

DOI: 10.19650/j.cnki.cjsi.12210095

基于深度学习的机制砂级配在线检测研究^{*}

黄斐智, 房怀英, 杨建红, 潘维俊

(华侨大学机电及自动化学院 厦门 361021)

摘要: 机制砂的级配和细度模数是工业制砂中重要的质量指标, 针对机制砂级配的传统检测方法无法解决在实际工况下在线检测的问题, 结合实验研究提出了一种基于深度学习的机制砂级配在线检测方法。首先采集传送带上的堆叠机制砂图像, 其次经过卷积神经网络对机制砂图像实例分割, 最后经过图像处理技术在线计算机制砂级配和细度模数。对比实验结果表明, Mask R-CNN 实例分割模型在机制砂堆叠场景下对完整颗粒能有效分割; 采用等效椭圆 Feret 短径作为等效粒径参数, 面积级配作为级配表征参数; 在线检测两组细度模数机制砂的最大重复性误差为 0.03 和 0.05, 粒径区间最大重复性误差为 2.97% 和 3.43%; 相较于传统检测方法, 该检测方法具备可行性, 且能够满足在工业制砂中在线检测的要求。

关键词: 机制砂; 深度学习; 实例分割; 级配; 细度模数

中图分类号: TH741

文献标识码: A

国家标准学科分类代码: 510.4050

On-line detection research on manufactured sand grading based on deep learning

Huang Feizhi, Fang Huaiying, Yang Jianhong, Pan Weijun

(College of Mechanical Engineering and Automation, Huaqiao University, Xiamen 361021, China)

Abstract: The gradation and fineness modulus of manufactured sand are important quality indicators in industrial sand production. To solve the problem that the traditional method of grading detection of manufactured sand cannot be implemented online under the actual working condition. This article combines experimental research to propose an online detection method for manufactured sand grading based on deep learning. Firstly, the images of the stacked manufactured sand on the conveyor belt are collected. Then, the manufactured sand images are segmented by the convolution neural network (CNN). Finally, the gradation and fineness modulus of manufactured sand is computerized online by the image processing technology. Comparative experimental results show that the mask R-CNN instance segmentation model can effectively segment intact particles in the manufactured sand stacking scenario. The equivalent elliptical Feret short diameter is used as the equivalent particle size parameter and the area gradation is used as the gradation characterization parameter. The maximum repeatability error values of online detection of two groups of fineness modulus manufactured sand are 0.03 and 0.05. The maximum repeatability error values of particle size interval are 2.97% and 3.43%. Compared with traditional detection methods, this method is feasible and can meet the requirements of online detection in industrial sand production.

Keywords: manufactured sand; deep learning; instance segmentation; gradation; fineness modulus

0 引言

近年来, 现代建筑领域的发展对于天然砂的需求逐年增大, 天然砂的资源有限性导致供求矛盾突出, 为解决

这一矛盾, 机制砂逐渐取代天然砂以促进生态建材发展。然而, 破碎机生产出来的机制砂级配和细度模数大小参差不齐, 直接影响了混凝土原料用量和性能强度。因此有必要对机制砂的级配进行实时监测, 实现对破碎机的制砂效果进行评价, 同时对破碎机的破碎加工参数优化

收稿日期: 2022-07-08 Received Date: 2022-07-08

^{*} 基金项目: 福建省高校产学研合作项目 (2020H6012, 2021H6029)、福建省科技重大专项专题 (2020YZ017022) 项目资助

起指导意见。所以,开展机制砂级配的在线检测研究具有重要意义。

传统测量机制砂级配使用的方法是振动筛分法,是国家标准采用的检测方法,但筛分法由于筛分过程人工成本和时间成本较大,无法满足实际的工程需要^[1]。随着图像处理技术的快速发展,越来越多学者采用数字图像处理技术实现颗粒检测。Bagheri 等^[2]结合采用了扫描电镜、显微 CT 和图像分析等方法对颗粒的体积和表面积进行研究,通过颗粒的投影面积估计颗粒的表面积、等效直径和球形度。Huang 等^[3]用显微镜采集机制砂和天然砂图像,结合图像处理技术发现天然砂更接近球形且更光滑,而机制砂则更纤细、平坦和粗糙。Yang 等^[4]利用振动分散和高速视频成像技术开发了一种机制砂粒度测量方法,证明了基于成像方法的颗粒大小和形状测量系统满足了机制砂的检测要求。Maitre 等^[5]利用光学显微镜获取矿物颗粒的图像,基于图像技术和机器视觉,首次利用超像素分割代替传统分割方法以分割矿物颗粒。蔡园园等^[6]开发了一套机制砂检测系统,基于数字图像处理的方法,系统提取颗粒的轮廓特征,检测速度快、采用非接触测量不会破坏颗粒的原有形状。黄晓宇等^[7]提出了基于动态图像的机制砂级配测量,研究动态下落的机制砂颗粒图像灰度化、滤波、二值化等预处理方式及粒度、粒形特征提取方法,并设计了一套提取机制砂图像特征及形态参数的图像处理算法。然而,上述测量方法都属于离线采样检测,通过在生产线上取少量的机制砂样本进行离线检测,离线采样检测的方法不具备代表性,严格的检测条件只适用于特定的实验研究,而无法在实际的复杂工况中在线应用。

对于实际工况中大量生产的机制砂,往往是以堆积的状态存在,且基于图像法的在线检测难点在于对图像中重叠的不规则颗粒进行分割。目前,以卷积神经网络(convolutional neural networks, CNN)为代表的深度学习技术在图像分割和目标检测领域取得显著成果^[8],受到了越来越多学者的关注。Hamzeloo 等^[9]结合图像处理和卷积神经网络技术对铜选厂破碎传送回路中颗粒的粒度分布进行估计,发现了最大内切圆是描述颗粒大小的最有效特征,证实了基于 2D(面积)的粒度估计比基于 3D(重量)的更准确。U-Net 网络作为图像语义分割的经典算法得到了学者们的广泛应用,于宁波等^[10]基于 U-Net 网络提出了一种改进的 DRD U-Net(dilated residual and deeply supervised U-Net)模型用于膝关节图像的分割,实验表明该模型提高了膝关节磁共振图像的分割精度。姜枫等^[11]使用卷积神经网络和模糊聚类技术,提出一种 3 阶段颗粒分割方法首次将 CNN 用于提取砂岩图像特征,克服了一般的图像分割方法只能利用图像低层特征,无法适应砂岩矿物中复杂微结构的不足,取得较好的

分割结果。梁雅妮^[12]利用改进后的生成式对抗网络模型 SEG-GAN 以生成式的方式达到对宫颈细胞图片细胞质的分割,SEG-GAN 模型主要针对重叠细胞,这种由定位因子定位每个细胞,进而输入到生成式模型中生成的分割方式,为重叠细胞的难分割问题找到了突破口。

以上研究表明,深度学习技术广泛应用于颗粒分割, CNN 为机制砂的颗粒分割提供了新思路。在基于图像的机制砂级配在线检测中,主要任务是逐一分割图像中每一个完整颗粒以得到颗粒完整轮廓。以往的图像分割更多是借助语义分割的思想^[13],虽然能将前景目标从复杂背景中分割出来,但为获得独立个体仍要通过后期处理。实例分割模型则在进行像素级分类的同时增加了实例级理解^[14-16],Hu 等^[17]提出了一种基于实例分割算法对堆积的粗集料图像进行分割,有效避免了分水岭算法过分割的问题,实现了粗骨料的自动分割。Konopczyński 等^[18]基于 U-Net 和 Mask R-CNN 架构提出一种混合实例分割模型,在密集的芽殖酵母细胞数据集上实现了准确的分割效果。Qiao 等^[19]提出了一种新的实例分割网络模型实现了对隧道开挖现场岩石碎片的实时识别,能够为隧道掘进机掘进过程提供调整参数。因此,实例分割模型更合适完成基于深度学习的机制砂级配在线检测的任务。

针对以上问题,本文提出一种基于深度学习的机制砂级配在线检测方法,首先对机制砂图像进行卷积神经网络实例分割得到掩膜并将其输出,然后基于 OpenCV 计算机视觉库通过阈值分割和寻找轮廓算法寻找掩膜边界并绘制颗粒轮廓图,最后使用等效粒径计算机制砂粒径,并根据标定系数转换成实际粒径后计算各个粒径区间占比得到机制砂级配。通过对比实验证明,该方法可在工业制砂生产线上在线检测机制砂级配和细度模数,和传统筛分法对比检测速度快,误差小,检测方法具备准确性和可行性,能满足实际工程的测量需求。

1 检测流程与方法

基于深度学习的机制砂级配在线检测整体框架如图 1 所示,制砂过程的方法流程主要包括构建检测模型、图像获取、图像分割和获取图像特征模块组成,其中构建检测模型是通过搭建的图像采集系统采集机制砂图像制作成训练样本,然后训练得到实例分割模型;获取图像特征是通过提取基于图像卷积神经网络实例分割得到的颗粒掩膜轮廓,通过相机标定系数计算机制砂真实级配,最后输出反馈参数结果给破碎机实时调整破碎参数。

1.1 检测模型构建

1) 深度学习算法

深度学习模型通常分为 3 类:深度神经网络(deep neural networks, DNN)、CNN 和循环神经网络(recurrent




图 1 检测方法整体框架

Fig. 1 Overall framework of the detection method




图 2 实例分割卷积神经网络结构示意图

Fig. 2 Structure diagram of example segmentation convolution neural network

可知,随着网络加深,优化效果反而更差^[23-24]。残差网络 ResNet 通过恒等映射则让更深的网络也能训练出好的效果^[25]。ResNet 的作者提出 5 种深度的 ResNet,包括 18、34、50、101 和 152 层。此外,在图像中由于大目标物体所占像素较多,经过卷积核的次数比小目标多,经过 CNN 多次卷积后,会出现小目标特征丢失的问题。特征金字塔网络(feature pyramid networks, FPN)结合了 bottom-up 与 top-down 可以更好地提取不同尺度目标丰富的语义信息和边缘特征信息,提高了对小目标的检测精度^[26]。所以,考虑到机制砂图像颗粒尺度大小多变且堆叠工况下的复杂背景对检测精度和效率的影响,本研究采用 ResNet50 结合 FPN 作为 Mask R-CNN 模型的主干网络,对 ResNet 底层到高层(C2~C5)的特征图(feature map)进行融合,充分利用提取 ResNet 中 C2~C5 各个阶段的特征。

neural networks, RNN),而图像数据集更多地应用于 CNN 模型,并取得很好的性能^[20]。在图像目标分割任务中,预测时间和分割精度是模型选择的主要权衡标准^[21],经典 CNN 实例分割模型 Mask R-CNN 是基于 Faster-RCNN^[22]提出的一种实例分割模型,在原有目标检测的基础上添加一个语义分割的全卷积网络分支,为每个 ROI(region of interest)预测对应的二值掩膜,具有良好性能。本研究采用 Mask R-CNN 模型对机制砂图像目标颗粒进行逐一分割以获得颗粒掩膜,实例分割卷积神经网络结构如图 2 所示。

(1) 特征提取主干网络

随着卷积网络层数的增加,CNN 获取的特征越丰富,但从经典的 CNN 模型如 VGG 和 Goog LeNet 等经验

(2) 区域生成网络

区域生成网络(region proposal network, RPN)主要是基于多尺度的锚框对来自特征提取网络的特征图生成区域候选框(proposal)。RPN 采用滑窗的方式,在特征图上用一个 3×3 的窗口进行滑动,将窗口中心对应位置映射回图像,同时通过一个定位卷积层输出候选框的坐标偏移和一个分类卷积层输出候选框的前后景概率。

(3) 感兴趣区域校准

感兴趣区域校准(ROI align)是感兴趣区域池化(ROI pooling)的改进,利用双线性插值的方式对特征图和目标候选区域进行匹配,取消了量化操作,连续地完成特征图特征聚集并池化为固定大小。ROI Align 的引入有效保留了图像中小目标的像素信息,提高了分割掩膜的精度。

(4) 损失函数

网络中损失函数除了 RPN 网络的分类和回归损失函数,由于 Mask RCNN 对每一个 ROI 都输出一个独立二

值掩膜,所以每个 ROI 都对应一个分类损失函数、回归损失函数和掩膜损失函数,总损失函数定义如式(1)所示。

$$L = L_{\text{rpn}} + L_{\text{cls}} + L_{\text{box}} + L_{\text{mask}} \quad (1)$$

式中: L_{rpn} 为 RPN 网络损失函数, L_{cls} 为分类损失函数, L_{box} 为回归损失函数, L_{mask} 为掩膜损失函数。

2) 学习及预测样本

本文采用机制砂图像数据集训练神经网络模型。通过图像采集实验平台采集图片分辨率为 640×640 的机制砂原图,使用 labelme 标注工具对原图进行标注,生成 json 文件,参照 COCO 数据集制作成机制砂图像数据集。由于单张堆叠的机制砂图片包含的颗粒数较多,数据集标注工作量巨大,为减小标注工作量,本文采用自动标注和半自动标注相结合的方法。主要分为 3 个步骤:(1)基于 OpenCV 的阈值分割图像处理方式,对不粘连不堆叠的离散工况机制砂图像进行自动标注,如图 3(a)所示;(2)将自动标注的离散机制砂图像用实例分割算法训练得到初步模型,利用训练好的模型预测只粘连不堆叠的

平铺工况机制砂图像,对预测结果进行图像处理半自动标注,由于预测结果有偏差,所以还需人工审核修改有错误的标注信息,如图 3(b)所示;(3)将制作的只粘连不堆叠机制砂数据集用实例分割深度学习算法训练得到新模型,用第 2 步同样的方法对堆叠工况下的机制砂进行半自动标注,如图 3(c)所示。为提高训练模型的泛化能力,将最终获得的堆叠工况数据集采用包括水平翻转、垂直翻转、亮度变化和伽马变换的数据增强方式对机制砂训练样本进行扩充,如图 4 所示。




图3 机制砂数据集标注图

Fig. 3 Dimension drawing of manufactured sand data set




图4 数据增强扩充样本

Fig. 4 Data enhancement expansion sample

3) 模型训练及优化

本文使用 CNN 实例分割模型在制作的机制砂数据集上进行训练,采用的训练设备为 Intel i9 CPU,搭载 RTX3090 显卡,开发环境为 Python3.7、OpenCV、Pytorch 以及一些必要的依赖库。由于机制砂图像训练样本较少,为提高模型性能,采用如下 3 种模型优化方法:

(1)采用迁移学习的方法对模型进行优化。模型训练时首先加载在官方 COCO 数据集上训练好的预训练权重对网络参数初始化,然后将制作的机制砂图像数据集按 9:1 划分为训练集和测试集后进行训练。

(2)根据样本特点修改模型参数。由于机制砂图像颗粒细小且目标数量最多达上千个,对图片输入分辨率放大为 1024×1024 ,提高非极大值抑制(non-maximum suppression, NMS)前后的 ROI 候选框数量为 3000;调整 5 个先验框尺度为 $(16^2, 32^2, 64^2, 128^2, 256^2)$,设置 3 种长宽比 $(1:1, 1:2, 2:1)$ 。

(3)调整训练超参数。选用 Adam 优化器,设置的基础学习率为 0.001,冲量系数为 0.9,权重衰减为 0.0005;训练迭代次数 Epoch 为 100,批次 batch size 为 1,在 Epoch 为 50 时进行一次学习率调整。

1.2 图像特征提取

机制砂图像通过实例分割模型生成目标颗粒掩膜,为了计算机制砂粒径和级配,需要对颗粒掩膜轮廓进行提取。本文基于 OpenCV 计算机视觉库提供的算法函数,首先通过简单阈值处理函数 threshold () 对颗粒掩膜图进行图像二值化处理,然后通过边界查找函数 findContours () 查找掩膜轮廓,如图 5 所示。




图5 图像特征提取效果

Fig. 5 Image feature extraction effect

图像二值化处理的目的是通过像素点灰度值置为 0 或 255 的方法将目标颗粒和背景分开,最常用的方法是阈值法,确定一个中间灰度值作为阈值标准,高于阈

值的为背景, 低于阈值的为目标颗粒, 表达式如式(2)所示:

$$dst(x, y) = \begin{cases} 255, & f(x, y) > T \\ 0, & f(x, y) \leq T \end{cases} \quad (2)$$

式中: $dst(x, y)$ 为二值图像的像素灰度值, $f(x, y)$ 为当前像素点灰度值, T 为阈值。其中, 最大类间方差法 OTSU 是求图像全局阈值的最佳方法, 方差是灰度分布均匀性的一种度量, OTSU 算法根据图像的灰度特性, 计算比较目标和背景之间的类间方差大小, 类间方差值越大说明错分的概率越小。

提取掩模轮廓的边界查找函数 $\text{findContours}()$ 是基于黑白二值图像的一种轮廓跟踪算法, 对黑白图像像素点进行从左到右和从上到下按列顺序扫描, 当某一像素点 (i, j) 满足外边界起始点图 6(a) 或孔边界起始点图 6(b) 所示条件时, 点 (i, j) 则为轮廓跟踪的起始点。接着在起始点查找邻域像素点作为下一个边界点, 按顺时针将所有边界点连接得到轮廓曲线。




图 6 边界起始点
Fig. 6 Boundary start point

1.3 机制砂形态参数表征

1) 等效粒径表征

在基于图像的机制砂级配测量方法中, 由于机制砂颗粒的形状不规则, 未能找到一种确切的粒径参数进行表征, 对于机制砂等效粒径的表征方法, 本文选取了如下 3 种常用的粒径表征方法进行研究:

(1) 等效椭圆 Feret 短径, 将颗粒形状等效为一个椭圆, 当椭圆的面积和颗粒的投影面积相等, 且椭圆的长轴为颗粒的最大 Feret 径, 该椭圆为等效 Feret 椭圆, 椭圆的短轴为颗粒的等效椭圆 Feret 短径, 如图 7(a) 所示。等效椭圆 Feret 短径的计算公式如式(3)所示。

$$D_f = \frac{4S}{\pi \times F_{\max}} \quad (3)$$

式中: D_f 为等效椭圆 Feret 短径; S 为机制砂颗粒投影面积; $F_{\max}$ 为颗粒最大 Feret 径。

(2) 等效椭圆短轴: 当椭圆的周长和面积都和机制砂颗粒的投影轮廓的周长和面积相等时, 该椭圆的短轴为等效椭圆短轴, 如图 7(b) 所示。等效椭圆短轴的计算公式如式(4)~(6)所示。

$$S = \pi \times a \times b \quad (4)$$

$$C = 2\pi \times b + 4(a - b) \quad (5)$$

$$b = \frac{\pi C - \sqrt{\pi^2 L^2 - 32\pi S(\pi - 2)}}{2\pi^2 - 4\pi} \quad (6)$$

式中: S 为机制砂颗粒投影面积; C 为机制砂颗粒周长; a 为等效椭圆长轴; b 为等效椭圆短轴。

(3) 等效投影面积圆直径: 当一个圆的面积和机制砂颗粒的投影面积相等时, 该圆的直径为等效投影面积圆直径, 如图 7(c) 所示。等效投影面积圆直径的计算公式如式(7)所示。

$$D_s = \sqrt{\frac{4S}{\pi}} \quad (7)$$

式中: S 为机制砂颗粒投影面积; D_s 为等效投影面积圆直径。






图 7 3 种不同的等效粒径计算方法

Fig. 7 Three different calculation methods of equivalent particle size

2) 机制砂级配表征

机制砂级配是各粒径区间内颗粒的质量占比, 由于基于图像法的测量方法无法直接测出颗粒的质量, 本文采用面积和体积来计算各档机制砂占比。

(1) 面积级配, 表示为各粒度区间的机制砂投影面积占所有的机制砂投影总面积的百分率。计算公式如式(8)所示。

$$u_{s_i} = \frac{s_i}{S_A} \times 100\% \quad (8)$$

式中: u_{s_i} 为机制砂各级粒度的面积百分率; s_i 为机制砂各级粒度的投影面积和; S_A 为机制砂投影总面积。

(2) 体积级配, 表示为各粒度区间的机制砂等效体积占所有的机制砂等效体积的百分率。计算公式如式(9)所示。

$$u_{v_i} = \frac{v_i}{V} \times 100\% \quad (9)$$

式中: V_i 为机制砂各级粒度的等效体积和; V 为所有机制砂的总等效体积。

3) 细度模数

(1) 分计筛余百分率, 表示筛分过程中, 每一级标准筛留在网面上的机制砂质量占筛分样本总质量的百分率, 计算公式如式(10)所示。

$$a_i = \frac{m_i}{M} \times 100\% \quad (10)$$

式中: a_i 为各级标准筛的分计筛余百分率; m_i 为各级筛网上的机制砂质量; M 为筛分样本总质量。

(2) 累计筛余百分率, 表示为每一级标准筛及大于该级标准筛的分计筛余率的和, 计算公式如式(11)所示。

$$A_i = a_1 + a_2 + a_3 + \dots + a_i \quad (11)$$

式中: A_i 为各级标准筛的累计筛余百分率; a_i 为各级标准筛的分计筛余百分率。

(3) 细度模数, 表示机制砂粗细程度的指标, 计算公式如式(12)所示。

$$M_x = \frac{(A_2 + A_3 + A_4 + A_5 + A_6) - 5A_1}{100 - A_1} \quad (12)$$

式中: M_x 为细度模数; A_1 、 A_2 、 A_3 、 A_4 、 A_5 、 A_6 分别为 4.75、2.36、1.18、0.6、0.3、0.15 mm 标准筛网的累积筛余率。

2 实验与结果分析

国家标准的级配测量方法是筛分法, 筛分法是机制砂通过不同孔径的筛网, 落到不同的孔径区间。本研究通过设计相关对比实验对方法的性能进行验证, 其中, 为了验证基于深度学习的机制砂级配在线检测方法的准确性和可行性, 分别采用机制砂级配和细度模数作为性能评估指标。另外, 通过统计检测方法的处理时间以验证在线检测方法的时效性。

2.1 实验平台

机制砂级配在线检测系统如图 8 所示, 由一条黑色传送带、LED 光源、CCD 工业相机和计算机图像处理系统组成。当传送带上的机制砂经过相机下方的图像采集

区域时, 由架设的相机和光源组成图像采集系统对机制砂进行拍摄以获取图像数据。




图 8 图像采集实验平台

Fig. 8 Image acquisition experimental platform

2.2 实验材料

本文设计了以下 5 个实验: 1) 对比 Mask R-CNN 和 U-Net 两种分割算法对机制砂堆叠图像的分割效果。2) 对于石灰石机制砂级配料, 采用 3 种不同的等效粒径表征方法和两种不同的级配表征方法与筛分法进行对比实验, 选取最优的表征方法。3) 对于石灰石机制砂两种不同细度模数的级配料分别进行 3 次重复性实验, 验证检测方法的准确性。4) 对于不同材料的花岗岩机制砂和石灰石机制砂, 分别选取 5 种单级料和 3 种细度模数的级配料和筛分法进行对比实验, 验证在线测量机制砂级配检测方法的可行性。5) 通过对比筛分法、动态图像法和本文的在线检测方法, 验证在线检测方法的时效性。

根据本文实验需要, 机制砂筛分的设备采用振筛机, 准备了 5 种粒径区间 (0.15~0.3, 0.3~0.6, 0.6~1.18, 1.18~2.36, 2.36~4.75 mm) 的机制砂单级料, 且按照一定占比用各区间的单级料进行配制不同细度模数的机制砂作为级配料。

2.3 图像分割效果

为了直接证明 Mask R-CNN 实例分割算法对机制砂堆叠图像的分割有效性, 选择另一经典分割算法 U-Net 进行对比, 分别使用同一数据集训练得到模型, 然后对同一张图片进行预测, 分割效果如图 9 所示。




图 9 机制砂图像分割效果

Fig. 9 Image segmentation effect of manufactured sand

观察两种算法的分割效果图,如图 9(b)中蓝色区域,用 U-Net 分割堆叠的机制砂图像,粘连的颗粒出现欠分割的现象严重,即将多个颗粒连通成一个颗粒。如图 9(c)中,用 Mask R-CNN 分割则有效减少了颗粒欠分割现象,因此,基于 Mask R-CNN 在机制砂堆叠场景下能对机制砂完整颗粒实现较准确地分割。

2.4 粒径和级配表征对比实验

针对 1.3 节提到的 3 种不同的等效粒径表征方法和两种不同的级配表征方法,设置对比实验,将实验结果和筛分法对比,确定最佳的粒径表征参数和级配表征参数。为保证变量单一,在确定最佳粒径表征参数时,均采用面积作为级配表征方式;在确定级配表征方式时,均采用等效椭圆 Feret 短径作为粒径表征方式测量机制砂级配。本实验研究所需的机制砂采用福建省石灰石 M_x 为 2.85 级配料。实验结果如表 1 和 2 所示。

由表 1 可知,对于 M_x 为 2.85 的级配料,3 种粒径表征方式测量结果 M_x 都大于筛分法,但是等效粒径为等效椭圆 Feret 短径时, M_x 误差为 0.08,远低于等效椭圆短轴和等效投影面积圆直径作为等效粒径时的 M_x 误差。其中,等效粒径为等效椭圆 Feret 短径时,各档级配占比误差绝对值都在 5% 以内,而等效粒径为等效椭圆短轴和等效投影面积圆直径,分别在区间 0.15~0.3 mm 和 1.18~2.36 mm 误差绝对值大于 8%。由表 2 可知,对于 M_x 为 2.85 的级配料,采用面积级配作为级配表征方式时各粒度区间占比更接近筛分法, M_x 误差远低于采用体积级配作为级配表征方式。综上所述,等效粒径参数为等效椭圆 Feret 短径,且级配表征参数为面积级配时最接近筛分法。

表 1 $M_x=2.85$ 级配料粒径表征方法结果
Table 1 Results of the graded batch particle size representation method for $M_x=2.85$

占比/%	粒径区间/mm					M_x
	0.15~0.3	0.3~0.6	0.6~1.18	1.18~2.36	2.36~4.75	
筛分法	10.00	25.00	40.00	20.00	5.00	2.85
等效椭圆 Feret 短径	5.52	26.24	41.99	22.55	3.67	2.93
△	-4.48	1.24	1.99	2.55	-1.33	0.08
等效椭圆短轴	1.74	26.91	43.72	23.48	4.17	3.01
△	-8.26	1.91	3.72	3.48	-0.83	0.16
等效投影面积圆直径	6.07	22.69	37.26	28.20	5.60	3.04
△	-3.93	-2.31	-2.74	8.20	0.60	0.19

表 2 $M_x=2.85$ 级配料级配表征方法结果
Table 2 Results of the gradation representation method for the gradation of $M_x=2.85$

占比/%	粒径区间/mm					M_x
	0.15~0.3	0.3~0.6	0.6~1.18	1.18~2.36	2.36~4.75	
筛分法	10.00	25.00	40.00	20.00	5.00	2.85
面积级配	5.52	26.24	41.99	22.55	3.67	2.93
△	-4.48	1.24	1.99	2.55	-1.33	0.08
体积级配	1.39	12.82	38.03	36.48	9.82	3.36
△	-8.61	-12.18	-1.97	16.48	4.82	0.51

2.5 机制砂级配料重复性实验

为了验证机制砂粒度在线检测方法的准确性,采用福建省石灰石机制砂,按照一定占比将机制砂配制成细度模数 M_x 为 2.85 和 3.7 的级配料,分别设置了 3 组重复性实验,通过与筛分法比较,得到 3 组实验的最大重复性误差,3 次重复性实验的结果对比如图 10 所示。

由图 10 可知, M_x 为 2.85 和 3.7 的级配料的 3 次重复性实验结果的重复性误差都较小,细度模数最大重复性误差只有 0.03 和 0.05。观察各粒径区间的级配占比可知,两组实验的最大重复性误差不超过 3.5%,其中 M_x 为 2.85 级配料的测量结果最大重复性误差出现在区间 0.6~1.18 mm,为 2.97%; M_x 为 3.7 级配料的测量结果最大重复性误差出现在区间 1.18~2.36 mm,为 3.43%;




图 10 2 种 M_x 的级配料 3 次实验测量结果统计图

Fig. 10 Statistical graphs of the results of three experimental measurements of 2-grade ingredients

综合观察, M_x 为 2.85 的级配料重复性整体比 M_x 为 3.7 更好, 因为细度模数更大即大颗粒占比更大, 颗粒越大其粒形越不规则, 对测量结果影响越大。

2.6 机制砂级配测量与筛分法对比实验

为了验证机制砂级配在线检测方法的可行性, 采用福建省石灰石机和花岗岩机制砂两种材料为实验对象, 进行级配测量实验, 将测量结果和筛分法进行比较, 如果

基于深度学习的在线测量方法和筛分法的误差较小, 则认为该方法具有可行性。

1) 单级料对比实验

本实验分别对石灰石和花岗岩 0.15~0.3、0.3~0.6、0.6~1.18、1.18~2.36、2.36~4.75 mm 5 种粒径区间的机制砂单级料进行实验, 单级料即在该粒径区间的级配占比为 100%, 其他为 0, 测量统计结果如图 11 所示。




图 11 5 种单级料机制砂测量结果统计图

Fig. 11 Statistical graphs of measurement results for five single-grade materials of manufactured sand

根据图 11 可得,5 种粒度中,无论是石灰石还是花岗岩机制砂在区间 1.18~2.36 mm 其测量结果最接近筛分法,石灰石机制砂除了在 2.36~4.75 mm 区间测量结果不足 65%,其他 4 个粒度区间的测量结果接近 75%;花岗岩机制砂则在 0.15~0.3 和 2.36~4.75 mm 区间测量结果接近 65%。由图可以看出,除了在 0.15~0.3 mm 区间石灰石机制砂测量结果明显大于花岗岩机制砂,超过 10%,其他区间两种机制砂测量结果区别不大,而粒度区间越大,石灰石和花岗岩机制砂的测量结果越接近。

2) 级配料对比实验

本实验用 5 种福建石灰石和花岗岩单级料机制砂按照表 3 所示分别配制成 M_x 为 2.85、3.15 和 3.7 的级配料进行实验。3 种 M_x 机制砂级配料实验测量统计结果如图 12~14 所示,为了直观体现误差情况,图中的误差均取绝对值。

表 3 3 种 M_x 级配料各区间占比

Table 3 Percentage of each zone for the three M_x grade ingredients

占比 /%	粒径区间/mm					M_x
	0.15~0.3	0.3~0.6	0.6~1.18	1.18~2.36	2.36~4.75	
	10.00	25.00	40.00	20.00	5.00	2.85
筛分法	10.00	20.00	25.00	35.00	10.00	3.15
	5.00	10.00	15.00	50.00	20.00	3.70

综合分析图 12~14,对于不同细度模数的石灰石和花岗岩机制砂,级配误差在区间 0.6~1.18 mm 显著偏大,且测量结果都显著高于筛分法,同时在区间 2.36~4.75 mm 级配测量结果都低于筛分法,这是因为实例分割时容易将堆叠图像中被表层颗粒部分遮挡的底层大颗粒进行错分割,因此位于中间粒度的 0.6~1.18 mm 占比偏高。粒度区间 0.15~0.3 mm 其测量结果显著低于筛分法,这是因为在这个区间的颗粒细小,由于传送过程振动等因素使颗粒被沉落在大颗粒下面导致拍摄的图像缺乏小颗粒,并且 Mask R-CNN 算法对细小颗粒存在漏分割现象。颗粒越小,石灰石的测量结果越接近筛分法,反之,颗粒越大花岗岩的测量结果越接近筛分法,这是因为颗粒较小,颗粒粒形的影响较小,而石灰石透光性较差,其轮廓更明显;颗粒较大时,花岗岩的粒形较规则,粒形影响较小。

2.7 在线检测时间结果分析

为验证在线检测方法的时效性,将传统筛分法、动态图像法和本文提出的检测方法的平均检测时间进行对比分析。实验选取了一张含有 1 587 个机制砂完整颗粒的图像,在 Intel i9 CPU 和 RTX3090 显卡统计本研究基于




图 12 $M_x=2.85$ 级配料测量结果统计图

Fig. 12 Statistical graph of the results of grade batching measurements of $M_x=2.85$




图 13 $M_x=3.15$ 级配料测量结果统计图

Fig. 13 Statistical graph of the results of grade batching measurements of $M_x=3.15$

深度学习的检测方法的检测时间,各算法模块的处理时间如表 4 所示。根据统计结果,识别和处理一张机制砂图像总共耗时约为 5.06 s,而人工振动筛分法统计 5 kg 机制砂样本约为 30 min,动态图像法取样离线测量 50 g 机制砂约为 8 min。对比分析得,本研究方法检测速度快,能够满足工业生产在线检测的要求。

表 4 检测处理时间结果

Table 4 Detection processing time results

算法模块	处理时间/s
深度学习实例分割	4.486 8
提取掩膜轮廓	0.467 2
计算级配	0.102 8




图 14 Mx=3.7 级配料测量结果统计图

Fig. 14 Statistical graph of the results of grade batching measurements of Mx = 3.7

3 结 论

为解决机制砂级配检测的传统方法无法实现工业制砂实际工况下在线检测的问题,本文结合实验研究提出了一种基于卷积神经网络 CNN 实例分割模型的机制砂级配在线检测方法,通过采集传送带上的堆叠机制砂图像,经过卷积神经网络图像分割和图像处理技术在线计算级配和细度模数。研究结果表明:

1) 采用 Mask R-CNN 实例分割模型能够较准确地对机制砂堆叠工况下的图像进行分割,保证了后续粒径和级配计算的顺利进行。

2) 通过 3 种不同的等效粒径表征方法和两种不同的级配表征方法对比实验,采用等效椭圆 Feret 短径作为机制砂等效粒径参数,且级配表征参数为面积时最接近国家标准筛分法。

3) 两种细度模数的级配料 3 次重复性实验结果的重复性误差都较小,细度模数最大重复性误差只有 0.03 和 0.05,基于深度学习和图像处理的机制砂测量方法准确性较好,而颗粒越小,其重复性越好。

4) 对石灰石和花岗岩两种不同材料的单级料和级配料分别进行实验,花岗岩机制砂计算的细度模数和石灰石相近,最大误差为 0.09。其中级配误差在区间 0.6~1.18 mm 显著偏大的原因是深度学习算法在进行颗粒分割时容易将堆叠图像中被表层颗粒部分遮挡的底层大颗粒进行错分割;0.15~0.3 mm 区间其测量结果显著低于筛分法是因为拍摄的图像细小颗粒被掩盖

和算法的漏分割。颗粒越小,石灰石的测量结果越接近筛分法,反之,颗粒越大花岗岩的测量结果的测量结果越接近筛分法。

该检测方法检测速度快,可实时监测破碎机生产出来的机制砂细度模数,实验证明具有准确性和可行性。在后续的研究工作中,重点在于提高检测精度,需要进一步提高深度学习算法对图像的分割精度和泛化能力。

参考文献

- [1] 蔡斌,王瑞青,叶上游. 动态图像法、激光散射法及筛分法的比较[J]. 炭素,2018(1):27-34.
CAI B, WANG R Q, YE SH Y. Comparison of dynamic image analysis, laser diffraction and sieve analysis[J]. Charcoal Element, 2018(1):27-34.
- [2] BAGHERI G H, BONADONNA C, MANZELLA I, et al. On the characterization of size and shape of irregular particles[J]. Powder Technology, 2014, 270: 141-153.
- [3] HUANG Y M, WANG L H. Effect of particle shape of limestone manufactured sand and natural sand on concrete[J]. Procedia Engineering, 2017, 210: 87-92.
- [4] YANG J H, FANG H Y, CHEN S J. Development of particle size and shape measuring system for machine-made sand[J]. Particulate Science and Technology, 2018, 37(8): 974-980.
- [5] MAITRE J, BOUCHARD K, BÉDARD L P. Mineral grains recognition using computer vision and machine learning[J]. Computers & Geosciences, 2019, 130: 84-93.
- [6] 蔡园园,房怀英,余文,等. 采用数字图像处理的机制砂粒度级配检测方法[J]. 华侨大学学报(自然科学版),2019, 40(5):567-573.
CAI Y Y, FANG H Y, YU W, et al. Digital image processing based particle size grading measurement method for machine-made sand[J]. Journal of Huaqiao University, 2019, 40(5):567-573.
- [7] 黄晓宇. 基于动态图像法的机制砂级配测量及补偿算法研究[D]. 厦门:华侨大学,2020.
HUANG X Y. Study on gradation measurement and compensation algorithm of manufactured sand based on dynamic image method [D]. Xiamen: Huaqiao University, 2020.
- [8] 蓝金辉,王迪,申小盼. 卷积神经网络在视觉图像检测

- 的研究进展[J]. 仪器仪表学报, 2020, 41(4): 167-182.
- LAN J H, WANG D, SHEN X P. Research progress on visual image detection based on convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 167-182.
- [9] HAMZELOO E, MASSINAEI M, MEHRSHAD N. Estimation of particle size distribution on an industrial conveyor belt using image analysis and neural networks[J]. Powder Technology, 2014, 261: 185-190.
- [10] 于宁波, 刘嘉男, 高丽, 等. 基于深度学习的膝关节 MR 图像自动分割方法[J]. 仪器仪表学报, 2020, 41(6): 140-149.
- YU N B, LIU J N, GAO L, et al. Auto-segmentation method based on deep learning for the knee joint in MR images[J]. Chinese Journal of Scientific Instrument, 2020, 41(6): 140-149.
- [11] 姜枫, 顾庆, 郝慧珍, 等. 基于语义特征提取的砂岩薄片图像颗粒分割方法[J]. 中国科学: 信息科学, 2020, 50(1): 109-127.
- JIANG F, GU Q, HAO H ZH, et al. Grain segmentation of sandstone thin section images based on semantic feature extraction (in Chinese) [J]. Sci Sin Inform, 2020, 50(1): 109-127.
- [12] 梁雅妮. 基于深度学习的宫颈细胞图像分割方法的研究[D]. 哈尔滨: 哈尔滨理工大学, 2021.
- LIANG Y N. Research on cell image segmentation based on deep learning [D]. Harbin: Harbin Institute of Technology, 2021.
- [13] LIANG Z, NIE Z, AN A, et al. A particle shape extraction and evaluation method using a deep convolutional neural network and digital image processing[J]. Powder Technology, 2019, 353: 156-170.
- [14] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017: 2961-2969.
- [15] CHEN, X, GIRSHICK R, HE K, et al. TensorMask: A foundation for dense object segmentation [J]. International Conference on Computer Vision, 2019: 2061-2069.
- [16] CHEN H, SUN K, TIAN Z, et al. BlendMask: Top-down meets bottom-up for instance segmentation [J]. Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 8570-8578.
- [17] HU X, FANG H Y, YANG J H, et al. Online measurement and segmentation algorithm of coarse aggregate based on deep learning and experimental comparison [J]. Construction And Building Materials, 2022, 327: 127033.
- [18] KONOPCZYŃSKI T, HEIMAN R, WOŹNICKI P, et al. Instance segmentation of densely packed cells using a hybrid model of u-net and mask R-CNN [M]. Cham: Springer International Publishing, 2020: 626-635.
- [19] QIAO W D, ZHAO Y F, XU Y, et al. Deep learning-based pixel-level rock fragment recognition during tunnel excavation using instance segmentation model [J]. Tunnelling and Underground Space Technology incorporating Trenchless Technology Research, 2021, 115: 1041072.
- [20] 季长清, 高志勇, 秦静, 等. 基于卷积神经网络的图像分类算法综述 [J]. 计算机应用, 2022, 42(4): 1044-1049.
- JI CH Q, GAO ZH Y, QIN J, et al. Overview of image classification algorithms based on the convolutional neural network [J]. Computer Application, 2022, 42(4): 1044-1049.
- [21] ZHAO Z, ZHENG P, XU S, et al. Object detection with deep learning: A review [J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(11): 3212-3232.
- [22] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. Advances in Neural Information Processing Systems, 2015: 91-99.
- [23] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. Arxiv Preprint, 2014, ArXiv: 1409.1556.
- [24] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions [J]. Conference on Computer Vision and Pattern Recognition (CVPR), 2015, DOI: 10.1109/cvpr. 2015. 7298594.
- [25] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [J]. Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.

[26] LIN T Y, DOLLAR P, GIRSHICK R, et al, et al. Feature pyramid networks for object detection [J]. Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 936-944.

作者简介



黄斐智, 2021 年于福建农林大学获得学士学位, 现为华侨大学硕士研究生, 主要研究方向为多模态视觉检测方法及系统开发。
E-mail: huangfz0129@163.com

Huang Feizhi received his B.Sc. degree from Fujian Agriculture and Forestry University in 2021. He is currently a master student at Huaqiao University. His main research interests include multimodal vision inspection method and system development.



杨建红 (通信作者), 2004 年于华侨大学获得硕士学位, 2010 年于华侨大学和日本东北大学获得博士学位, 现为华侨大学教授, 主要研究方向为多模态视觉检测方法及系统开发和基于多平台的机器深度学习算法。
E-mail: yjhong@hqu.edu.cn

Yang Jianhong (Corresponding author) received his M. Sc. degree from Huaqiao University in 2004 and received his Ph. D. degree from Huaqiao University and Tohoku University in 2010. He is currently a professor at Huaqiao University. His main research interests include multimodal vision inspection method and system development and multi-platform based machine deep learning algorithms.