

基于卷积神经网络的相位体自动识别方法研究

季颖^{1*}, 龚凌冉¹, 傅爽², 王亚伟¹

¹江苏大学物理与电子工程学院, 江苏 镇江 212013;

²南方科技大学生物医学工程系, 广东 深圳 518055

摘要 针对定量相位成像技术中样本形态信息提取繁琐不利于自动化检测分析的问题,探索了基于小规模数据集对轮廓相似的相位物体进行精准识别的可行性及其训练策略。分别建立了包括聚苯乙烯微球、红细胞等4类样本的相位分布和干涉条纹数据集。构建了一个卷积神经网络(CNN)模型成功实现对相位图的识别,进而对不同样品相位值进行变换以增大识别难度,并通过改进网络模型在验证集上成功识别出所有样品类型。为简化检测流程,对4类样本对应的干涉条纹进行了识别,用残差模块改善CNN模型的网络退化问题实现了准确分类。针对条纹可见度、载波频率复杂多变的实际情况,分别考查了其对识别准确率的影响。通过优化训练集提高了模型的识别效率,表明了机器学习技术在相位信息识别方面的潜力。

关键词 医用光学; 相位分布; 干涉条纹; 自动识别; 卷积神经网络; 残差网络

中图分类号 O436

文献标志码 A

doi: 10.3788/LOP202259.0617026

Automatic Phase Recognition Method Based on Convolutional Neural Network

Ji Ying^{1*}, Gong Lingran¹, Fu Shuang², Wang Yawei¹

¹*School of Physics and Electronic Engineering, Jiangsu University, Zhenjiang, Jiangsu 212013, China;*

²*Department of Biomedical Engineering, Southern University of Science and Technology, Shenzhen, Guangdong 518055, China*

Abstract Aiming at the problem that the extraction of sample morphological information in quantitative phase imaging technology is cumbersome and not conducive to automatic detection and analysis, the feasibility and training strategy of an accurate recognition of phase objects with similar contour based on small-scale datasets are explored. The phase distribution and interference fringe datasets of four types of samples, including polystyrene microspheres and red blood cells are established accordingly. A convolution neural network (CNN) model is constructed to recognize the phase diagram successfully, and then the phase values of different samples are transformed to increase recognition difficulty. All sample types are successfully recognized on the verification set by improving the network model. To simplify the detection, the interference fringes corresponding to four types of samples are identified. The residual module is used to improve the network degradation of CNN model and realize an accurate classification. According to the actual situation of complex and changeable fringe visibility and carrier frequency, the impact on the recognition accuracy is investigated, respectively. The recognition efficiency of the model is improved via optimizing the training set, which shows the potential of machine learning technology in phase information recognition.

收稿日期: 2021-06-28; 修回日期: 2021-08-07; 录用日期: 2021-08-31

基金项目: 江苏大学农业装备学部项目(NZXB20200215)、江苏大学学生科研立项项目(19A253)

通信作者: jy@ujs.edu.cn

Key words medical optics; phase distribution; interference fringe; automatic recognition; convolution neural network; residual network

1 引言

定量相位成像(QPI)^[1-2]是一种适用于透明样品的成像技术,无需进行染色、标记等预处理^[3-5]便可快速无损地观测原态样品。QPI技术得到的是一系列干涉或衍射光强分布图,是从由样品引起的包含结构信息的相移中定量提取出来的。随着人工智能热潮的涌来,深度学习技术^[6-10]逐渐走进人们的视野并逐步应用于QPI技术领域,如相位恢复、条纹分析、三维成像等。在分类识别方面,Majeed等^[11-12]尝试将机器学习与定量相位成像技术相结合,实现了对乳腺癌的病变识别以及前列腺癌的自动化Gleason分级,检测数据吞吐量得以增大。Trujillo等^[13]利用卷积神经网络(CNN)技术在原始全息图中直接检测并计数红细胞,准确率达到人工判别水平。上述工作在分辨率、准确率方面都取得了非常可喜的进展,但是关注的样本或是物理厚度固定的组织切片或是同种类细胞。而临床上常用的血细胞分类检测针对的是悬浮细胞,包括红细胞和白细胞亚类等,样品位置和姿态各异,在光入射方向上的厚度难以确定。并且相移量除了与样品局部厚度和折射率有关,还受到参考面性质、入射光方向等因素的影响,这就给制定可广泛应用的特征提取标准和统一标准化的大数据集带来了困难,因而相位信息下的生物细胞自动化分类识别工作尚不多见。

正是基于这样的背景,鉴于CNN方法在图像识别分类问题上的优异表现^[14]及相位分布矩阵与图像数据的相似性,本文提出了两种CNN模型,从相位分布或干涉条纹空间变化与样品结构特征存在的直接关联出发探讨相位信息自动识别的可行性。考虑到研究对象的可操作性和实际应用价值,本文选取直径为8 μm 的标准聚苯乙烯微球和临床上常用的指标物质——红细胞作为实验样本,辅以无相位体噪声和仿真获得的人血小淋巴细胞相位及其干涉条纹共同构成数据集^[15-17],在此基础上尝试了基于机器学习的相位图像和干涉条纹识别。针对不同类型的数据,从神经网络模型搭建和训练集构成两方面探究了深度学习训练策略,并通过实验初步验证了该策略的可行性和准确性。

2 基于相位分布的识别

对于相位图的自动识别,由于样本的多样性和实验条件的限制,本实验组采用实验采集和数值仿真两种方式建立数据集。实验所用红细胞来自健康成年男性血液,聚苯乙烯微球直径为8 μm ,折射率为1.588,均以质量分数为0.9%的生理盐水为环境液。考虑到样品成像时,杂质的存在或是液面不均匀导致的干扰经常会影响到分类识别的结果,本实验组以无相位体噪声图作为样品的一种。样品相位分布数据由免标记数字细胞成像系统Biophase^[18]获得,实验获得的视场界面中有多个细胞分布,若需要采集单个细胞进行分析,则需要对全视场相位图像进行感兴趣区域提取。此外本实验组还通过Matlab软件模拟了小淋巴细胞的相位分布图,用以代表一类双介质相位体。设该模型为球形,直径在6~9 μm 之间随机选取,细胞核大小比细胞尺寸小0.5~1.5 μm ,环境液、细胞质、细胞核折射率分别为1.33、1.37、1.45。

实验采集了36幅红细胞相位图、221幅空白噪声相位图、50幅聚苯乙烯微球相位图,通过仿真模拟了200幅小淋巴细胞相位图,所有样品的相位分布图均表征着面积为12 $\mu\text{m} \times 12 \mu\text{m}$ 的实际视场。上述实验采集的红细胞和聚苯乙烯微球的数据量仍不足以支撑训练集训练,故通过数据增强^[19]对红细胞和聚苯乙烯微球的相位图进行随机角度的旋转和翻转。最后得到了867幅相位分布图,其中红细胞相位图有216幅,聚苯乙烯微球相位图有230幅,无相位体的噪声图有221幅,小淋巴细胞相位图有200幅。基于训练集数据的数量应占总数2/3~4/5的原则,每次训练从各类样本中随机均匀抽取50幅作为测试集(即总共包括200幅相位分布图),剩余667幅用作训练集。图1分别展示了在一次训练时抽取的测试集和训练集数据,其中4类样品各选取一幅图像进行展示。由于多次实验下的不确定性,为测试模型的泛化能力,没有刻意选取和训练集一致性好的数据,而是随机选取并加入了一些噪声等其他干扰较大、质量较差的图形,因此训练集和测试集中的相位图会有一些差异。例如测试集中图1(b)所示的聚苯乙烯微球,其球心位置

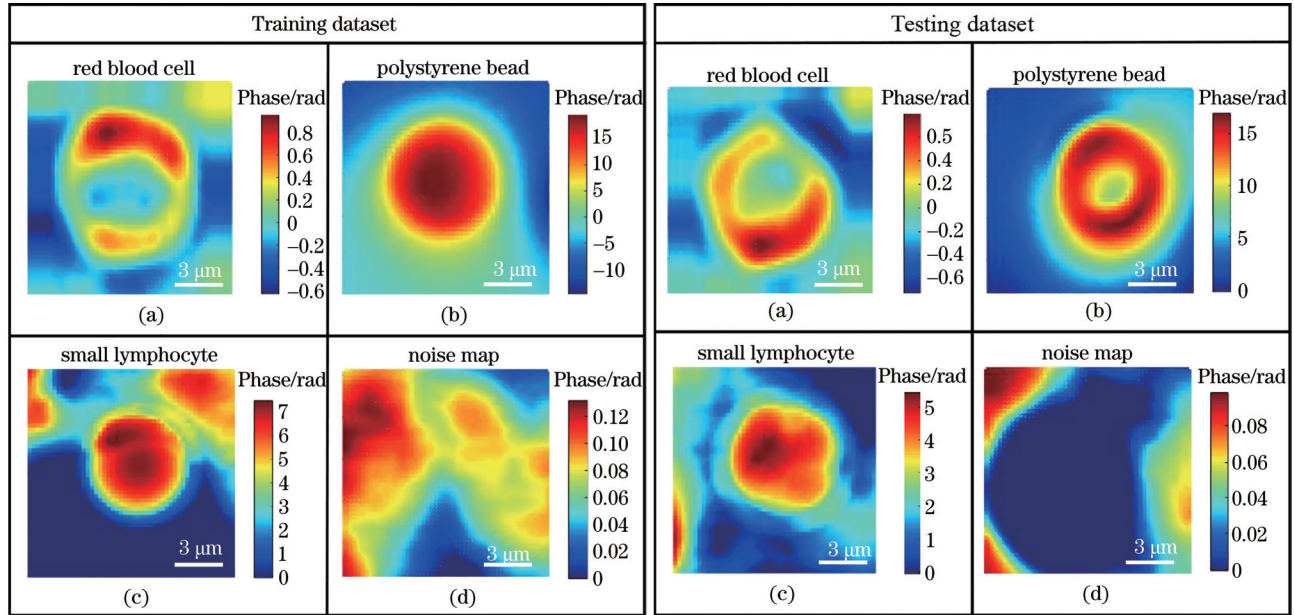


图 1 训练集(左)和测试集(右)中各分类样例。(a)红细胞;(b)聚苯乙烯微球;(c)小淋巴细胞;(d)噪声图
 Fig. 1 Examples of each class in training dataset (left) and testing dataset (right) (a) Red blood cell; (b) polystyrene bead; (c) small lymphocyte; (d) noise map

相位值就较周边小。这是由于受到入射光照角度、材质的透明度和表面光滑程度的影响,微球顶部反射光较强,透射光强相对较弱,而Biophase系统得到的相位值是通过透射光强迭代计算得到的,因此球心位置对应的相位值反而较周围小。

本实验组基于LeNet-5^[20]进行网络改造,在尝试组合不同复杂度的网络结构后,从训练集上表

现相似的网络结构中选择结构最轻便、参数最少的网络。该网络总共包括8层,结构如图2所示,由2层卷积层、2层池化层、2层全连接层(FC layer)、1层flatten层和dropout层^[21]组成。整个神经网络的输出层(output layer)也是一层全连接层,得到的四维向量经Softmax函数计算后输出类别预测概率。

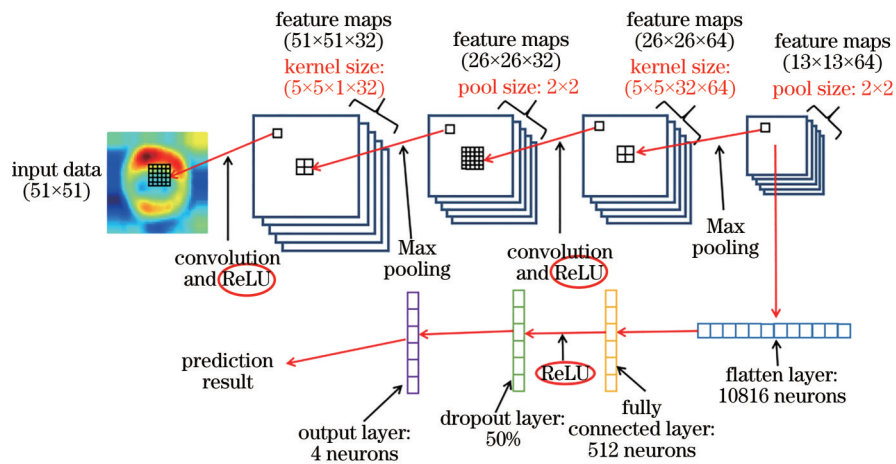


图 2 用于 4 类相位体识别的卷积神经网络结构示意图
 Fig. 2 Structure of CNN implemented for 4-class phase recognition

网络使用的损失函数如下,每次训练过程就是通过更新网络中的所有参数 w 来降低损失函数值的。

$$L(w) = -\frac{1}{N} \sum_{i=1}^N \log \left[\frac{\exp(h_{ii})}{\sum_{j=1}^c \exp(h_{ij})} \right] + \frac{1}{2} \lambda \|w\|_2^2, (1)$$

式中: N 为每轮训练所喂入神经网络的训练样本数

量; C 为样本的总类别数; h_i 为第 i 个样本对应的输出, h_{ij} 为向量中第 j 个元素的值, h_{ii} 为第 i 个样本正确标签对应的元素值; λ 为正则化系数。

训练过程中, 通过比较收敛速度选择了自适应




图 3 LeNet-5 模型在训练过程中的表现。(a) 损失函数值; (b) 准确率

Fig. 3 Performance of LeNet-5 model in training process. (a) Loss function value; (b) accuracy

所用计算机配置如下。CPU 型号为 Intel i7 8700, 主频为 3.2 GHz, RAM 为 32 GB, GPU 型号为 RTX 2070, 显存为 8 GB。卷积神经网络的搭建依赖于 TensorFlow 框架, 采用 CUDA 架构^[23-24]加速计算, 使用 Numpy 库、Matlab 软件处理数据。在测试集的分类结果中, 只有一个红细胞被误判为无相位体。在上述配置下, 用训练好的网络识别 1000 幅相位图像只需要 0.24 s。

矩估计 (Adam) 算法^[22]。图 3 是 LeNet-5 模型在 500 轮训练中的表现。从图中可以看出, 损失函数值和准确率的波动很小, 收敛速度很快。

为了进一步探索 LeNet-5 模型对不同样品相位分布的识别能力, 将数据集的不同类别样品的相位数值分布拉伸到同一水平, 以此消除样品间明显的分布值域差异。以红细胞为例, 对红细胞的数据进行数值上的增大, 使其接近聚苯乙烯微球的相位值。图 4 展示了变化前后的红细胞相位三维分布图。同样, 对所有小淋巴细胞数据进行相同的操作, 无相位体的数据保持不变。

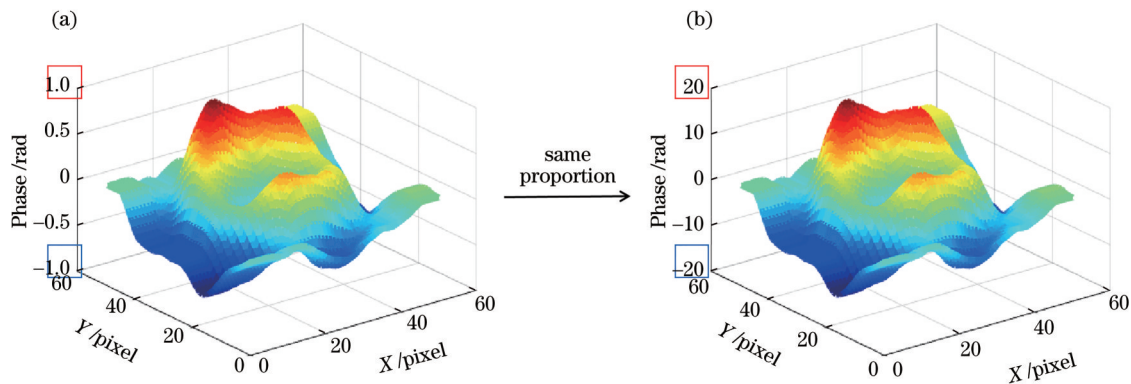


图 4 变化前后的红细胞相位分布图。(a) 变化前; (b) 变化后

Fig. 4 Phase distributions of red blood cell before and after change. (a) Before change; (b) after change

在提升数据集识别难度后, 相应地对 LeNet-5 模型进行了一些改变, 增加了一层卷积层与池化层。越深的模型意味着越好的非线性表达, 越小的卷积核意味着越小的计算量, 从而加快模型训练。卷积核总数的增加意味着激活函数的使用更加频繁, 这使得模型具有更强的特征学习能力。图 5 展示了新的网络模型在新数据集上训练 500 轮的损失

函数值和准确率。与之前的数据集相比, 网络模型的收敛速度略有降低, 这验证了样本识别的难度有所增加。从图 5 中可以看出, 训练过程中损失函数值有一次较大的跃变, 相应的准确率也急剧降低, 但是 Adam 算法快速找到了损失函数值下降的方向, 使训练过程回归到良好的轨迹, 避免了偏离正确优化方向情况的出现, 这也体现了 Adam 算法的




图5 新CNN模型在训练过程中的表现。(a)损失函数值;(b)准确率

Fig. 5 Performance of new CNN model in training process. (a) Loss function value; (b) accuracy

鲁棒性。500轮训练后,模型仅用0.19 s就在测试集上成功地识别出所有样品类型。在大规模多分类的数据集上,该网络模型准确率肯定会有所下降,但是这个结果充分表明了卷积神经网络在相位分布识别上的可行性。

3 基于干涉条纹的识别

感光元件只能感应光的强度,相位信息需要经由一系列恢复和解包算法才能从干涉或衍射光强分布图中获得。考虑到相位获取过程引入的误差和耗费的时间成本,出于简化检测流程的目的,本小节探究直接对干涉条纹进行识别的可行性。但是受制于本实验组目前的实验条件,大量干涉图样

的获取尚有困难。为此,基于样本引起的相位分布取决于样品本身的物质结构属性、透射光波长及照射方向而与具体光路无关这一性质,本实验组从成像理论出发,运用Matlab软件,设置波长等相应的基本光学参数,基于离轴干涉原理,利用第2小节的相位图数据集反演得到对应的干涉图数据集。模拟波长设置为632.8 nm,光场振幅设为均匀分布,且参考光与物光光强比值为1,载波条纹空间频率设置为1.57 rad/pixel。根据上述过程,共获得867幅不同样品的干涉图数据,以其中667幅作为训练集,200幅作为测试集,各类样本数量均匀分布。从红细胞、聚苯乙烯微球、小淋巴细胞和空白噪声4类样品中各取一幅干涉图进行展示,如图6所示。




图6 各类样品干涉图。(a)红细胞;(b)聚苯乙烯微球;(c)小淋巴细胞;(d)噪声图

Fig. 6 Interferograms of various samples. (a) Red blood cell; (b) polystyrene bead; (c) small lymphocyte; (d) noise map

3.1 基于LeNet-5的干涉图识别

由于上述改造后的LeNet-5模型对相位图的识别效果较好,仍然采用相同的网络结构和训练策略来识别干涉图。图7显示了500轮参数更新过程中的损失函数值[即 $L(\mathbf{w})$]及准确率。与相位分布识别的训练过程(图5)相比,在干涉图识别的训练过程中,损失函数在整个过程伴随着较大的波动,准确率也明显降低。在结束训练后,将训练过程中准确率最高的模型参数代入神经网络,即第493次更新的参数,对应着85.76%的训练集准确率。

除了准确率的变化外,从LeNet-5模型在测试集上的识别结果混淆矩阵(如表1所示)可以看出,各类样品均有误判的情况,这可能是不同样品的相位分布引起的干涉条纹弯曲程度类似导致的。表2反映了干涉图测试集各分类的精确率、召回率和F1-Score,从表2中可以直观地看到,红细胞和空白噪声图的指标最差。由此可见,该LeNet-5模型对干涉条纹识别的总准确率仅为77.5%,有待进一步提高。




图7 LeNet-5模型在训练过程中的表现。(a)损失函数值;(b)准确率

Fig. 7 Performance of LeNet-5 model in training process. (a) Loss function value; (b) accuracy

表1 LeNet-5模型在干涉图测试集上的分类结果混淆矩阵

Table 1 Confusion matrix of classification results of LeNet-5 model on interferogram testing dataset

Confusion matrix		Predicted class			
		Red blood cell	Polystyrene bead	Small lymphocyte	No phase object
Actual class	Red blood cell	28			22
	Polystyrene bead		48	2	
	Small lymphocyte		15	35	
	No phase object	6			44

表2 LeNet-5模型在干涉图测试集各分类上的表现

Table 2 Performance of LeNet-5 model on each class of interferogram testing dataset

Class	Accuracy / %	Recall / %	F1-Score	Overall accuracy / %
Red blood cell	82.35	56	0.667	77.5
Polystyrene bead	76.19	96	0.850	
Small lymphocyte	94.59	70	0.805	
No phase object	66.67	88	0.759	

3.2 基于残差网络的干涉图识别

3.2.1 残差网络的构建和训练过程

与LeNet-5模型相比,残差网络通过往多层神经网络中加入残差块而具有了恒等映射能力,有效地解决了随着网络层数加深而模型退化的问题^[25]。因此本实验组设计了一个包含17层可训练层的残差网络,即ResNet-17,所设计的残差块结构如图8(a)所示,整个结构由5个残差块和2个FC layer组成,如图8(b)所示,其中BN是Batch Normalization的缩写。

采用Adam优化算法对ResNet-17模型进行训练,初始学习率设定为0.001,损失函数不变。由于数据集较小,在17层网络中可能会出现过拟合的问题,因此采用了Dropout函数和正则化^[26-27]防止过拟合。图9是ResNet-17在训练过程中的损失函数值和准确率。与图7相比,ResNet-17的性能有了显著的提高,收敛速度加快了,而且准确率达到更好的水平。由于残差块的存在,模型没有出现退化,

并且BN保证了收敛速度。

ResNet-17模型在测试集上的分类结果中,只有4个聚苯乙烯微球被误判为小淋巴细胞,在测试集上的总体准确率达到98%,如表3所示,表明ResNet-17模型具有很好的干涉图识别能力。

3.2.2 含多种条纹可见度和载波频率的干涉图识别

上述识别是基于物光和参考光强相同(即可见度最高)、空间载波频率单一的情形进行的。而当干涉图的可见度及分布密集程度不同的时候,其条纹清晰度和弯曲程度都会有所变化,这些变化都可能对网络识别效率产生不同影响。为了进一步测试所提残差网络模型识别干涉图的性能,本实验组还研究了该模型对不同可见度、不同空间频率条纹的识别能力。

为研究条纹可见度对识别性能的影响,通过设置不同的参考光光强和物光强比值分别获得不同可见度的干涉图数据,图10以聚苯乙烯微球为例进

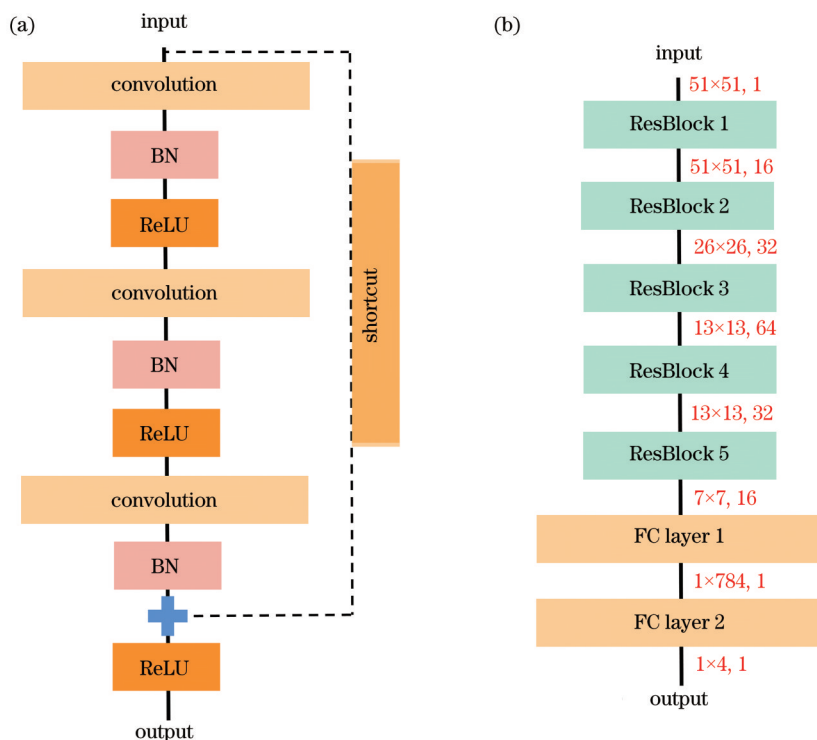


图 8 ResNet-17 网络架构。(a) 残差块结构；(b) 整体网络架构

Fig. 8 ResNet-17 network architecture. (a) Structure of residual block; (b) total architecture of network




图 9 LeNet-5 模型在训练过程中的表现。(a) 损失函数值；(b) 准确率

Fig. 9 Performance of LeNet-5 model in training process. (a) Loss function value; (b) accuracy

表 3 ResNet-17 模型在干涉图测试集各分类上的表现

Table 3 Performance of ResNet-17 model on each class of interferogram testing dataset

Class	Accuracy / %	Recall / %	F1-Score	Overall accuracy / %
Red blood cell	100	100	1.000	98
Polystyrene bead	100	92	0.958	
Small lymphocyte	92.59	100	0.962	
No phase object	100	100	1.000	

行展示,参考光与物光光强比值分别设为 1~4,载波条纹空间频率设置为 1.57 rad/pixel,这样共获得了 4 组干涉图数据集。

类似地,研究了上述网络对不同空间频率载波条纹的识别性能。基于控制变量法,将载波条纹空

间频率设置为 4 个不同的值,即 1.05, 1.57, 2.09, 3 rad/pixel,固定条纹可见度(干涉光强比设置为 1)。以聚苯乙烯微球为例,通过计算反演得到的 4 组干涉条纹图谱如图 11 所示。使用训练好的 ResNet-17 进行识别测试,相关结果如表 4 所示,其中 Accuracy




图 10 不同干涉光强比值(参考光:物光)的聚苯乙烯小球干涉图。(a) 1:1; (b) 2:1; (c) 3:1; (d) 4:1

Fig. 10 Polystyrene bead interferograms with different intensity ratios (reference wave : object wave). (a) 1 : 1; (b) 2 : 1; (c) 3 : 1; (d) 4 : 1




图 11 不同条纹空间频率的聚苯乙烯微球干涉图。(a) 1.05 rad/pixel; (b) 1.57 rad/pixel; (c) 2.09 rad/pixel; (d) 3 rad/pixel

Fig. 11 Polystyrene bead interferograms with different fringe spatial frequencies. (a) 1.05 rad/pixel; (b) 1.57 rad/pixel; (c) 2.09 rad/pixel; (d) 3 rad/pixel

表 4 ResNet-17 模型在不同干涉光强比和不同条纹空间频率数据集上的表现

Table 4 Performance of ResNet-17 model on interferogram datasets with different fringe spatial frequencies

Datasets with different intensity ratios ($R:O$)	Different fringe spatial frequency datasets / ($\text{rad}\cdot\text{pixel}^{-1}$)	Correctly identify number of samples/number of all samples		Accuracy /%	
1:1	1.05	863/867	453/867	99.54	52.25
2:1	1.57	849/867	863/867	97.92	99.54
3:1	2.09	849/867	361/867	97.92	41.64
4:1	3	840/867	654/867	96.89	75.43

中的两列数据分别表示不同干涉光强比和不同条纹空间频率的准确率。

对于不同干涉光强比,模型用比值为 1:1 的数据集进行训练。尽管随着测试集和训练集的可见度差异增大,准确率有所降低,但总体看来仍然保持在较好的水平。实验结果表明,使用残差网络进行干涉图识别的过程中,干涉光强比的影响较小,在一定的光照强度范围内可以有效识别。对于不同条纹空间频率,模型用空间频率为 1.57 rad/pixel 的数据集进行训练。这 4 组数据集的准确率差别很大,模型在空间频率为 1.57 rad/pixel 的识别上表现出明显的优势。这可能归因于训练数据的单一性,即网络模型的训练集只有空间频率为 1.57 rad/pixel 的数据。本实验组采用扩展训练数据集的办法提高识别效率。升级后的训练集由 3468 张干涉图组成,其载波条纹的空间频率分别为 1.05, 1.57, 2.09, 3 rad/pixel, 以其中 3068 幅作为训练集,

剩下 400 幅作为测试集,其中不同空间频率的不同类别的干涉图均匀分布。类似地,使用 ResNet-17 及相应的训练策略进行训练,训练过程如图 12 所示。与图 9 相比,从图 12 中可以看出,损失函数值和相应的准确度有明显的波动,但最终仍收敛到理想水平。ResNet-17 模型在多空间频率干涉图测试集上的分类结果中,有 11 个小淋巴细胞被误判为聚苯乙烯微球,表 5 显示了测试集上的分类指标。

最后,模拟生成条纹空间频率为 2.5 rad/pixel 的干涉图数据集,并对上述训练后的网络模型进行测试,即使训练数据中未包含 2.5 rad/pixel 的干涉图,ResNet-17 模型依然获得了 88.9% 的准确率。这说明利用多空间频率的干涉图数据训练的残差网络模型具有较好的鲁棒性,对特定载波条纹空间频率的依赖性大大降低,同时体现了机器学习技术在干涉图识别方面的巨大应用潜力。




图 12 LeNet-5 模型在训练过程中的表现。(a) 损失函数值; (b) 准确率

Fig. 12 Performance of LeNet-5 model in training process. (a) Loss function value; (b) accuracy

表 5 ResNet-17 模型在多空间频率干涉图测试集各分类上的表现

Table 5 Performance of ResNet-17 model on each class of interferogram testing dataset with multiple spatial frequencies

Class	Accuracy / %	Recall / %	F1-Score	Overall accuracy / %
Red blood cell	100	100	1.000	97.25
Polystyrene bead	90.09	100	0.948	
Small lymphocyte	100	89	0.942	
No phase object	100	100	1.000	

4 结 论

探索了卷积神经网络识别不同相位体的可行性和模型训练策略。在 LeNet-5 网络模型基础上设计了 CNN 模型, 该模型对聚苯乙烯微球、红细胞等具有类似轮廓样品的相位分布图像实现了自动识别。为验证所设计模型的性能, 将所有样品的相移分布按比例转换至相近数值下, 以此消除原数据值域差异较大带来的显著特征信息。通过对 CNN 模型进行加深提高了非线性拟合能力, 经过训练的模型在普通配置环境下仅用 0.19 s 就完成了 1000 帧相位图的识别。出于简化检测流程的目的, 讨论了模型对于干涉图的识别能力, 引入残差块结构搭建 ResNet-17 模型, 有效解决了网络退化问题。进而分别考查了条纹可见度和载波频率对识别难度的影响, 针对识别过程中模型表现出的对载波频率的较强依赖性, 将具有多个条纹空间频率的干涉图添加到训练集中提高网络模型的鲁棒性。研究结果可为基于样品的相位信息进行自动识别提供参考, 尤其对红细胞这类具有基础临床意义的样本, 在简化检测流程提高检测效率方面有一定的潜在应用价值。

参 考 文 献

[1] Bhaduri B, Pham H, Mir M, et al. Diffraction phase

microscopy with white light[J]. Optics Letters, 2012, 37(6): 1094-1096.

- [2] Ding H, Nguyen F, Boppart S A, et al. Optical properties of tissues quantified by Fourier-transform light scattering[J]. Optics Letters, 2009, 34(9): 1372-1374.
- [3] Masters B R. Quantitative phase imaging of cells and tissues[J]. Journal of Biomedical Optics, 2012, 17(2): 029901.
- [4] Sridharan S, Macias V, Tangella K, et al. Prediction of prostate cancer recurrence using quantitative phase imaging: validation on a general population[J]. Scientific Reports, 2016, 6: 33818.
- [5] Lee K, Kim K, Jung J, et al. Quantitative phase imaging techniques for the study of cell pathophysiology: from principles to applications[J]. Sensors, 2013, 13(4): 4170-4191.
- [6] Wang F, Wang H, Bian Y M, et al. Applications of deep learning in computational imaging[J]. Acta Optica Sinica, 2020, 40(1): 0111002.
王飞, 王昊, 卞耀明, 等. 深度学习在计算成像中的应用[J]. 光学学报, 2020, 40(1): 0111002.
- [7] Zuo C, Feng S J, Zhang X Y, et al. Deep learning based computational imaging: status, challenges, and future[J]. Acta Optica Sinica, 2020, 40(1): 0111003.
左超, 冯世杰, 张翔宇, 等. 深度学习下的计算成像: 现状、挑战与未来[J]. 光学学报, 2020, 40(1): 0111003.
- [8] Jo Y, Cho H, Lee S Y, et al. Quantitative phase

- imaging and artificial intelligence: a review[J]. IEEE Journal of Selected Topics in Quantum Electronics, 2019, 25(1): 1-14.
- [9] Rivenson Y, Liu T, Wei Z, et al. PhaseStain: the digital staining of label-free quantitative phase microscopy images using deep learning[J]. Light, Science & Applications, 2019, 8: 23.
- [10] Majeed H, Sridharan S, Mir M, et al. Quantitative phase imaging for medical diagnosis[J]. Journal of Biophotonics, 2017, 10(2): 177-205.
- [11] Majeed H, Nguyen T H, Kandel M E, et al. Label-free quantitative evaluation of breast tissue using Spatial Light Interference Microscopy (SLIM) [J]. Scientific Reports, 2018, 8(1): 6875.
- [12] Nguyen T H, Sridharan S, Macias V, et al. Automatic Gleason grading of prostate cancer using quantitative phase imaging and machine learning[J]. Journal of Biomedical Optics, 2017, 22(3): 36015.
- [13] Trujillo C, Garcia-Sucerquia J. Automatic detection and counting of phase objects in raw holograms of digital holographic microscopy via deep learning[J]. Optics and Lasers in Engineering, 2019, 120: 13-20.
- [14] Wang P, Liu R, Xin X J, et al. Scene classification of optical remote sensing images based on residual networks[J]. Laser & Optoelectronics Progress, 2021, 58(2): 0210001.
汪鹏, 刘瑞, 辛雪静, 等. 基于残差网络的光学遥感图像场景分类算法[J]. 激光与光电子学进展, 2021, 58(2): 0210001.
- [15] Sawaf F, Groves R M. Phase discontinuity predictions using a machine-learning trained kernel [J]. Applied Optics, 2014, 53(24): 5439-5447.
- [16] Spoorthi G E, Gorthi S, Gorthi R K S S. PhaseNet: a deep convolutional neural network for two-dimensional phase unwrapping[J]. IEEE Signal Processing Letters, 2019, 26(1): 54-58.
- [17] Zhang J, Tian X, Shao J, et al. Phase unwrapping in optical metrology via denoised and convolutional segmentation networks[J]. Optics Express, 2019, 27(10): 14903-14912.
- [18] PhaseView F. Label-free Digital Cell Imager: Biophase[EB/OL]. [2021-05-20]. <http://phaseview.com/pdf/PhaseView.BioPhase.pdf>.
- [19] Salamon J, Bello J P. Deep convolutional neural networks and data augmentation for environmental sound classification[J]. IEEE Signal Processing Letters, 2017, 24(3): 279-283.
- [20] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [21] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [22] Kingma D, Ba J. Adam: a method for stochastic optimization[EB/OL]. (2014-12-22) [2021-05-20]. <https://arxiv.org/abs/1412.6980v5>.
- [23] Raina R, Madhavan A, Ng A Y. Large-scale deep unsupervised learning using graphics processors[C]// Proceedings of the 26th Annual International Conference on Machine Learning-ICML '09, June 14-18, 2009. Montreal, Quebec, Canada. New York: ACM Press, 2009: 873-880.
- [24] Li W, Cheng S, Qian K, et al. Automatic recognition and classification system of thyroid nodules in CT images based on CNN[J]. Computational Intelligence and Neuroscience, 2021, 2021: 5540186.
- [25] 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.
- [26] Cortes C, Mohri M, Rostamizadeh A. L2 regularization for learning kernels[C]//Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence, June 18-21, 2009, Montreal, QC, Canada. New York: AUAI Press, 2009: 109-116.
- [27] Jaiswal M, Sharmay V, Sharmaz A, et al. Transfer learning with L2 norm regularization for classifying static two hand Hindi sign language gestures[C]// 2020 IEEE 9th International Conference on Communication Systems and Network Technologies (CSNT), April 10-12, 2020, Gwalior, India. New York: IEEE Press, 2020: 44-48.