

## 基于卷积神经网络的离焦颗粒粒径与位置测量

张翔云<sup>1,2</sup>, 周骛<sup>1,2\*</sup>, 姜友新<sup>1,2</sup>, 夏向学杰<sup>1</sup><sup>1</sup>上海理工大学能源与动力工程学院, 上海 200093;<sup>2</sup>上海市动力工程多相流动与传热重点实验室, 上海 200093

**摘要** 针对双相机成像系统所获取的颗粒离焦图像, 搭建了基于 Faster-RCNN 和 VGG16 卷积神经网络 (CNN) 的颗粒粒径与位置同步预测模型。在 75~95 mm (约 9~10 倍的成像系统景深) 深度范围内, 拍摄直径为 50~350  $\mu\text{m}$  的 9 种不同圆点用于所提模型的训练, 并将所提模型与基于离焦测距 (DFD) 理论模型的处理方法进行了比较分析。测量结果表明, 与基于 DFD 理论模型的处理方法相比, CNN 模型的颗粒深度测量范围有所提高, 直径测量误差有所降低, 但深度测量误差有所增大。进一步采用双相机系统拍摄在循环样品池内流动的粒径为 120  $\mu\text{m}$  的标准颗粒, 应用所提 CNN 模型对相应图片进行处理, 粒径预测结果的相对误差范围为  $-8\% \sim 8\%$ 。

**关键词** 测量; 卷积神经网络; 双相机离焦成像系统; 位置测量; 粒径测量

中图分类号 TP389.1; TP183

文献标志码 A

DOI: 10.3788/AOS202242.1912006

## Particle Size and Position Measurement of Defocused Particle Based on Convolutional Neural Network

Zhang Xiangyun<sup>1,2</sup>, Zhou Wu<sup>1,2\*</sup>, Jiang Youxin<sup>1,2</sup>, Xia-Xiang Xuejie<sup>1</sup><sup>1</sup>School of Energy and Power Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;<sup>2</sup>Shanghai Key Laboratory of Multiphase Flow and Heat Transfer in Power Engineering, Shanghai 200093, China

**Abstract** A simultaneous particle size and position prediction model based on Faster-RCNN and VGG16 convolutional neural networks (CNNs) is constructed for the defocused images of particles obtained by a dual-camera imaging system. Nine different dots with diameters ranging from 50 to 350  $\mu\text{m}$  are taken in a depth range of 75 to 95 mm (about 9 to 10 times the depth of field of the imaging system) for the training of the proposed model, and the proposed model is compared with the processing method based on the depth from defocus (DFD) model. The measurement results show that compared with the processing method based on the DFD model, the particle depth measurement range of the CNN model is improved, the diameter measurement error is reduced, and the depth measurement error is increased. The standard particles with a particle size of 120  $\mu\text{m}$  flowing in a circulating sample cell are further photographed by a dual-camera system, and the images are processed by applying the proposed CNN model. The relative error of the particle size prediction results ranges from  $-8\%$  to  $8\%$ .

**Key words** measurement; convolutional neural network; dual-camera defocused imaging system; position measurement; particle size measurement

## 1 引言

许多光学技术可以用于含有颗粒流的分散系中的尺寸或速度测量<sup>[1]</sup>, 其中离焦测距 (DFD) 技术是一种通过颗粒离焦信息的数学表征寻找模糊程度与深度位置关系的测量技术, 尤其适用于成像系统景深有限, 清

晰成像范围之外会采集到大量颗粒非聚焦图像的场景。1987年, Pentland<sup>[2]</sup>认为离焦模糊图像原理上是由清晰图像与相应退化函数进行卷积得到的, 并且退化模型服从高斯分布, 因此该高斯分布的标准差可以表示离焦的模糊程度。这种方法优势在于通过函数量化模糊程度后可以固定光学系统, 并且有较大的测量范

收稿日期: 2022-02-28; 修回日期: 2022-03-02; 录用日期: 2022-04-16

基金项目: 国家自然科学基金 (51576130)、上海理工大学校级大创项目

通信作者: \*zhouwu@usst.edu.cn

围<sup>[3]</sup>。2011年,韩丽燕等<sup>[4]</sup>提出了一种基于边缘扩散函数的离焦测距方法,主要原理是通过调制传递函数来描述不同离焦程度的图像,对系统标定后即可得到该物体的距离信息。2016年,赵攀杰等<sup>[5]</sup>利用三孔档板离焦成像原理,对显微离焦颗粒的识别和速度分布进行了研究,结果表明测量出的示踪粒子速度分布与仿真曲线十分吻合。2019年,宋祥磊等<sup>[6]</sup>提出了一种光场显微粒子图像测速方法,该方法用微透镜阵列采集图像,用反卷积算法重建出微流场中示踪粒子的瞬时三维空间位置。2021年,王宵宵等<sup>[7]</sup>提出了离焦粒子轨迹测速方法,通过数值仿真拟合粒子图像的灰度分布来识别离焦特征参数 $\sigma$ ,并将该技术应用于测量射流流场的三维速度分布中。Zhou等<sup>[8-10]</sup>针对离焦二义性问题,提出了基于单镜头双相机系统,结合多种图像处理方法的深度测量技术,可同步测量颗粒的粒径和深度信息。其中,较简单的方法是基于二值化阈值识别颗粒图像,但需要在两个电荷耦合器件(CCD)成像面上的成像具有一定的清晰度,即深度测量区域相对较小,约为4~5倍景深。此外,相应测量系统的颗粒粒径测量下限约为 $20\ \mu\text{m}$ <sup>[10]</sup>,而该系统二维分辨率可低至 $10\ \mu\text{m}$ ,因此从图像处理算法的角度对该测量方法进行改进是有可能的。

近年来,深度学习特别是卷积神经网络(CNN)在图像分类与识别领域中得到了大规模的应用。黄继鹏等<sup>[11]</sup>基于快速区域卷积神经网络(Faster-RCNN)进行了对小目标的识别研究,最小检测精度可达几十像素并且有不错的检测效率。Newby等<sup>[12]</sup>将CNN应用于颗粒的二维平面位置测量中,但尚未对三维位置和粒径大小进行研究。唐睢等<sup>[13]</sup>基于深度学习实现了在较低噪声条件下对光学合成孔径成像系统采集到的模糊图像进行复原,结果显示U型CNN能够实现图像的快速复原。李文健等<sup>[14]</sup>利用CNN从嵌入散斑的单帧复

合图像中获得了相位,提出了一种实现高精度场景下的三维测量方法。程文涛等<sup>[15]</sup>基于神经网络实现了离焦图像去模糊效果,充分显示了神经网络在处理离焦图片上具有较高的稳定性和效率。陈清江等<sup>[16]</sup>基于深度学习发展了一种多聚焦图像融合算法,将聚焦图像与非聚焦图像进行融合,结果显示该算法可以获得较多的高频信息,并在多种评价指标上有不错的表现。

受上述研究的启发,本文针对双相机离焦成像,提出基于CNN直接进行颗粒深度位置和粒径测量的方法。首先,建立基于CNN的颗粒粒径与位置的同步预测模型,用圆点标定板验证该模型的可行性,并分析测量误差。随后,搭建循环样品池实验台,采集循环样品池内标准颗粒的离焦图片,并使用训练好的模型对实际图片进行预测和分析。

## 2 基于卷积神经网络的颗粒粒径与位置测量原理及图像处理流程

### 2.1 双相机离焦测距原理

离焦模糊成像是指在光学成像时,物体没有处在对焦平面而产生的模糊成像现象。单相机在应用DFD时会出现离焦二义性的现象,如图1所示,当物点分别位于 $P_1$ 和 $P_2$ 处时,在 $IS_1$ 成像面上成像的弥散圆直径均为 $D_1$ 。因此,当仅使用 $IS_1$ 成像面采集到的图像来反推颗粒位置时,无法确定颗粒是在 $P_1$ 处还是在 $P_2$ 处。为了解决离焦二义性带来的问题,本课题组提出双相机DFD方法<sup>[17]</sup>,即在 $IS_1$ 的基础上增加一个像距不同的 $IS_2$ 成像面。由图1可知,当物体分别位于 $P_1$ 处和 $P_2$ 处时,在 $IS_2$ 成像面上的成像弥散圆直径分别为 $D_3$ 和 $D_2$ ,如此时利用 $D_1$ 和 $D_3$ 可以唯一确定物体处于 $P_1$ 位置,即一组带有顺序的双相机离焦图片可以唯一地确定颗粒深度位置。图1中 $P'_1$ 和 $P'_2$ 分别为物点位于 $P_1$ 和 $P_2$ 处时的清晰成像位置, $M$ 为光阑直径。




图1 双相机离焦成像原理示意图

Fig. 1 Principle diagram of dual-camera defocused imaging

### 2.2 基于监督学习的卷积神经网络框架

CNN是深度学习的代表算法之一<sup>[18]</sup>,其主要特点是局部连接和共享权值,有监督学习和非监督学习两种训练模式。监督学习是指通过已标注的训练样本进行训练得到一个网络模型,随后通过该模型将需要预测的样本映射为相应的输出,并通过对输出结果

进行简单的分类来实现对未经训练的样本进行分类的目的。非监督学习适用于训练样本不易标注的场景。本文中的训练样本易于标注,因此选择监督学习模式。

本文搭建的CNN框架主要由两部分组成,即用于目标检测的Faster-RCNN和用于分类回归的VGG16。

Faster-RCNN 算法网络结构如图 2 所示,主要由 Fast-RCNN(虚线框所示)与区域候选网络(RPN)两部分组成<sup>[19]</sup>。其中,Fast-RCNN 主要负责提取待测定位矩形框的位置,RPN 主要负责修正目标分类和矩形框位

置。Faster-RCNN 算法将特征抽取、目标框选取和目标框分类集成在一个网络中,使得该网络的性能得到了大幅提高,尤其是检测速度方面,故本文选择 Faster-RCNN 网络作为目标检测的网络模型。

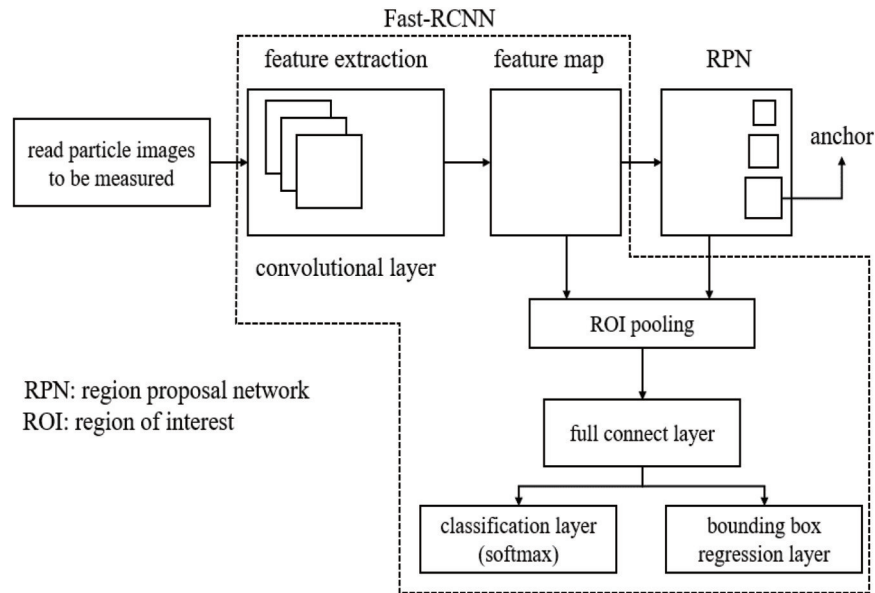


图 2 Faster-RCNN 网络结构<sup>[19]</sup>

Fig. 2 Faster-RCNN network architecture<sup>[19]</sup>

VGG16 是 Simonyan 和 Zisserman<sup>[20]</sup>提出的经典 CNN。该网络通过堆叠尺寸为  $3 \times 3$  的卷积核来实现

卷积过程,主要优势在于结构简洁,训练收敛时间短并且准确率高,图 3 为 VGG16 网络结构图。




图 3 VGG16 网络结构<sup>[20]</sup>

Fig. 3 VGG16 network architecture<sup>[20]</sup>

### 2.3 图像处理流程

所提的基于 CNN 的颗粒粒径与位置的同步预测流程如图 4 所示。本文涉及的图像预处理主要包括图像减背景和对齐两个操作。本文采用的双相机系统采集图像是使用两台相机拍摄的,为消除在采集到的原始图片中存在的背景差异、CCD 本身产生的暗电流噪声的影响并减少计算时间,首先对原始图片进行减背景操作,即用原始图片减去无颗粒物时拍摄的背景图片。在减背景操作之后,需要对图片进行对齐操作,该

操作是为了消除两台相机视场间存在的几何位置和一定角度旋转的差异。采用 Evangelidis 和 Psarakis<sup>[21]</sup>提出的区域对齐算法 Lucas-Kanade 对图片进行对齐校准操作。

随后,将上述预处理后的图片输入 Faster-RCNN 网络中,目标检测完成后可得颗粒所在的二维平面位置和两组单颗粒子图像。由于采用的神经网络模型的输入端口为单输入,将端口改写为双输入又会增加代码的复杂度,故需将单颗粒子图像进行多通道处理。

该操作的主要思路为类比彩色图片将双相机系统采集到的单通道灰度图合成为一张多通道图片(相机一采集到的图片作为 1 通道、相机二采集到的图片作为 2 通道、全 0 矩阵作为 3 通道),合成的这张图片既保留了两

个相机采集的图片信息,又能作为单输入的图片让 VGG16 网络更快速有效地进行回归预测,最终完成对颗粒粒径与位置的同步预测。

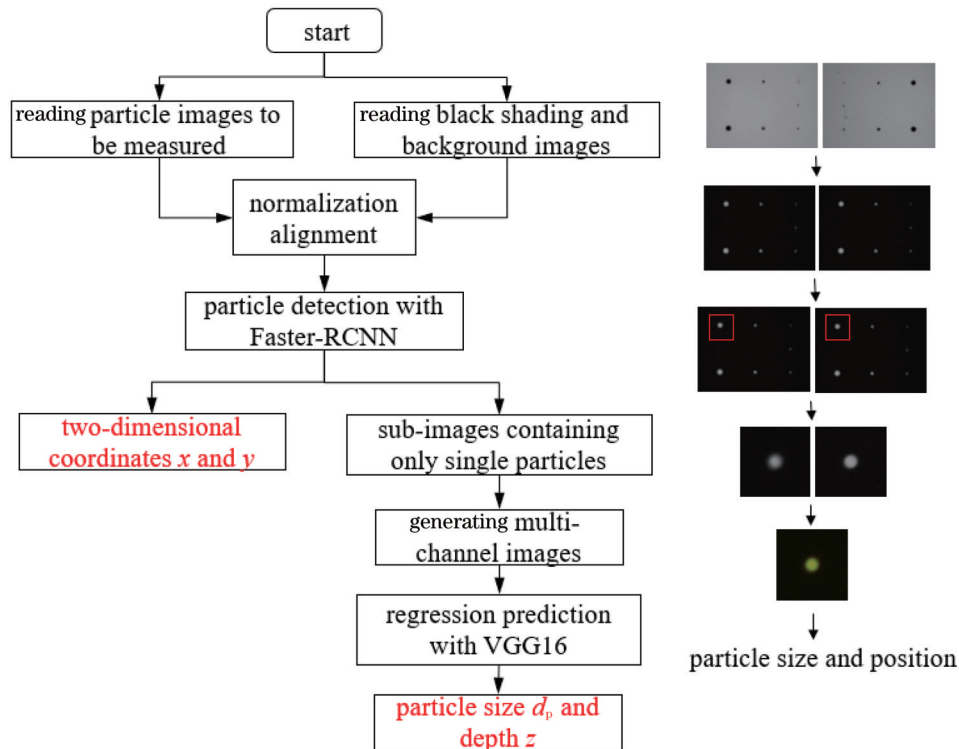


图 4 基于卷积神经网络的颗粒粒径与位置同步预测流程图

Fig. 4 Flow chart of simultaneous particle size and position prediction based on convolution neural network

### 3 基于圆点标定板的实验系统标定及模型的训练

#### 3.1 双相机实验系统

双相机标定实验系统<sup>[17]</sup>主要由相机(两台 IMI 公司生产的型号为 IMC-7020G 的相机)、镜头[灿睿(上海)数字科技有限公司生产的型号为 XF-T1×110 的物方远心镜头]、分光棱镜(Thorlabs 公司生产,边长为 25.4 mm 的立方体)、光源(功率为 10 W 的绿光光源)、步进电机和计算机构成。如图 5 所示,光学系统垂直于光学平台进行布置,并使用背光照明。

由于颗粒的二维平面位置在 Faster-RCNN 网络中可以测出,故将位置训练和预测的重点放在三维深度上,即平行于光轴方向的深度。标定实验将圆点标定板首先放置于光轴方向清晰成像处,控制步进电机以 0.05 mm 为步长从距相机前端面 95 mm 处竖直向上运动至距相机前端面 75 mm 深度位置处。圆点标定板会相应地从成像的前离焦位置移动至后离焦位置处,利用步进电机的输出信号作为双相机的触发信号,步进电机运动到相应位置时便可触发相机采集一次图像,从而获得不同离焦位置下的双相机原始图像序列。每张标定板选取 9 种不同粒径大小(50, 60, 70, 100, 120, 200, 220, 300, 350  $\mu\text{m}$ )的圆点的成像图片作为原

始数据。

#### 3.2 模型的训练与预测

##### 3.2.1 训练与预测数据集的制作

原始图片经过上述预处理流程后,为更好地进行训练数据集的制作和标注,还需对采集到的圆点标定板图片按粒径大小进行分类裁剪、数据增强等操作。

裁剪操作指以圆点圆心为中心裁剪出尺寸为 199 pixel×199 pixel 的子图。裁剪完的部分颗粒序列图如图 6 所示,仅显示了相机 1 获取的图片,横向数值为不同深度位置,纵向数值为不同粒径大小。

通过 CNN 训练出一个最优模型需要大量的原始数据,单从实验获取显然是不够的,故在这部分对合并后的图片采取 4 种图片数据增强的操作,分别为旋转 180°、左右翻转、上下翻转和增加标准差为 0.01 的高斯噪声。本文实验部分采集了 9 种不同粒径大小的圆点图像各 400 张,并通过 4 种数据增强方式获得了 5 倍的数据量,共计 2000 张图像。除去部分圆点粒径过小导致的无效样本,共计 14000 张单颗粒子图像用于训练。

##### 3.2.2 训练及预测结果

本文旨在应用 Faster-RCNN 和 VGG-16 模型对不同粒径和颗粒深度的双相机离焦图像作回归分类。在采集到的图片经过 2.3 节所示的图像处理流程后,随




图 5 双相机系统原理示意图和标定实验台<sup>[17]</sup>。(a)双相机系统原理示意图;(b)标定实验台

Fig. 5 Schematic diagram of dual-camera system and calibration test bench<sup>[17]</sup>. (a) Schematic diagram of dual-camera system; (b) calibration test bench




图 6 裁剪后的部分圆点图片

Fig. 6 Partial dot images after cropping

机选取其中的 90% 作为训练集,剩余的 10% 作为预测集,利用 2.3 节介绍的综合预测网络进行训练,激活函数选用 ReLU,将训练的学习率设置为 0.01,动量因子设置为 0.9,权重衰减值设置为 0.0005。训练集中将 90% 的图片设为训练集,其余的 10% 作为内测试集,内测试集的目的是在训练的反向传播过程中调整训练的方向和速度,训练完成后用该最优模型对预测数据集进行预测。

为了更好地描述颗粒粒径与深度预测结果的优劣,采用深度预测相对误差和粒径预测相对误差作为判定相对误差的依据。深度预测相对误差  $\delta_\omega$  的表达式为

$$\delta_\omega = \frac{\omega_P - \omega_R}{H} \times 100\%, \quad (1)$$

式中: $\omega_P$  为预测深度值; $\omega_R$  为真实深度值; $H$  为能识别样本的最大深度差。粒径预测相对误差  $\delta_D$  的表达式为

$$\delta_D = \frac{D_P - D_R}{D_R} \times 100\%, \quad (2)$$

式中: $D_P$  为预测粒径值; $D_R$  为真实粒径值。

为更好地表现基于 CNN 模型(CNN-based)方法的优势,将所得结果与本课题组基于离焦模糊模型(Model-based)方法得到的结果<sup>[15]</sup>进行对比,粒径和深度预测误差如图 7 所示,横坐标为圆点对应的真实深度值。由图 7(a)、(b)可知,在粒径方面,CNN-based 方法的预测误差要小于 Model-based 方法的预测误差,且 CNN-based 方法的测量范围也大于 Model-based 方

法的测量范围。由图 7(c)、(d)可知,在深度预测方面,CNN-based 方法的预测误差要略高于 Model-based 方法的预测误差,但从测量范围上来看 CNN-based 方法的测量范围大于 Model-based 方法的测量范围。测量范围增大主要原因为:Model-based 方法是基于二值化来识别图像上的颗粒的,这就要求双相机拍摄到的图片都要有一定的清晰度且二值化阈值的选取对结果也有一定的影响,这会造成 Model-based 方法的测量范围受到限制;CNN-based 方法主要是将采集到的整张图像的灰度值输入到计算机中,通过计算机强大的计算力来拟合出图像信息与粒径、深度等信息的最优模型,无需利用二值化来识别图像。综合粒径和深度结果来看,CNN-based 方法要优于 Model-based 方法。

此外,在预测耗时方面,Model-based 方法测量 705 张图像的总耗时为 70 s, CNN-based 方法预测 1123 张图像的总耗时为 37 s,即 CNN-based 方法明显优于 Model-based 方法。

## 4 循环样品池实验及结果分析

采用圆点标定板代替颗粒与实际情况难免不一致,故需要对实际颗粒图片进行预测以证明所提方法的可行性。因此,将圆点标定板换成循环样品池,在循环样品池中加入粒径为 120  $\mu\text{m}$  的标准颗粒,采取 2.3 节所述流程采集循环样品池中的标准颗粒图像并进行图像预处理,用第 3 章中训练出的最优模型对 178 张粒径为 120  $\mu\text{m}$  的标准颗粒进行预测并与 Model-based 方法对比。循环样品池内标准颗粒的粒径预测误差结果

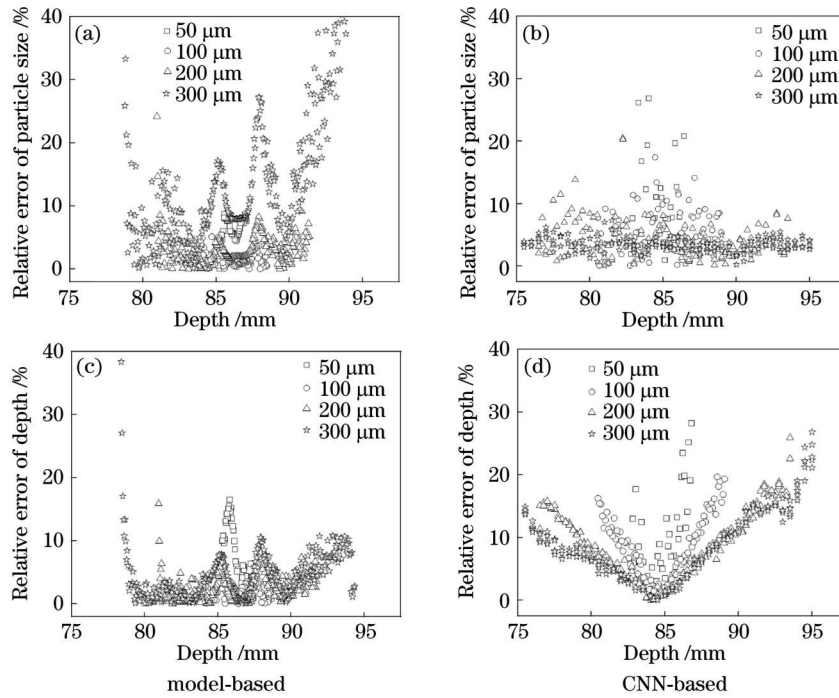


图 7 不同粒径下粒径误差与深度误差的对比。(a)(b)粒径误差;(c)(d)深度误差

Fig. 7 Comparison of particle size and depth errors under different particle sizes. (a)(b) particle size error; (c)(d) depth error

如图 8 所示,纵坐标为粒径相对误差,横坐标为深度预测值与工作距离(83 mm)的差值。由图 8 可以看出:使用 CNN-based 方法时 178 张图像中 167 张图像的粒径预测误差范围为  $-8\% \sim 8\%$ ,占预测样本的 93.8%,明显优于 Model-based 方法(178 张图像中 151 张图像的粒径预测误差范围为  $-8\% \sim 8\%$ ,占预测样本的 84.8%);CNN-based 方法的预测结果与同样深度范围内的圆点标定板的预测结果(平均相对误差为 7.38%)相比,误差有所增大,这可能是实际颗粒在拍摄过程中的流动产生了运动模糊,对离焦模糊成像形成干扰造成的。

在预测耗时方面,CNN-based 方法预测总耗时为 3 s,Model-based 方法预测总耗时为 20 s,即 CNN-based 方法优于 Model-based 方法。

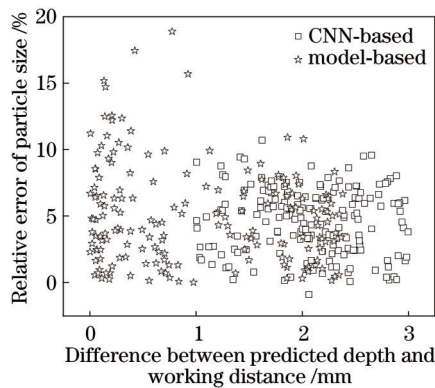


图 8 循环样品池内标准颗粒粒径预测误差

Fig. 8 Size prediction error of standard particles in circulating sample cell

## 5 结 论

搭建了一种基于 Faster-RCNN 和 VGG-16 的 CNN,实现了双相机 DFD 离焦成像系统颗粒粒径与位置测量。首先,基于双相机 DFD 成像原理推导出一组带有顺序的离焦颗粒图像能唯一地确定颗粒深度位置,并提出将双相机 DFD 原理与 CNN 相结合的方法,对颗粒粒径和深度进行测量。然后,使用圆点标定板标定实验验证 CNN 在结合双相机 DFD 方面的可行性。粒径预测结果显示,CNN 方法有 94% 以上的圆点相对误差在  $-10\% \sim 10\%$  以内,高于 Model-based 方法(89%)。进一步将所提方法应用于测量粒径为  $120 \mu\text{m}$  的标准颗粒粒径,93.8% 的预测样本的粒径预测相对误差在  $-8\% \sim 8\%$  以内,高于 Model-based 方法(84.8%)。所提的基于 CNN 模型的颗粒离焦图像处理能够在保证较低粒径测量误差的条件下,获取更大的测量深度范围。此外,深度学习的巨大优势在于完成对深度和粒径综合模型的训练后,对实际图片进行预测的耗时极短,故该网络十分适合进行实时测量。

## 参 考 文 献

- [1] Tropea C. Optical particle characterization in flows[J]. Annual Review of Fluid Mechanics, 2011, 43: 399-426.
- [2] Pentland A P. A new sense for depth of field[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1987, 9(4): 523-531.
- [3] Mannan F, Langer M S. Blur calibration for depth from defocus[C]//13th Conference on Computer and Robot Vision, June 1-3, 2016, Victoria, BC, Canada. New

- York: IEEE Press, 2016: 281-288.
- [4] 韩丽燕, 王黎明, 刘宾. 一种基于边缘扩散函数描述散焦程度的测距算法[J]. 传感器世界, 2011, 17(2): 9-11.  
Han L Y, Wang L M, Liu B. A ranging algorithm based on edge diffusion function to describe the degree of scattered focus[J]. Sensor World, 2011, 17(2): 9-11.
- [5] 赵攀杰, 王昊利, 汪兵, 等. 显微散焦粒子识别与追踪测速[J]. 计算机测量与控制, 2016, 24(8): 298-300, 303.  
Zhao P J, Wang H L, Wang B, et al. Identification and tracking about three-dimensional microscopic defocusing particle[J]. Computer Measurement & Control, 2016, 24(8): 298-300, 303.
- [6] 宋祥磊, 李舒, 顾梦涛, 等. 光场显微成像微尺度流场三维重建方法研究[J]. 光学学报, 2019, 39(10): 1011002.  
Song X L, Li S, Gu M T, et al. Three-dimensional reconstruction of micro-scale flow field based on light field microscopic imaging[J]. Acta Optica Sinica, 2019, 39(10): 1011002.
- [7] 王宵宵, 周骛, 王芳婷, 等. 基于离焦成像的粒子轨迹测速[J]. 光学学报, 2021, 41(19): 1912004.  
Wang X X, Zhou W, Wang F T, et al. Particle streak velocimetry based on defocused imaging[J]. Acta Optica Sinica, 2021, 41(19): 1912004.
- [8] Zhou W, Jin N, Jia M H, et al. Three-dimensional positioning method for moving particles based on defocused imaging using single-lens dual-camera system[J]. Chinese Optics Letters, 2016, 14(3): 31201-31205.
- [9] 罗旭. 基于离焦模糊的颗粒复原与粒径测量研究[D]. 上海: 上海理工大学, 2019.  
Luo X. Particle restoration and size measurement based on defocused images[D]. Shanghai: University of Shanghai for Science and Technology, 2019.
- [10] Zhou W, Luo X, Chen B T, et al. Estimation of particle depth from two defocused images using the Fourier transform[J]. Particuology, 2020, 49: 48-54.
- [11] 黄继鹏, 史颖欢, 高阳. 面向小目标的多尺度 Faster-RCNN 检测算法[J]. 计算机研究与发展, 2019, 56(2): 319-327.  
Huang J P, Shi Y H, Gao Y. Multi-scale Faster-RCNN algorithm for small object detection[J]. Journal of Computer Research and Development, 2019, 56(2): 319-327.
- [12] Newby J M, Schaefer A M, Lee P T, et al. Convolutional neural networks automate detection for tracking of submicron-scale particles in 2D and 3D[J]. Proceedings of the National Academy of Sciences of the United States of America, 2018, 115(36): 9026-9031.
- [13] 唐睢, 王凯强, 张维, 等. 一种基于深度学习的光学合成孔径成像系统图像复原方法[J]. 光学学报, 2020, 40(21): 2111001.  
Tang J, Wang K Q, Zhang W, et al. Deep learning based image restoration method of optical synthetic aperture imaging system[J]. Acta Optica Sinica, 2020, 40(21): 2111001.
- [14] 李文健, 盖绍彦, 俞健, 等. 基于卷积神经网络的单帧复合图像绝对相位恢复[J]. 光学学报, 2021(23): 2312001.  
Li W J, Gai S Y, Yu J, et al. Absolute phase recovery of single frame composite image based on convolutional neural network[J]. Acta Optica Sinica, 2021(23): 2312001.
- [15] 程文涛, 任冬伟, 王旗龙. 基于循环神经网络的散焦图像去模糊算法[J/OL]. 计算机应用研究: 1-7[2022-02-24]. DOI:10.19734/j.issn.1001-3695.2021.11.0635.  
Cheng W T, Ren D W, Wang Q L. Defocus deblurring algorithm based on deep recurrent neural network[J/OL]. Application Research of Computers: 1-7[2022-02-24]. DOI:10.19734/j.issn.1001-3695.2021.11.0635.
- [16] 陈清江, 李毅, 柴昱洲. 一种基于深度学习的多聚焦图像融合算法[J]. 激光与光电子学进展, 2018, 55(7): 071015.  
Chen Q J, Li Y, Chai Y Z. A multi-focus image fusion algorithm based on depth learning[J]. Laser & Optoelectronics Progress, 2018, 55(7): 071015.
- [17] Zhou W, Tropea C, Chen B T, et al. Spray drop measurements using depth from defocus[J]. Measurement Science and Technology, 2020, 31(7): 075901.
- [18] Goodfellow I, Bengio Y, Courville A. Deep learning[M]. Cambridge: The MIT Press, 2016: 326-366.
- [19] 夏禹, 肖金球, 翁玉尚. 基于改进 Faster-RCNN 的偏光片表面缺陷检测[J]. 光学技术, 2021, 47(6): 695-702.  
Xia Y, Xiao J Q, Weng Y S. Surface defect detection of polarizer based on improved Faster-RCNN[J]. Optical Technique, 2021, 47(6): 695-702.
- [20] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2022-02-24]. <https://arxiv.org/abs/1409.1556>.
- [21] Evangelidis G D, Psarakis E Z. Parametric image alignment using enhanced correlation coefficient maximization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 30(10): 1858-1865.