得煤矸石的相对尺寸, 这表明 YOLO v4.1 不仅能准确地识别出煤矸石, 还可以获取煤矸石的位置及相对尺寸, 有利于煤矸石的分离操作。

表 5 边界框的坐标和得分

Table 5 Coordinate and score of bounding box

Sample	Detection result [label:score $(x_{lt}, y_{lt}), (x_{rb}, y_{rb})$]								
	Label	Score	$(x_{lt}, y_{lt}), (x_{rb}, y_{rb})$	Label	Score	$(x_{lt}, y_{lt}), (x_{rb}, y_{rb})$	Label	Score	$(x_{lt}, y_{lt}), (x_{rb}, y_{rb})$
1	c	0.97	(87,124),(173,254)			—			—
2	c	1.00	(8,200),(109,275)	c	1.00	(92,221),(184,297)			—
3	c	1.00	(34,119),(130,209)	c	0.99	(42,217),(173,319)	c	0.91	(120,104),(216,223)
4	g	0.58	(90,145),(216,261)			—			—
5	g	1.00	(43,242),(152,326)	g	0.98	(51,209),(149,266)			—
6	g	0.84	(7,178),(162,320)	g	0.81	(79,152),(164,255)			—
7	g	1.00	(6,110),(141,205)	c	0.72	(44,205),(173,318)			—
8	g	0.96	(29,100),(185,197)	c	0.99	(41,202),(126,320)			—
9	g	0.98	(106,134),(216,258)	c	0.99	(26,84),(128,196)	c	0.99	(29,212),(124,326)

4 结 论

将多光谱成像技术和目标检测用于煤矸石分离研究,当煤和煤矸石混合在一张光谱图像中时,不仅能准确识别煤矸石,还能获得煤和煤矸石的位置及相对大小。针对煤与煤矸石混合时容易混淆的问题,将煤和煤矸石的混合物作为一类进行识别,减少了两者在同一张图像中的错误识别问题。基于识别精度和相关系数进行波段选择,将多光谱成像用于煤矸石分离,研究了多光谱 25 个波段对煤矸石的识别率,预选出识别准确率较高的 8 个波段,然后分析不同波段之间的相关性,选出相关性最小的 3 个波段构成一个伪 RGB 图像用于检测。实验结果表明,YOLO v4.1 对煤和煤矸石的检测精度可媲美于输入图像分辨率为 608 pixel \times 608 pixel 的 YOLO v4,且检测时间仅为 4.18 s,远小于 YOLO v4 检测模型的 6.07 s。

参 考 文 献

- [1] BP statistical review of world energy 2019[EB/OL]. (2019-06-13) [2020-06-05]. https://www.baidu.com/link?url=7tQmvqET_nG18tx72kxKeru9_jXs-djGfjffEQmPAmuZJWnMBjr1ATnao2CK87SR1Z26oc_Jw0wlZmWPYafG9mjSEI0DKjN_CPYW0g5F-QOXXm0sO25C9_mUxscUx-Fu&wd=&eqid=a1fe96140004288d000000025f96cadf.
- [2] Liang Y C, Liang H D, Zhu S Q. Mercury emission from spontaneously ignited coal gangue hill in Wuda coalfield, Inner Mongolia, China[J]. Fuel, 2016, 182: 525-530.
- [3] Zhou C C, Liu G J, Wu S C, et al. The environmental characteristics of usage of coal gangue in bricking-making: a case study at Huainan, China[J]. Chemosphere, 2014, 95: 274-280.
- [4] Tang Q, Li L Y, Zhang S, et al. Characterization of heavy metals in coal gangue-reclaimed soils from a coal mining area[J]. Journal of Geochemical Exploration, 2018, 186: 1-11.
- [5] Yang Z Z, Zhang Y Y, Liu L L, et al. Environmental investigation on co-combustion of sewage sludge and coal gangue: SO₂, NO_x and trace elements emissions[J]. Waste Management, 2016, 50: 213-221.
- [6] Sahu A K, Biswal S K, Parida A. Development of air dense medium fluidized bed technology for dry beneficiation of coal[J]. International Journal of Coal Preparation and Utilization, 2009, 29(4): 216-241.
- [7] Duan C L, Zhou C Y, Dong L, et al. A novel dry beneficiation technology for pyrite recovery from high sulfur gangue[J]. Journal of Cleaner Production, 2018, 172: 2475-2484.
- [8] Mohanta S, Meikap B C. Influence of medium particle size on the separation performance of an air dense medium fluidized bed separator for coal cleaning[J]. Journal of the Southern African Institute of Mining and Metallurgy, 2015, 115(8): 661-766.
- [9] 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.
- [10] Zhao Y D, He X M. Recognition of coal and gangue based on X-ray[J]. Applied Mechanics and Materials, 2013, 275/276/277: 2350-2353.
- [11] Liang X G, Li Y F, Li Y, et al. The intelligent dry cleaning technology: study application and developing trend[J]. Coal Preparation Technology, 2019(1): 92-96, 102.
梁兴国, 李云峰, 李燕, 等. 智能干选技术研究应用及发展趋势[J]. 选煤技术, 2019(1): 92-96, 102.
- [12] Li W H, Wang Y, Fu B, et al. Coal and coal gangue separation based on computer vision[C]//2010 Fifth International Conference on Frontier of Computer Science and Technology, August 18-22, 2010, Changchun, Jilin, China. New York: IEEE, 2010: 467-472.
- [13] Lee V W, Kim C, Chhugani J, et al. Debunking the 100X GPU vs. CPU myth: an evaluation of throughput computing on CPU and GPU[J]. International Symposium on Computer Architecture, 2010, 38(3): 451-460.
- [14] 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, 2016: 770-778.
- [15] Li Q L, He X F, Wang Y T, et al. Review of spectral imaging technology in biomedical engineering: achievements and challenges[J]. Journal of Biomedical Optics, 2013, 18(10): 100901.
- [16] Wang H L, Peng J Y, Xie C Q, et al. Fruit quality evaluation using spectroscopy technology[J]. Sensors, 2015, 15(5): 11889-11927.
- [17] Hu F, Zhou M R, Yan P C, et al. Multispectral imaging: a new solution for identification of coal and gangue[J]. IEEE Access, 2019, 7: 169697-169704.
- [18] Lai W H, Zhou M R, Hu F, et al. A study of multispectral technology and two-dimension autoencoder for coal and gangue recognition[J]. IEEE Access, 2020, 8: 61834-61843.

- [19] Wang J Q, Li J S, Zhou X W, et al. Improved SSD algorithm and its performance analysis of small target detection in remote sensing images[J]. Acta Optica Sinica, 2019, 39(6): 0628005.
王俊强, 李建胜, 周学文, 等. 改进的 SSD 算法及其对遥感影像小目标检测性能的分析[J]. 光学学报, 2019, 39(6): 0628005.
- [20] Zhao Z Q, Zheng P, Xu S T, et al. Object detection with deep learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(11): 3212-3232.
- [21] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE, 2014: 580-587.
- [22] Feng X Y, Mei W, Hu D S. Aerial target detection based on improved Faster R-CNN[J]. Acta Optica Sinica, 2018, 38(6): 0615004.
冯小雨, 梅卫, 胡大帅. 基于改进 Faster R-CNN 的空中目标检测[J]. 光学学报, 2018, 38(6): 0615004.
- [23] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [24] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 779-788.
- [25] Nguyen D T, Nguyen T N, Kim H, et al. A high-throughput and power-efficient FPGA implementation of YOLO CNN for object detection [J]. IEEE Transactions on Very Large Scale Integration (VLSI) Systems, 2019, 27(8): 1861-1873.
- [26] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 6517-6525.
- [27] Ju M R, Luo H B, Wang Z B, et al. Improved YOLO v3 algorithm and its application in small target detection[J]. Acta Optica Sinica, 2019, 39(7): 0715004.
鞠默然, 罗海波, 王仲博, 等. 改进的 YOLO v3 算法及其在小目标检测中的应用[J]. 光学学报, 2019, 39(7): 0715004.
- [28] Bochkovskiy A, Wang C Y, Liao H Y M. YOLO v4: optimal speed and accuracy of object detection[EB/OL]. [2020-06-05]. <https://arxiv.org/abs/2004.10934>.
- [29] Wang C Y, Liao H Y M, Yeh I H, et al. CSPNet: a new backbone that can Enhance learning capability of CNN[EB/OL]. [2020-06-07]. <https://arxiv.org/abs/1911.11929>.
- [30] He K M, Zhang X Y, Ren S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [31] Liu S, Qi L, Qin H F, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 8759-8768.
- [32] Yu Z, Wang D, You J, et al. Progressive subspace ensemble learning [J]. Pattern Recognition, 2016, 60: 692-705.
- [33] Cao Y, Miao Q G, Liu J C, et al. Advance and prospects of AdaBoost algorithm [J]. Acta Automatica Sinica, 2014, 39(6): 745-758.
- [34] Fawagreh K, Gaber M M, Elyan E. Random forests: from early developments to recent advancements [J]. Systems Science & Control Engineering, 2014, 2(1): 602-609.
- [35] Loh W Y. Fifty years of classification and regression trees[J]. International Statistical Review, 2014, 82(3): 329-348.
- [36] Jiang S Y, Wang L X. Efficient feature selection based on correlation measure between continuous and discrete features[J]. Information Processing Letters, 2016, 116(2): 203-215.