

干涉粒子成像中基于深度学习的低位深散斑图 粒子形状分类

付雨石^{1,2}, 张红霞^{1,2*}, 侯景辉^{1,2}, 贾大功^{1,2}, 刘铁根^{1,2}

¹天津大学精密仪器与光电子工程学院, 天津 300072;

²天津大学光电信息技术教育部重点实验室, 天津 300072

摘要 粒子形状是不规则粒子测量中的一个重要参数,干涉粒子成像(IPI)技术已经被广泛应用于不规则粒子形状表征,但目前仍然缺少从大量散斑数据中对不规则粒子形状进行快速分析的方法。基于 DenseNet 网络,本文提出了一种利用从 IPI 系统获取的离焦散斑对不规则粒子形状直接进行分类的方法,通过改进的模拟粒子系统建立包含超过 7000 张散斑数据的模拟冰晶粒子散斑数据集,在不同位深的情况下对共 9 种形状类别的冰晶粒子离焦散斑进行了网络训练和验证。实验结果表明,散斑数据集上的最高分类精度达到 92.7%,同时在信息压缩比仅为 12.5% 的情况下形状分类精度仍超过 85%。本文提出的方法对 IPI 测量中粒子形状的快速分析具有重要意义,并且可以实现测量散斑数据的低成本存储和高效率传输。

关键词 散射; 干涉粒子成像; 粒子形状; 深度学习

中图分类号 TN247

文献标志码 A

DOI: 10.3788/AOS231180

1 引言

在燃烧、气象学、化妆品安全检测等领域中,对包括尺寸、形态分类、精确形状等参数在内的不规则粒子的测量是一个重要的科学问题。近年来干涉粒子成像(IPI)技术提供了一种可行的解决方案,不规则粒子被准直激光照射,其散射光通过成像系统在离焦位置形成散斑图,被探测器捕获并被进一步处理以进行粒子参数的测量和形态表征^[1-4]。IPI 技术已经广泛地应用于典型不规则粒子如冰晶、沙砾等的尺寸测量^[5-7],同时在形态表征方面,也已经实现了对粒子二维自相关形状^[8]、椭球粒子取向^[9]等的表征。目前的研究聚焦于从离焦图像中检索单个不规则粒子的准确形状^[10-11],然而粒子形状种类的分析 and 表征是当前 IPI 研究中较少涉及的部分,但是在对浓度较高的粒子场进行测量时一幅离焦图像中会同时探测到多个粒子,同时在一次测量任务中也会获得数量庞大的离焦图像数据集,因此从大量离焦图像中对粒子形状进行快速分析和识别是非常重要的。

目标识别和分类是散斑场分析的一个重要研究方向,对于医学、光纤传感和交通安全有着非常重要的意义。近年来,神经网络已经被广泛应用于散斑场的目标识别和分类工作,以及更进一步的目标分类重建工

作^[12]。2015年,Ando等^[13]采集了人脸以及非人脸图像通过散射介质后的散斑图案并进行了分类,准确率超过 90%;2017年,Satat等^[14]利用合成散斑数据训练了神经网络,在真实散斑数据集上的准确度为 73.3%;2018年,Wang等^[15]将支持向量机同卷积神经网络相结合,提出了一种二分类网络 SpeckleNet,在多模光纤传输的人脸与非人脸散斑图案数据集上获得了 96% 的分类准确率;2020年,Kakkava等^[16]基于 MNIST 数据集研究了多模光纤的波长漂移对散斑图案分类的影响,在 50 nm 和 100 nm 波长漂移的情况下分别获得了约 80% 和 70% 的分类准确率。与基于特征提取的散斑分析方法相比,神经网络在压缩感知和分类准确度上有着明显优势,但这些工作中的散斑场主要是目标物体通过一个固定的散射介质如氧化钙薄板^[13]、纸张^[14]、多模光纤^[15-16]等形成的,在散斑形成过程中,一个不变的编码器被用来对目标物体进行编码,神经网络在训练过程中逐渐向这个编码器对应的解码器靠近。然而在 IPI 测量中,不规则粒子的粗糙表面特性决定了每一个粒子的散射光都会形成一个独特的散斑场,即便粒子拥有相同的形状,在这种情况下利用神经网络模拟解码器显然是不可行的。由此引出的另一个问题是离焦散斑的采集和存储,单次测量任务中被测的粒子数量可以达到数千甚至数万个,这显然给数据

收稿日期: 2023-06-25; 修回日期: 2023-07-17; 录用日期: 2023-08-02; 网络首发日期: 2023-08-15

基金项目: 国家自然科学基金(42175097)

通信作者: *hxzhang@tju.edu.cn

的存储和传输带来了巨大的压力^[17]。

由此,本文提出使用神经网络进行散斑图的特征识别来实现基于 IPI 测量的不规则粒子形状分类。本文在实验中应用了一个拥有超过 7000 张不同类别冰晶粒子形状的数据集,并通过改良的数字显微镜模拟粒子系统得到离焦散斑数据集;在原始散斑数据集和低位深散斑数据集上训练了密集连接网络,验证了分类方法的可行性,分析了信息压缩比和灰度阈值对分类精度的影响;对离焦距离和散斑图尺寸的影响进行了讨论。相比于准确粒子形状重建的方法^[10-11],本文提出的方法能够快速获取大量被测粒子的形状信息,对于粒子场的实际测量具有重要意义。

2 理论分析

2.1 模拟粒子干涉成像系统

图 1 展示了在 IPI 系统中获取不规则粒子离焦散斑图的过程。不规则粒子由激光束照明,粒子表面的散射光经透镜收集后在离焦平面形成干涉并被探测器捕获,形成离焦散斑图。通常,在 IPI 测量中将不规则粒子简化为 Dirac 散射体的集合,这些散射体随机分布在粒子的投影形状内^[1]。由于 IPI 系统的尺寸远大于被测粒子的尺寸,可以假设所有的 Dirac 散射体均位于同一平面内,因而可以将不规则粒子表示为二维投影形状,并通过深度学习获得离焦散斑图与形状种类之间的关系。

由于在实验室环境中难以直接获取大量的冰晶粒子散斑数据,基于 Dirac 散射体的思想,本文使用模拟粒子 IPI 系统来生成任意形状不规则粒子的离焦散




图 1 IPI 系统探测不规则粒子散斑图的过程

Fig. 1 Process of detecting defocused speckle of irregular particles in IPI system

斑,实验系统见图 2。532 nm 激光经扩束和准直后照射在数字显微镜设备(DMD, DLP6500FYEHD, 像素尺寸为 $7.56 \mu\text{m}$, 像素数为 $1920 \text{ pixel} \times 1080 \text{ pixel}$)上,由 DMD 形成的模拟粒子的散射光被成像透镜(NF Nikkor 1:1.4D, 焦距为 50 mm)收集,在离焦位置上形成散斑图并被 CMOS 探测器(PointGray, GS3-U3-23S6M-C, 像素尺寸为 $5.86 \mu\text{m}$, 像素数为 $1920 \text{ pixel} \times 1200 \text{ pixel}$)记录。为了使 DMD 和探测器的像素配齐的同时模拟粒子表面的粗糙情况,本实验在光路中加入了一个 $4f$ 系统,同时在 $4f$ 系统的后聚焦面上放置一个足够粗糙的薄毛玻璃(SIGMA, DFSQ1-30C02-240, 240grits)。 $4f$ 系统中的 f_1 为 70 mm, 而 f_2 为 50 mm, 这使得 DMD 上 434×434 的区域与 CMOS 上 400×400 的区域对齐。




图 2 模拟粒子 IPI 系统装置

Fig. 2 Setup of simulated particle IPI system

为了证明在系统中获得的离焦散斑图具有模拟不规则粒子散斑场的能力,在图 3 中展示了同一个特殊粒子形状在数值模拟 IPI 系统和上述系统中的散斑场及其二维傅里叶变换幅值,数值模拟中的系统参数和粒子参数与实际系统一致。根据文献[8], IPI 系统中探测得到的粒子散斑其二维傅里叶变换幅值形状在尺度因子变换下与粒子形状的二维自相关形状保持一致。虽然散斑场具有很强的差异性,这是由于粒子形状上

的出射复振幅不同所致,但二者的二维傅里叶变换幅值表现出了一致性。因此,上述系统成功模拟了粗糙不规则粒子。

2.2 数据采集与处理

输入 DMD 的冰晶粒子形状来自于中国冰晶数据库(ICDC)^[18],该数据集的粒子形状图片来自于 2016 年及 2017 年在河北省上空的机载探测,由云粒子探针获取。根据视觉特征,该数据库中的 7282 张粒子




图 3 不规则粒子形状自相关分析。(a) 模拟冰晶粒子形状; (b) 图(a)自相关运算结果; (c) 模拟粒子 IPI 系统中的离焦散斑; (d) 图(c)的二维傅里叶变换幅值(二值化结果); (e) 实验粒子 IPI 系统中的离焦散斑; (f) 图(e)的二维傅里叶变换幅值(二值化结果)

Fig. 3 Autocorrelation analysis of irregular particle shape. (a) Simulated ice particle shape; (b) autocorrelation calculation result of (a); (c) defocused speckle in simulated particle IPI system; (d) 2D Fourier transform amplitude of (c) binarization result; (e) defocused speckle in experimental particle IPI system; (f) 2D Fourier transform amplitude of (e) binarization result

图片被人工分为 10 个类别,如图 4 所示。首先对数据库中的粒子图片进行了初步筛选,将不完整的冰晶粒子形状从数据集中删除。本文的分类工作仍然基于文献中的粒子类别,但剔除了数量过少的 Ser 类别,最终

得到用于实验的 9 类共 6990 张冰晶粒子图片。为了将这些粒子形状输入 DMD,一个包括二值化和填充的预处理过程被应用于冰晶粒子形状上。

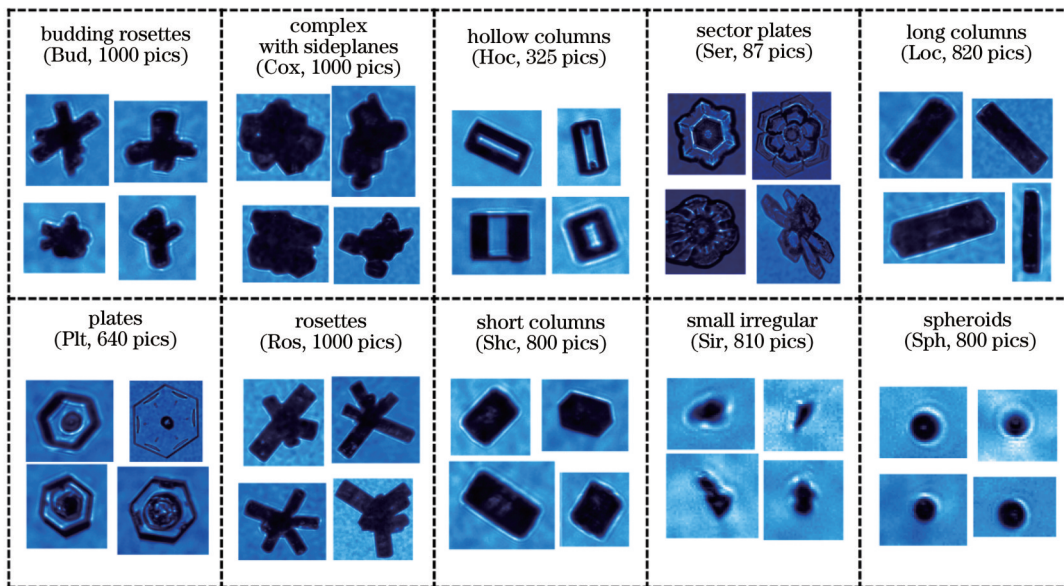


图 4 ICDC 中冰晶形状种类分布及示例

Fig. 4 Shape categories distribution and corresponding examples of ice particles in ICDC

本文提出的粒子形状分类方法如图 5 所示,将大量的冰晶粒子形状输入 DMD 后,通过模拟粒子 IPI 系统获得离焦散斑图并标记为对应形状种类的标签,建立散斑数据的测试集和验证集。在训练步骤中,将训练集的散斑数据输入未训练的神经网络并输出预测类

别,通过计算预测类别和真实类别之间的损失函数值进行参数优化。训练结束后,使用权重优化的神经网络对测试集散斑数据进行形状分类,以测试网络对不同形状类别粒子散斑图的分辨能力。

然而,即使粒子的形状具有极大的差异,由同一块

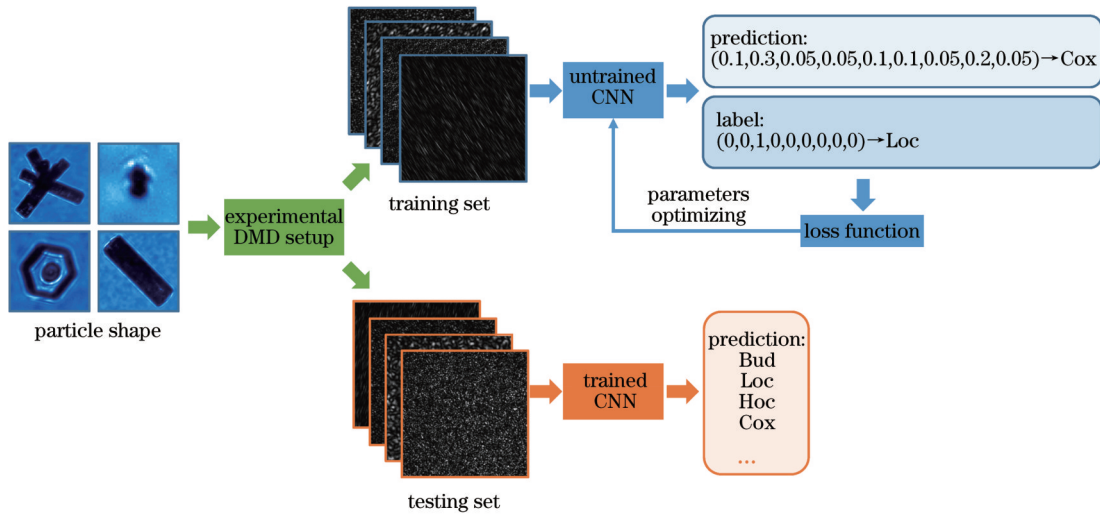


图 5 粒子形状分类网络的训练和测试过程

Fig. 5 Training and testing processes of particle shape classification network

毛玻璃产生的粒子散斑图像同样具有很强的相关性，这与 IPI 系统的实际探测情况并不相符。本文使用散斑相关性和皮尔逊相关系数(PCC)来说明这一点,如图 6 所示。当后聚焦面上的毛玻璃没有变化时,不同粒子形状产生的散斑图虽然在视觉上具有很大差异,但在其互相关图的中心可以观察到明显的峰值;同时,

散斑图之间的 PCC 值也在较高水平,说明这些散斑图之间存在强相关性。上述情况与 IPI 系统的实际探测情况并不相符,因为不同的粒子表面粗糙情况不同,每个 Dirac 散射体的初始幅值和相位各异,通过 IPI 测量系统获得的散斑之间应当不存在相关性。

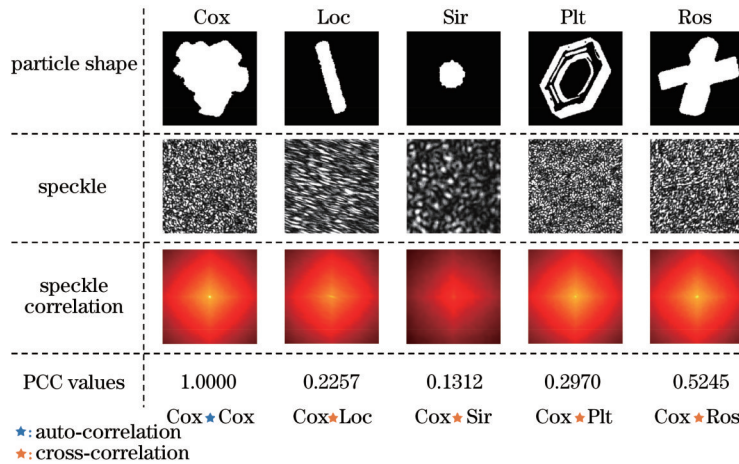


图 6 五种不同冰晶粒子形状类别的离焦散斑和相关性分析

Fig. 6 Defocused speckle and correlation analysis of 5 ice particle shape categories

因此,为了尽可能使得每个粒子形状拥有独特的散斑场,本文在散斑采集过程中对 4f 系统后聚焦面处的毛玻璃应用了特别的更新策略,如图 7 所示。具体而言,在实验中使用 3 个不同的毛玻璃,它们的粒度相同但各自的微结构不同。同时,将所有粒子图片随机分为 140 组,在每组粒子形状对应的离焦散斑被探测之前对毛玻璃进行更新。更新的过程由四种操作随机组合而成:旋转、垂直平移、水平平移以及替换毛玻璃。对于每组被测粒子形状,四种操作都独立地拥有 50% 的概率来决定是否被应用。

需要注意的是,本文在平移(旋转)过程中采用了

一个足够大的距离(旋转角度)来破坏散斑图之间的相关性。图 8 展示了初始离焦散斑与四种更新操作后离焦散斑的相关性。可以看到,更新过程对相关性的破坏是显著的,更新策略后散斑互相关图中心的峰值消失,同时 PCC 值下降到极低水平,说明更新之后散斑图与原始散斑图之间已经失去了相关性。上述结果表明,本文的更新策略达到了为每组粒子形状设置一个独特散斑场的目的。

由于原数据集中 Hoc 类别形状较少,对其均采集了 2 张不同的离焦散斑补充进数据集使得 Hoc 类别的散斑数量扩充至原来的 2 倍;同时,为了进一步破坏每




图 7 毛玻璃更新策略。(a)旋转;(b)水平平移;(c)垂直平移;(d)替换

Fig. 7 Updating strategies of diffuser. (a) Rotating; (b) lateral translating; (c) longitudinal translating; (d) replacing

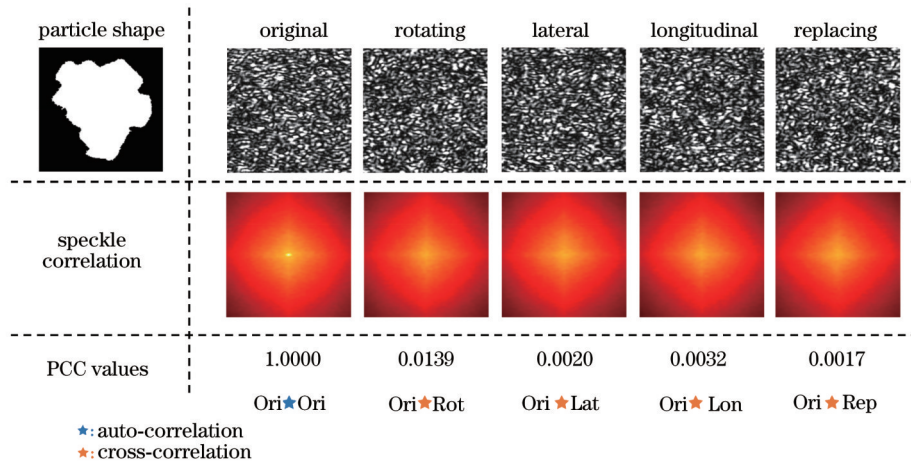


图 8 应用更新策略后散斑相关性的变化

Fig. 8 Variation in speckle correlation after applying updating strategies

组粒子形状内部的散斑相关性,在散斑采集过程结束后,在每个散斑图的中心 800×800 区域中随机裁剪 512×512 大小的区域并标记为对应的粒子形状,最终在每个离焦位置上得到 7301 张离焦散斑构成的数据集用于神经网络的训练和验证。进一步地,将所有离焦散斑按 8:1:1 的比例划分为训练集、验证集以及测试集。

3 结果分析与讨论

3.1 分类网络选择

本文使用 DenseNet^[19] 进行散斑图对应的形状分类工作,其网络结构如图 9 所示。DenseNet 网络的核心是 dense block 结构,该结构内的任意两层网络之间均存在直接连接,因而在当前层学习到的特征也能够直接传递给 dense block 内后续的所有层。这种连接方式使得网络可以设计得更窄从而减少网络参数,同时

可以有效地减少梯度弥散和梯度消失现象。

作为对比,在图 10 中分析了 AlexNet^[20]、ResNet152^[21] 和 DenseNet169^[19] 三种典型的分类网络对冰晶粒子散斑图进行形状分类的结果,训练使用的数据集为在离焦距离 70 mm 位置采集的散斑数据集。对于所有网络,在训练过程中选用多元交叉熵作为损失函数,并使用一个学习率为 0.001 的 Adam 优化器。批大小为 32,训练过程经历 30 个 epoch。神经网络在 Pytorch1.8 上编译并在一个装有 NVIDIA Geforce GTX 2080Ti $\times 2$ 的计算机上训练。

由图 10 和表 1 可知,三种网络中 AlexNet 的训练时间长,同时最终的形状分类精度最低;ResNet152 和 DenseNet169 最终达到的分类精度相差不大,但与 DenseNet169 相比,ResNet152 所需要的训练时间更长,且网络参数数量更大。因此综合考虑后,在后续工作中选择 DenseNet169 进行散斑图的分类。




图 9 DenseNet 结构

Fig. 9 Structure of DenseNet

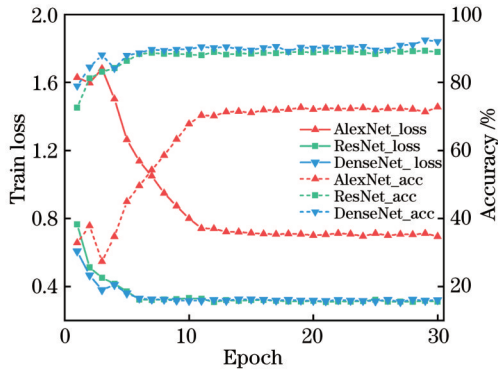


图 10 AlexNet、ResNet152 和 DenseNet169 的训练误差和准确率曲线

Fig. 10 Training loss and accuracy curves of AlexNet, ResNet152, and DenseNet169

3.2 离焦距离

本文在 70、80、90、100 mm 四个不同的离焦距离处分别采集了散斑数据集进行分类,其结果如图 11 所示。对于每个位置的散斑数据集,以不同的初始值进行了 10 次神经网络的训练过程,得到的平均分类精度以及误差棒标注在图 11(a)中。可见在不同的离焦距

表 1 AlexNet、ResNet152 和 DenseNet169 的训练参数对比
Table 1 Comparison of training parameters for AlexNet, ResNet152, and DenseNet169

Network	AlexNet	ResNet152	DenseNet169
Training time /s	3386.1	3581.5	1946.3
Weight size /MB	233.2	222.1	48.6
Number of parameters /M	61.0	60.2	27.2

离下, DenseNet 在训练集上的分类精度均超过了 90%, 最高分类精度为 70 mm 离焦距离处的 92.7%, 并且随着离焦距离的增加分类精度有所下降, 这是由于相同散斑图尺寸下散斑颗粒随离焦距离增加而增大, 使得散斑结构中所隐含的可识别特征减少所致。具体地, 图 11(b) 展示了 DenseNet 在 70 mm 离焦距离测试集上的混淆矩阵, 可以看到, DenseNet 成功地分辨出了散斑图中隐含的粒子种类信息, 并且在 Cox、Ros、Loc 以及 Sph 类别上均取得了接近 100% 的分类精度。同时, 在包含 730 张散斑图的测试集上, 训练好的 DenseNet 仅用 46.3 s 就给出了分类结果, 平均每张散斑图的处理时间仅为 0.06 s, 实现了对大量散斑数据的快速分类。

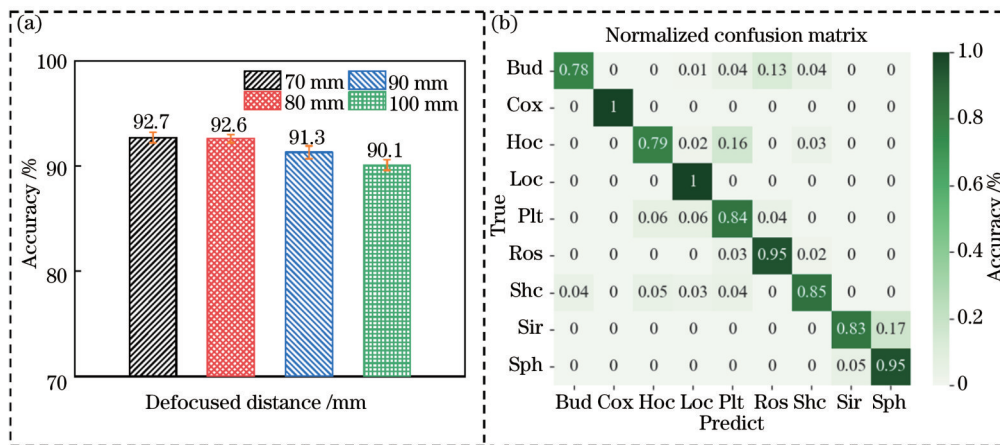


图 11 离焦距离对分类精度的影响。(a) 四个不同离焦距离下的测试集分类精度; (b) 70 mm 离焦距离散斑测试集的混淆矩阵
Fig. 11 Influence of defocused distance on classification accuracy. (a) Testing set classification accuracies at four different defocused distances; (b) confusion matrix of speckle testing set at defocused distance of 70 mm

3.3 数据压缩

对于单次测量任务中数以千万计的散斑数据, 数据集的采集和存储给采集设备和处理终端带来了很大的压力。因此, 希望进行散斑数据的压缩来实现数据采集、存储和处理的优化。位深压缩是一种有效的数

据压缩手段, 在位深压缩过程中散斑失去了大多数的强度信息, 但仍然保留了一定的可识别特征, 因此在本节中通过压缩散斑图的位深来消除 DenseNet 分类中的信息冗余^[22]。在本文实验中采集的原始散斑数据位深为 8 (256 灰度等级), 通过应用灰度阈值可以将其压

缩为更低的位深。具体而言,平均灰度阈值(AGT)被用在原始散斑图上生成 1 位深(2 灰度等级)的散斑图,而多位深(如 2 位深,4 灰度等级)的散斑图则由多

灰度阈值分割策略生成,如图 12 所示。可以看到,位深压缩后 IPI 散斑图仅保留了有限的形状和分布特征。




图 12 不同位深的散斑数据。(a)8 位深;(b)2 位深;(c)1 位深

Fig. 12 Speckle data at different bit depths. (a) 8 bit; (b) 2 bit; (c) 1 bit

应用 DenseNet 对 70 mm 和 100 mm 两个不同离焦距离下的低位深散斑数据集进行了形状分类,其结果如图 13(a)所示,其中,在 70 mm 离焦距离下 1 位深散斑图像的混淆矩阵如图 13(b)所示。随着散斑数据位深的降低,散斑图的信息容量减少,部分特征信息丢失,这直接导致了分类精度的下降。从图 13(b)中可以看到,与原始 8 位深散斑数据相比,形状分类精度的

下降主要体现在低位深情况下神经网络失去了一部分对空心粒子的识别能力(Hoc 与 Shc),而且更难分辨更短的树枝结构(Bud 与 Shc),但在 1 位深的情况下最低的分类精度仍然超过了 85%。同时可以注意到,低位深情况下 DenseNet 仍然对 Cox 以及 Loc 形状类别保持着接近 100% 的分类精度。

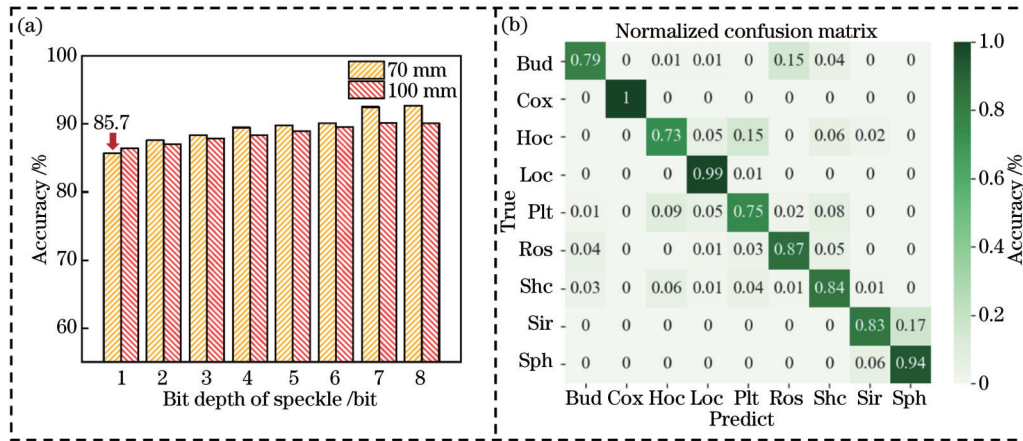


图 13 散斑位深对分类精度的影响。(a)不同位深下的测试集分类精度;(b)70 mm 离焦距离 1 位深散斑测试集的混淆矩阵

Fig. 13 Influence of speckle bit depth on classification accuracy. (a) Testing set classification accuracies at different bit depths;

(b) confusion matrix of 1 bit speckle testing set at defocused distance of 70 mm

用香农信息熵公式来表示离焦散斑数据的信息容量:

$$C = L \lg g_{\max} \quad (1)$$

式中: L 为散斑图尺寸; g_{\max} 为图像中的灰度最大取值范围。在上述实验中,原始散斑图的位深为 8,灰度取值范围为 0~255,尺寸为 512 pixel×512 pixel,此时散斑图的信息容量为 2097152;在位深压缩达到最大的情况下,灰度取值仅有 0 和 1,对于相同尺寸的散斑图,此时的信息容量仅为 262144,压缩比为 12.5%。这意味着仅仅应用散斑图中的部分信息就可以使用 DenseNet 达到超过 85% 的形状分类精度,大大缓解了数据存储和传输的压力。

在以上讨论中,使用 AGT 对原始散斑图进行二值化操作以获得 1 位深散斑图。由于 1 位深散斑图仅由稀疏的非零值组成,散斑数据内非零值的数量关系到散斑数据是否能够进一步以稀疏矩阵的形式进行数据压缩和数据编码,而非零值的数量显然由二值化操作中使用的阈值大小决定。因此,以 AGT 为标准选取了一系列灰度阈值进行二值化操作来分析散斑的稀疏程度对分类精度的影响,这些阈值包括 0.25AGT、0.5AGT、1.0AGT、1.5AGT、2.0AGT,以及 3.0AGT,如图 14(a)所示。

用 1 位深散斑图中零值的占比来表征二值化后散斑数据的稀疏程度:

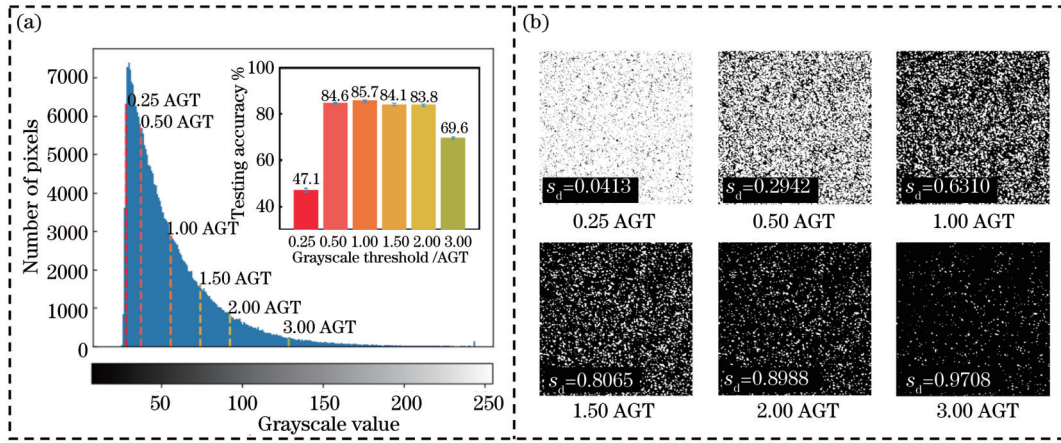


图 14 二值化阈值对 1 位深散斑数据分类精度的影响。(a) 原始散斑灰度直方图和二值化阈值。插图: 不同阈值下散斑数据分类精度; (b) 不同灰度阈值对应的 1 位深散斑和稀疏程度

Fig. 14 Influence of binarization threshold on classification accuracy of 1-bit speckle data. (a) Grayscale histogram of raw speckle and binarization thresholds. Inset: classification accuracies of speckle data under different thresholds; (b) 1-bit speckle and its sparsity corresponding to different grayscale thresholds

$$s_d = \frac{N_{zero}}{N_{total}}, \quad (2)$$

式中, N_{zero} 与 N_{total} 分别为 1 位深散斑图中零值的数目以及总像素数。不同阈值策略下散斑数据的示意图及其稀疏程度如图 14(b) 所示, 在这些 1 位深散斑数据集上训练了 DenseNet 模型并对其分类准确度进行了验证, 其结果见图 14(a)。可见, 随着散斑数据稀疏程度的上升, 冰晶粒子形状的分类精度出现下降的趋势, 并且在二值化阈值接近 AGT 时 DenseNet 对数据集的分类精度最高, 说明此时散斑结构保留得最为完整。同时, 当散斑的稀疏程度过高或者过低时, 形状分类的准确程度都会迅速下降, 这是因为两种情况下散斑的颗粒结构均被严重破坏, 导致神经网络无法对其进行分辨。因此, 在对原始散斑数据进行二值化操作时应当选取 AGT 附近的阈值以获得更高的分类

精度。

3.4 散斑图尺寸

由于进行分类的数据对象是散斑图, 其尺寸越大, 对卷积神经网络而言所隐含的可识别特征越多, 因此散斑图的尺寸同样是决定形状分类精度的一个重要因素。在以上的分类实验中散斑图尺寸固定为 512×512 , 本文在相同的散斑图数据集的每张散斑图中分别随机截取 256×256 , 128×128 , 64×64 大小的散斑片段形成对应尺寸的散斑数据集, 并分别训练了 DenseNet 进行分类, 其结果如图 15 所示。可见, 随着散斑图尺寸的减小, 形状分类的精度不断下降, 在散斑图尺寸为 64×64 时下降为 75%, 说明 DenseNet 此时无法给出满意的分类结果。因此, 为实现粒子形状的正确分类, 不应使散斑图的尺寸过小, 以保证神经网络可以识别到散斑图中隐含的粒子形状特征。

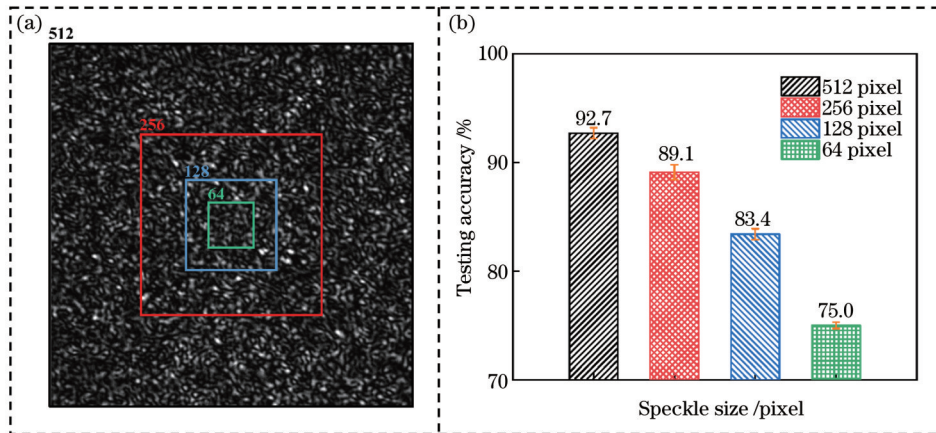


图 15 散斑图尺寸对散斑数据分类精度的影响。(a) 不同尺寸的散斑片段; (b) 不同散斑图尺寸下的测试集分类精度

Fig. 15 Influence of speckle pattern size on classification accuracy of speckle data. (a) Speckle slices of different sizes; (b) testing set classification accuracies of different speckle pattern sizes

4 结 论

本文提出了一种基于深度学习的冰晶粒子形状快速分类方法,通过搭建模拟粒子 IPI 系统采集并建立了冰晶粒子形状 IPI 散斑数据集,训练 DenseNet 进行形状分类的训练和验证。实验结果表明,训练好的 DenseNet 能够在短时间内对大量散斑图进行精确的形状分类,最高分类精度达到 92.7%。进一步地,通过减少位深的方法对散斑数据进行了压缩,在信息压缩比仅为 12.5% 的情况下对冰晶粒子形状的最小分类精度仍超过 85%。此外,对不同离焦距离和散斑图尺寸下粒子形状的分类精度也进行了分析和讨论。本文提出的方法对于 IPI 测量中大量散斑数据的快速分析具有重要意义,同时极大地节省了散斑数据所需的内存空间,提高了数据传输效率。

参 考 文 献

- [1] Brunel M, Coetmellec S, Grehan G, et al. Interferometric out-of-focus imaging simulator for irregular rough particles[J]. Journal of the European Optical Society: Rapid Publications, 2014, 9: 14008.
- [2] Ouldarbi L, Talbi M, Coetmellec S, et al. 3D-shape recognition and size measurement of irregular rough particles using multi-views interferometric out-of-focus imaging[J]. Applied Optics, 2016, 55(32): 9154-9159.
- [3] Wu X C, Shi L, Lin Z M, et al. Dual-beam interferometric particle imaging for size and shape characterization of irregular coal micro-particle: validation with digital inline holography[J]. Journal of Quantitative Spectroscopy and Radiative Transfer, 2020, 241: 106728.
- [4] Zhang H X, Li Z H, Sun J L, et al. Characterization of particle size and shape by an IPI system through deep learning[J]. Journal of Quantitative Spectroscopy and Radiative Transfer, 2021, 268: 107642.
- [5] Brunel M, Lemaitre P, Porcheron E, et al. Interferometric out-of-focus imaging of ice particles with overlapping images[J]. Applied Optics, 2016, 55(18): 4902-4909.
- [6] Talbi M, Grehan G, Brunel M. Interferometric particle imaging of ice particles using a multi-view optical system[J]. Applied Optics, 2018, 57(21): 6188-6197.
- [7] Brunel M, Delestre B, Talbi M. 3D-reconstructions for the estimation of ice particle's volume using a two-views interferometric out-of-focus imaging set-up[J]. Review of Scientific Instruments, 2019, 90(5): 053109.
- [8] Brunel M, González Ruiz S, Jacquot J, et al. On the morphology of irregular rough particles from the analysis of speckle-like interferometric out-of-focus images[J]. Optics Communications, 2015, 338: 193-198.
- [9] Sun J L, Zhang H X, Li Z H, et al. Determining speckle orientation of interferometric out-of-focus images[J]. Journal of Quantitative Spectroscopy and Radiative Transfer, 2019, 226: 73-80.
- [10] Shen H H, Wu L Y, Li Y L, et al. Two-dimensional shape retrieval from the interferometric out-of-focus image of a nonspherical particle—part I: theory[J]. Applied Optics, 2018, 57(18): 4968-4976.
- [11] Delestre B, Abad A, Talbi M, et al. Experimental particle's shapes reconstructions from their interferometric images using the Error-Reduction algorithm[J]. Optics Communications, 2021, 498: 127229.
- [12] 鄢江磊, 唐唯, 吴计, 等. 卷积神经网络在光学信息处理中的应用研究进展[J]. 激光与光电子学进展, 2021, 58(16): 1600001.
Di J L, Tang J, Wu J, et al. Research progress in the applications of convolutional neural networks in optical information processing[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1600001.
- [13] Ando T, Horisaki R, Tanida J. Speckle-learning-based object recognition through scattering media[J]. Optics Express, 2015, 23(26): 33902-33910.
- [14] Satat G, Tancik M, Gupta O, et al. Object classification through scattering media with deep learning on time resolved measurement[J]. Optics Express, 2017, 25(15): 17466-17479.
- [15] Wang P, Di J L. Deep learning-based object classification through multimode fiber via a CNN-architecture SpeckleNet[J]. Applied Optics, 2018, 57(28): 8258-8263.
- [16] Kakkava E, Borhani N, Rahmani B, et al. Deep learning-based image classification through a multimode fiber in the presence of wavelength drift[J]. Applied Sciences, 2020, 10(11): 3816.
- [17] Dunker C, Roloff C, Grassmann A. Interferometric laser imaging for in-flight cloud droplet sizing[J]. Measurement Science and Technology, 2016, 27(12): 124004.
- [18] Xiao H X, Zhang F, He Q S, et al. Classification of ice crystal habits observed from airborne cloud particle imager by deep transfer learning[J]. Earth and Space Science, 2019, 6(10): 1877-1886.
- [19] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [20] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [21] 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.
- [22] Zhou Z Y, Xia J, Wu J, et al. Learning-based phase imaging using a low-bit-depth pattern[J]. Photonics Research, 2020, 8(10): 1624-1633.

Deep Learning-Based Particle Shape Classification Using Low-Bit-Depth Speckle Patterns in Interferometric Particle Imaging

Fu Yushi^{1,2}, Zhang Hongxia^{1,2*}, Hou Jinghui^{1,2}, Jia Dagong^{1,2}, Liu Tiegen^{1,2}

¹*School of Precision Instrument and Opto-Electronics Engineering, Tianjin University, Tianjin 300072, China;*

²*Key Laboratory of the Ministry of Education on Optoelectronic Information Technology, Tianjin University, Tianjin 300072, China*

Abstract

Objective Particle shape is an important parameter in irregular particle measurement, which has scientific and practical significance for studying environmental climate changes and ensuring engineering production safety. The interferometric particle imaging (IPI) technique has been widely employed in recent years to measure the sizes and shapes of irregular particles. Irregular particles form complex speckle patterns at defocused planes, which have been utilized to retrieve size and shape features such as 2D auto-correlation estimation and particle orientation. However, there are still two main problems during processing defocused speckles detected in IPI measurement. On one hand, the existing methods in IPI have slower processing time and thus incur significant time costs when processing large amounts of speckle data. On the other hand, a large amount of speckle data also brings enormous pressure to the storage and transmission of detected datasets. Therefore, we propose a method for rapid shape analysis of a large number of defocused speckles to reduce the memory cost brought by the dataset through data compression.

Methods We apply a deep learning method to rapidly analyze large amounts of defocused speckle data of ice crystal particles collected by the IPI system. The proposed method includes two steps of data collection and network training. In data collection, we build an experimental particle IPI system to obtain a sufficient number of defocused speckles of ice crystal particles and provide different particle shapes in the dataset with unique speckle fields through the diffuser update strategy. In network training, we adopt the DenseNet network structure to classify the shapes corresponding to the speckle patterns, input the speckle data of the training set into the untrained DenseNet, and output the prediction category. After completing the training step, trained DenseNet is leveraged to classify the shape of the test set speckle data to test the ability to distinguish particle speckle patterns of different shape categories. Furthermore, we utilize bit-depth compression to compress the speckle dataset to eliminate information redundancy in DenseNet classification. Meanwhile, the original speckle dataset is segmented by a grayscale threshold strategy to generate a low bit-depth speckle dataset, and DenseNet is trained for shape classification and feasibility verification.

Results and Discussions By comparing three different network structures (Fig. 10 and Table 1), we choose the DenseNet structure for speckle classification. Firstly, we compare the classification accuracy of DenseNet under defocused speckle dataset from different defocused distances. The experimental results (Fig. 11) show that the classification accuracy exceeds 90% at all four different defocused distances, with the highest accuracy up to 92.7%. Our experimental results on low bit-depth speckle datasets (Fig. 13) show that the classification accuracy of DenseNet decreases with the reducing speckle data bit-depth, while the lowest classification accuracy still exceeds 85% when the information compression ratio reaches 12.5%. For the 1 bit-depth speckle data with the lowest information compression ratio, the classification results of the dataset (Fig. 14) indicate that the threshold near the average grayscale threshold could achieve the highest classification accuracy. Moreover, the speckle sparsity increases with the rising binarization threshold. Finally, the size analysis of the defocused speckle (Fig. 15) indicates that the size of the defocused speckle pattern cannot be too small to ensure that the neural network can recognize the hidden particle shape features in the speckle pattern.

Conclusions The proposed deep learning-based method can rapidly analyze the shape information of a large number of defocused speckle patterns detected in IPI measurement. The experimental results show that compared with traditional methods, our method has an average processing time of only 0.06 s for each defocused speckle pattern to greatly reduce the time cost of speckle processing. Meanwhile, the trained DenseNet network has high classification accuracy on the collected ice crystal particle speckle dataset with a maximum of 92.7%. Furthermore, DenseNet trained on low bit-depth speckle datasets still maintains classification accuracy of over 85% with a minimum information compression ratio of 12.5%, significantly reducing the data storage and transmission pressure. Thus, this method is of significance for rapidly analyzing a large amount of speckle data in IPI measurement and could facilitate low-cost storage and efficient transmission of speckle data.

Key words scattering; interferometric particle imaging; particle shape; deep learning