

基于深度学习的多模光纤散射介质成像重建

孟球^{1*}, 胡海峰^{1,2}, 胡金洲¹, 布思航¹, 高涵¹

¹东北大学信息科学与工程学院, 辽宁 沈阳 110004;

²上海理工大学光电信息与计算机工程学院, 上海 200093

摘要 多模光纤是一种厚散射介质,当目标图像经过多模光纤传输时将形成多种模式耦合,从而在光纤的输出端生成散斑图案。基于深度学习对多模光纤成像进行复原,解决了厚散射介质成像失真的问题。采用 DenseUnet,并以散斑图样作为模型的输入来重建目标图像。DenseUnet 模型采用融合机制加深了网络的深度,提高了重建的准确性,并具有很好的鲁棒性。实验结果表明,DenseUnet 可以很好地对具有不同长度的多模光纤产生的散斑图像进行重建。

关键词 光纤光学; 图像处理; 多模光纤; 深度学习; 密集连接; 图像重建; DenseUnet

中图分类号 TP311

文献标志码 A

doi: 10.3788/CJL202047.1206005

Image Reconstruction of Multimode Fiber Scattering Media Based on Deep Learning

Meng Lu^{1*}, Hu Haifeng^{1,2}, Hu Jinzhou¹, Bu Sihang¹, Gao Han¹

¹College of Information Science and Engineering, Northeastern University, Shenyang, Liaoning 110004, China;

²School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract Multimode fiber is a thick scattering medium. When the target image is projected onto the multimode optical fiber, multimode coupling will occur, thereby generating speckle images at the output of the fiber. In this work, multimode optical fiber imaging is restored based on deep learning, and the distortion of thick scattering media imaging is solved. DenseUnet is used and the speckle image is used as the input of the model for reconstructing the target image. The DenseUnet model employs a fusion mechanism to deepen the network depth, thus, improving the reconstruction accuracy and realizing good robustness. The experimental results reveal that DenseUnet can be used to reconstruct speckle images produced by multimode optical fibers with different lengths.

Key words fiber optics; image processing; multimode fiber; deep learning; dense connection; image reconstruction; DenseUnet

OCIS codes 100.4996; 100.2960; 200.4260

1 引言

散射介质计算成像技术^[1-4]在水下成像^[5]、生物组织检测、天文观测等众多领域都具有重要意义。当光纤用于通信时,多模光纤(MMF)相对于单模光纤具有更大的信息承载能力。在医疗方面,医生可以使用超细光纤探针来收集关于人体动脉的图像,而无需复杂的全息记录仪,并且超细光纤探针可以消除由轻微运动或呼吸造成的失真现象,而且还可

以微创的方式实时观察活体细胞的状态^[6]。在工业领域,油井内复杂的环境与狭窄的空间给油井勘探造成重大影响,由于光纤具有端面小、占用空间小、不受电磁干扰、可以长距离传输图像等优点,在油井勘探方面有重大作用。当光穿过混浊液体、生物组织、烟雾等具有不均匀密度的介质时,介质内部的粒子改变了部分光的传播方向,使其沿不规则的方向散开,这使得有序的波前相位变得无序,随后会在成像平面上产生无规则颗粒状散斑图样,因此会发生

收稿日期: 2020-06-22; 修回日期: 2020-07-17; 录用日期: 2020-08-10

基金项目: 国家自然科学基金(61973058)、教育部中央高校基本科研项目(N2004020)

* E-mail: menglu@ise.neu.edu.cn

散射现象。

传统的光学成像主要通过提取未发生散射的弹道光来解决散射介质成像的问题,但是随着散射介质的不均匀程度加深,弹道光会以指数形式衰减,最终通过相关技术提取的弹道光十分微弱,从而难以成像。经过不断努力,研究人员发现散射并不是限制成像的因素。从直观上看,斑点图案具有高度的随机性,实际上,在散射介质处于稳定的前提下,当光经过多次散射后,光子仍然保留了大量信息并且传播过程是具有确定性的。近年来,散射介质成像技术取得巨大的进步,研究者开发出了很多散射介质成像算法,常用的算法是波前整形算法。波前整形算法主要包括基于反馈优化的波前整形技术^[7-8]、光学相位共轭技术^[9-10]及传输矩阵技术^[11-12]。基于反馈优化的波前整形技术通过逐个对像素进行迭代优化得到最优的波前。光学相位共轭技术通过计算透过散射介质输出场的共轭场,然后将共轭场反向传播至散射介质,来重建原始图像。传输矩阵法计算出输入场与输出场的关系矩阵,最后通过传输矩阵的转置矩阵来重建原始输入场,但是此方法对光学系统和环境比较敏感,一旦外界环境或者光学系统内部发生改变,就难以达到理想的重建效果,因此,该方法具有一定局限性。

随着深度学习的发展,对不同的学科进行交叉融合,可以很好地解决一些常规方法难以突破的瓶颈^[13-14]。文献[15]采用卷积神经网络(CNN)对散斑进行重建,经过两次卷积与池化之后连接一个全连接层,此网络的深度有限,能够提取的特征有限,导致重建的精度不足。文献[16]提出混合神经网络(HNN),该网络引入丢弃层(dropout),起到了防止过拟合的作用,但是此网络全连接层神经元较多,导致需要训练的参数较多,而且网络的深度也有限,并且没有加入长距级联连接机制,从而缺少低层的空间信息。文献[17]提出 U-net 型^[18]网络结构,该网络加入融合机制,增加了空间信息获取能力,但传统的 U-net 深度较浅,学习能力有限。文献[4]提出一种 SpeckleNet 模型,此结构将机器学习中的支持向量机(SVM)当作分类器,直接对两类散斑(人脸散斑、非人脸散斑)进行分类,并且达到了较好的分类结果。文献[1]构造了一种 IDiffNet 结构对散斑进行重建,并对网络模型损失函数部分进行了改进,采用负皮尔逊相关系数(NPCC)作为损失函数并将其应用于神经网络的训练阶段。文献[10]使用脂肪乳来模拟人体组织器官,并采用生成对抗网络(GAN)

对散斑进行了重建。

本文提出一种密集连接型 DenseUnet 网络结构^[19],该网络由密集连接块组成,每个密集连接块中的卷积层之间通过融合机制建立了各个层之间的联系,以实现特征复用,同时通过长距级联操作机制对浅层信息和高层信息进行融合,提高了信息的获取能力。基于改进的 DenseUnet 网络模型对不同长度的多模光纤产生的散斑进行重建。

2 实验设计

2.1 光学实验平台的设计

基于 DenseUnet 神经网络的散射介质成像系统的实验平台如图 1 所示。波长为 632.8 nm 的激光从氦氖激光器中发出后经空间滤波器和透镜组成的光束扩展器(BE),从而完成对光束的滤波、扩束及准直操作。之后光束经半玻片(HWP)和偏振片(P)被分光棱镜(BS1)分束,一束光经四分之一波片(QWP)后到达空间光调制器(SLM)的微显示器上,经过调制之后的光束沿原路返回并与另外一束光耦合成一路。需要注意的是,为了保证这束光能原路返回,要调整微显示器的姿态,使其与光束传播方向垂直。同时,为了保证调制的效果,要保证光斑垂直入射在微显示器的中心且不会超出微显示器的范围,因此需要适当地调整光斑的大小。在本文中,将光斑的直径调整到微显示器宽度的 2/3。耦合之后的光经过一个偏振片后,再次被一个分光棱镜(BS2)分束,一束光被显微物镜(OBJ1,4×)耦合进多模光纤(纤芯直径为 62.5 μm,包层直径为 125 μm)中,然后在光纤输出端用另一个显微物镜(OBJ2,10×)和透镜搭建一个 4f 成像系统来放大光纤输出端的散斑图像,散斑图像采集和存储分别通过电荷耦合器件(CCD1)和计算机完成。另一束光被定义为评价 SLM 调制效果的参考光,用 CCD2 相机观察光束调制效果。在光路中,作为核心器件的 SLM 是一种调制光波空间分布的设备,它由许多独立的单元组成,并以二维阵列结构排列在空间中,已被广泛应用于光学控制、光学检测、图像处理、显示技术等领域。当偏振光入射到 SLM 上时,由于液晶的扭曲效应,光的偏振态随液晶分子的扭曲而改变。在入射光穿过液晶层之后将产生不同的光程差。正是由于液晶改变了入射光的偏振态,它可以通过将入射光投射到液晶装置上来达到改变入射光相位的目的。因此,可以通过 SLM 对光进行调制以获得所需的相位。采用分辨率为 1920×1080

的 Holoeye SLM(PLUTO 2 NIR 011)进行相位调制,其可以通过改变驱动电路施加在液晶显示器上的电压来改变液晶 SLM 的相位分布。如图 1 所示,将原始图片加载在 SLM 上,由于本实验采用相位型 SLM,因此相位型 SLM 会根据输入图片不同

灰度等级的像素施加相应的电压,以驱动 SLM 上的液晶元。由于液晶元的扭曲效应会改变光的相位,光束的横截面呈数字图像样式,最后使用 CCD2 捕获调制后的数字图像,由 CCD1 捕获经多模光纤后产生的散斑图样。

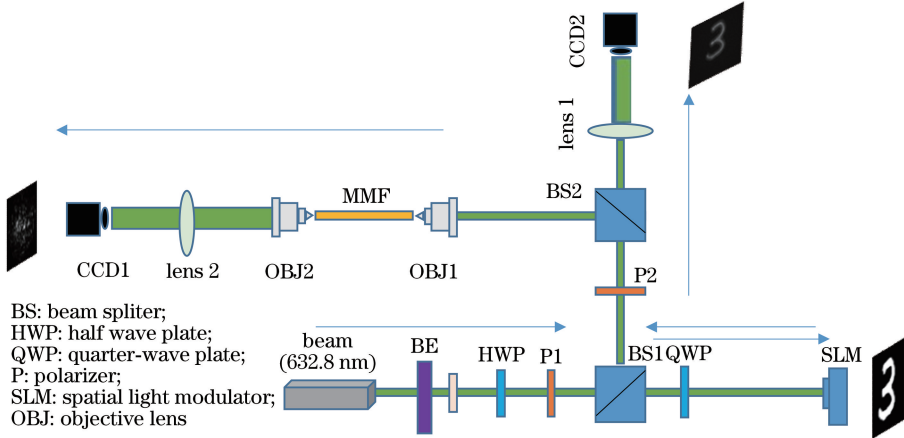


图 1 光学实验平台的设计

Fig. 1 Design of optical experiment platform

2.2 DenseUnet 网络模型结构设计

所采用的 DenseUnet 网络模型结构如图 2 所示,将长距级联操作与密集连接相结合。对于重建任务来说,图像内部的细节信息尤为重要。如图 2 (b)所示,在密集连接块中,每一个特征图都会沿着其通道方向融合到后一个特征图中,从数学角度来解释其原理,设其中的每一层的特征图用 x_l 表示,则密集连接机制的数学表达式为

$$\begin{cases} x_l = H_l(x_{l-1}) \\ x_l = H_l([x_0, x_1, x_2, \dots, x_{l-1}]) \end{cases}, \quad (1)$$

式中: H 表示对特征图使用激活函数激活; $[\cdot]$ 表示沿着通道方向融合; l 表示层数。因此,通过密集连接机制实现了特征复用。采用长距级联操作将模型编码部分与解码部分联系起来,通过卷积操作之后将编码部分的特征图加在对应解码部分,加强了特征的提取与利用,其数学表达式为

$$x = \text{Conv}(F_{\text{encoder}}) + F_{\text{decoder}}, \quad (2)$$

式中: $\text{Conv}(\cdot)$ 表示卷积操作; F_{encoder} 表示编码部分的特征图; F_{decoder} 表示解码部分的特征图。利用长距级联操作,实现了高层信息与低层信息的融合,提高了信息的获取能力和重建的精度。密集连接的优点在于能够确保网络中信息的最大流动,并且对于一个较小的增长率,同样能获得较好的结果,而且缓解了梯度消失问题,避免学习冗余特征。图 2(c) 描述了 DenseUnet 的具体框架。在 DenseUnet 中

使用了大量尺寸为 1×1 的卷积核,这不仅增加了网络的泛化能力,而且大大减少了网络的参数量^[20],其参数量降低了 60%。为了进一步提高模型的紧凑性,在过渡层中引入压缩系数(设置为 0.5),以减少特征图的数量,DenseUnet 输出的特征图尺寸为 224×224 。

为了实现对重建结果和原始光斑的精确分类,将 DenseUnet 得到的特征图输入到一个深度卷积神经网络(DCNN)中,这个 DCNN 是基于 VGG-16 设计的,在每一个 3×3 的卷积核之前都添加一个 1×1 的卷积核,网络结构如图 2(d) 所示。其中 $\text{Conv}(1 \times 1)$ 表示网络模型在进行卷积操作时卷积核尺寸为 1×1 ,其主要是通过通过对特征通道进行升维与降维来减少参数量。ReLU 表示非线性激活函数,其会使一部分神经元的输出为 0,使得网络变得稀疏,减少了计算量,一定程度上有利于神经网络训练,而且由于它是非线性的,加强了网络的表达能力。ReLU 的表达式为

$$f_{\text{ReLU}} = \max(0, x). \quad (3)$$

函数图像如图 3 所示,横轴表示输入神经元(像素),纵轴表示通过 ReLU 激活的输出。DCNN 的输入图像的大小为 224×224 ,经过 5 个池化层后,图像大小为 7×7 ,通道数达 512,再经过 3 个全连接层得到最终的分类结果。

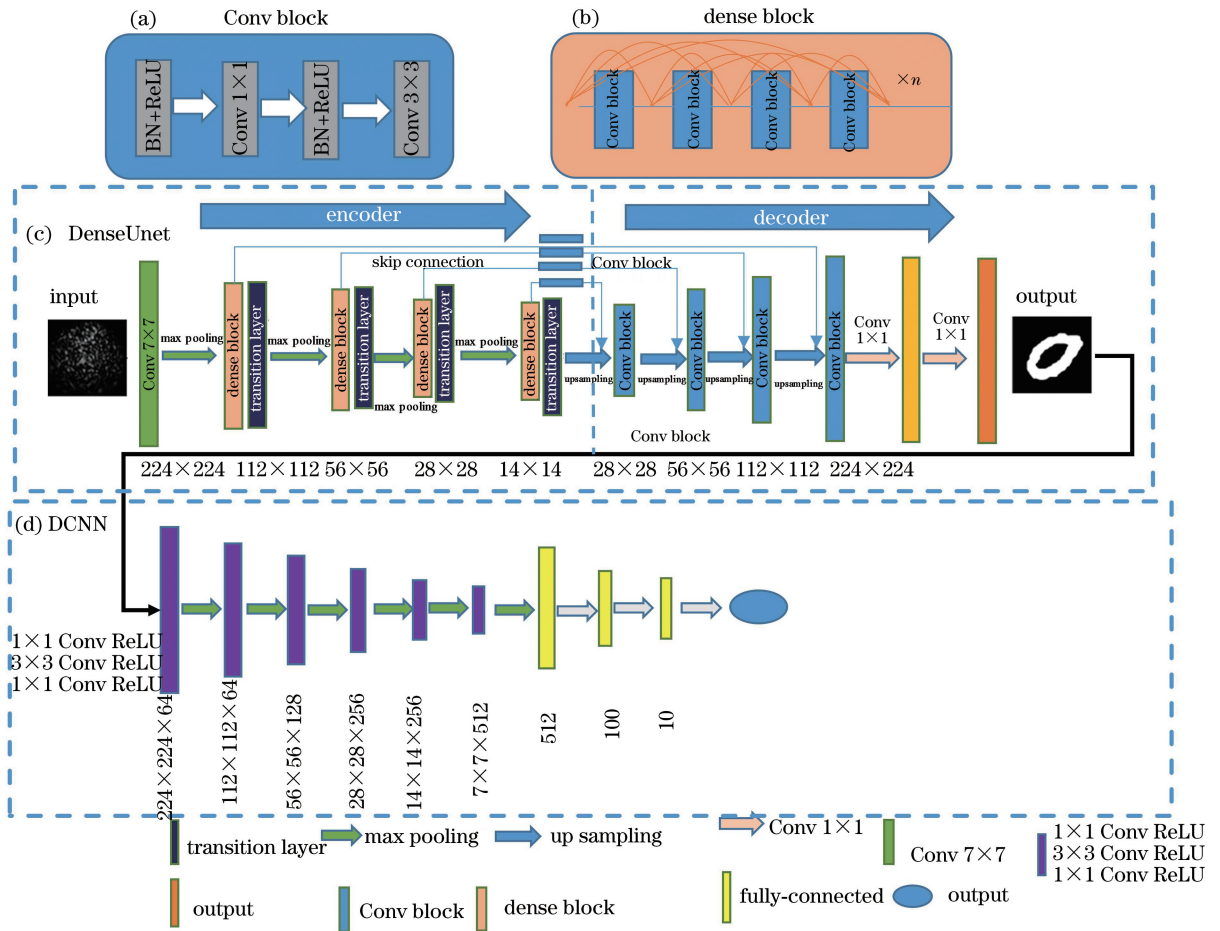


图 2 网络整体结构。(a) Conv block;(b) 密集连接块;(c) DenseUnet;(d) DCNN

Fig. 2 Overall network structure. (a) Conv block; (b) dense block; (c) DenseUnet; (d) DCNN

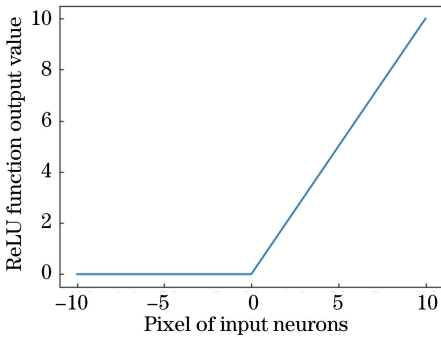


图 3 ReLU 非线性激活函数

Fig. 3 ReLU nonlinear activation function

3 实验结果分析

选用手写数字数据集 MNIST^[21], 它由 250 个人的手写数字构成。MNIST 数据集一共有 7 万张灰度手写体数字图片, 每张图片分辨率为 28×28 , 随机选取其中的 11000 张图片作为本实验的数据集。对其中各个图像经多模光纤后所产生的散射介质图像进行重建, 并对图像复原的准确性和系统的

性能进行分析和评价。光学实验系统如图 4 所示, 右下方短箭头表示来自于激光器的入射光 (632.8 nm), 中间长箭头表示通过四分之一波片后, 再通过多模光纤, 并射入到摄像头的光线。

3.1 实验的软、硬件环境

实验模型的训练都是在显卡 NVIDIA TESLA K40L 上完成的, 操作系统为 Ubuntu16.04, CPU 型号为志强 E5-2620 V4 @八核 2.1GHz。本算法是基于 Python2.7 编写的, 使用的编译器为 PyCharm, 以深度学习框架 TensorFlow 和 Keras 进行模型的搭建和训练。使用 Adam 优化器, 学习率为 1×10^{-4} , 以二进制交叉熵为代价函数。对所提模型进行训练时需要 10 h, 端到端的微调需要 5 h。

3.2 实验所采用的数据集

从 MNIST 数据集中随机选择 11000 张数字图像作为目标图像。测试实验选用图 1 所示的实验系统, 通过 Labview 编写程序将 SLM 和相机构成一个闭环系统, 以实现数据的自动加载与采集。原始数字图像在经过 SLM 调制后, 可以得到对应的散




图 4 多模光纤成像系统实物图

Fig. 4 Physical diagram of multimode optical fiber imaging system

斑图像,如图 5 所示,图像中像素值为 0~1。在图 5 中:第一行是原始的目标数字图像;第二行是 SLM 根据目标图像调制出的数字图像,通过观察可以发现,经过调制后的图像中的数字形状与原图像完全一样,仅在灰度值上有差别;第三行是光纤输出端的散斑图像,通过观察可以发现,不同数字对应的散斑图像有较大的差异,这就保证在训练时神经网络可

以准确地学习到不同数字的特征信息。

通过调整半波片、四分之一波片和偏振片后,经过 SLM 调制之后的光斑呈现以下特点,即空间光路中激光光束的光斑强弱与目标图像像素值大小相对应。目标图像像素值为 255 的部分对应激光光束光斑强的部分;目标图像像素值为 0 的部分,对应激光光束光斑弱的部分。



图 5 成像系统性能测试实验中的数字图像

Fig. 5 Digital images in imaging system performance test experiment

采集数据时,采取以下措施来保证空间光的光斑刚好可以投射到指定区域:使整个光学系统处于相同高度;将光斑直径调节到微显示器宽度的 2/3;微调 CCD 相机捕获散斑图像。如果光斑过大,则无法完全调制出目标图像,目标图像只有一部分被调制出来,这就大大减小了不同目标图像之间的差异性,从而降低了之后工作的重建准确率。

将原始数据集随机划分成训练集和测试集,数量分别为 10000 张和 1000 张。CCD 相机采集到的多模光纤光斑图像大小为 1920×1440 ,由于原始图像过大,其中包含了大量非重建区域的信息,因此对其进行裁剪,仅保留光斑区域,之后将图像分辨率统一调整为 224×224 。

3.3 重建结果分析

对 DenseUnet 与 DCNN 进行训练,训练完成后固定权重等超参数,并对测试集中的散斑进行测试,以长度为 0.1 m 的光纤为例,测试结果如图 6 所示。

第一行是使用图 1 所示的光学系统所采集的散斑,第二行是散斑所对应的真值标签,第三行是使用 DenseUnet 网络模型对第一行散斑进行重建的结果。由图 6 可知,DenseUnet 网络重建质量较高,可以完整地还原原始图像,并且使用重建图像进行分类时可以实现精准的分类。在整个测试集中,使用重建图像进行分类的准确率达到了 98.2%。

一般而言,重建结果的质量决定了分类预测质量,在 DCNN 充分训练的前提下,重建效果越好,分类准确率越高。如图 7 所示,在 DCNN 迭代训练过程中,训练集与验证集的分类准确率不断提高,训练结束后,验证集的分类准确率收敛在 99% 左右。最后将测试集作为 DCNN 模型的输入,通过计算得到重建图像的分类准确率达到 98.2%。由此可知,在 0.1 m 光纤下,DenseUnet 重建质量较高,并且使用重建的图像进行分类时也可以有较高的分类准确率。




图 6 重建与分类结果

Fig. 6 Results of reconstruction and classification




图 7 0.1 m 光纤下,重建图像的训练集与验证集的分类准确率
Fig. 7 Classification accuracy of training set and validation set for reconstructed images under 0.1 m fiber

3.4 多模光纤长度带来的影响

为了更加直观和准确地量化 DenseUnet 模型的重建效果,给出了当光纤长度分别为 0.1 m 和 10 m 时 DenseUnet 在训练数据集和验证数据集上获得的重建准确率,重建图像的准确率变化曲线如图 8 所示。从图 8 可以看出,当训练轮数达到 10

时,DenseUnet 在训练数据集上获得的重建准确率上升速度有所降缓,最终 DenseUnet 在验证数据集上的重建准确率变化趋于稳定。此处重建准确率的定义为:当网络预测的像素值与真实像素值的差值小于 0.5 时(像素值为 0~1),则认为此像素预测准确,所有预测正确的像素数量占总像素量的比例即为重建准确率。

可以观察到,当光纤长度增加时,DenseUnet 重建准确率有所下降。原则上来说,基于深度学习的还原方法的性能应与光纤长度无关,但是随着光纤长度的增加,光纤纤芯和包层界面存在的散射会在光纤输出端累积更多的背景噪声^[13]。对于较长的光纤,从输入到输出的映射愈发接近随机映射,在输入端,相似的对象在光纤输出端采集到的光斑并不相似,从而影响了模型的重建准确率。此外,在实验中还观察到,即使实验装置固定不动,光纤输出端的散斑图像也会发生轻微变化,引发不稳定的因素主要是空气对流等环境因素,这也会在一定程度上影

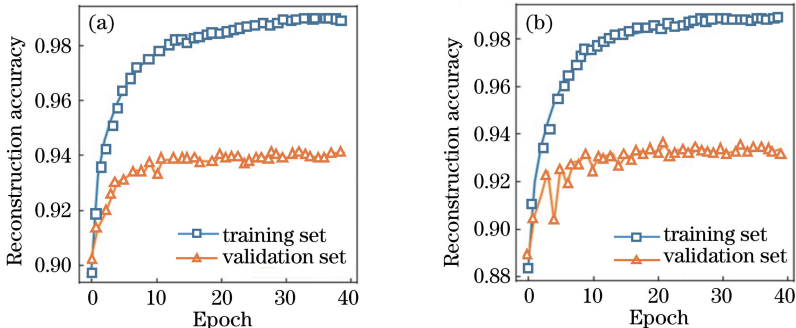


图 8 在不同长度光纤下的重建准确率。(a) 0.1 m;(b) 10 m

Fig. 8 Reconstruction accuracy under different fiber lengths. (a) 0.1 m; (b) 10 m

响其精度。

为了进一步评估不同长度多模光纤对重建质量的影响,利用一个 DCNN 来对重建后的图像进行分类,通过分类准确率来从不同的角度评估重建准确率。表 1 为不同长度光纤产生的散斑重建结果的分 类准确率,其中第 3、4 列分别表示分类模型 DCNN 的输入分别为散斑图像与重建图像。由表 1 可知:在相同光纤长度下,如果将重建图像作为分类网络的输入,分类准确率远高于散斑图像;当光纤长度达到 20 m 时,若直接通过散斑进行分类,其分类准确率大大降低,但是对重建图像的分类依旧可以保持较高的分类准确率。

将目标数字图像分成 10 类来训练 DCNN,并用训练好的 DCNN 结构来对还原的图像进行分类。光纤长度分别为 0.1 m 和 10 m 时的分类准确率如图 9 所示。由图 9 可知:光纤长度为 10 m 时的分类准确率会低于光纤长度为 0.1 m 的分类准确率,而且当光纤长度为 10 m 时,分类准确率依旧很高,这

归结于所提重建网络 DenseUnet 对散斑重建效果良好;在相同的光纤长度下,使用重建图像进行分类的准确率远高于直接对散斑进行分类,这是因为随着光纤长度的增加,在光纤输出端会累积更多的背景噪声,而且由于实验过程中空气流动、平台震动等环境因素会给输入输出之间的确定性关系造成一定影响,但是神经网络具有一定的抗干扰性,因此能够在很大程度上消除环境的影响。

表 1 两种输入模式下不同光纤长度的分类准确率

Table 1 Classification accuracy of different fiber lengths using two input modes

Fiber length /m	Model	Classification accuracy /%	
		Speckle image	Reconstructed image
0.1	DCNN	91.5±0.4	98.2±0.2
1	DCNN	90.2±0.3	97.6±0.2
10	DCNN	86.6±0.6	97.2±0.5
20	DCNN	76.4±1.1	97.0±0.4

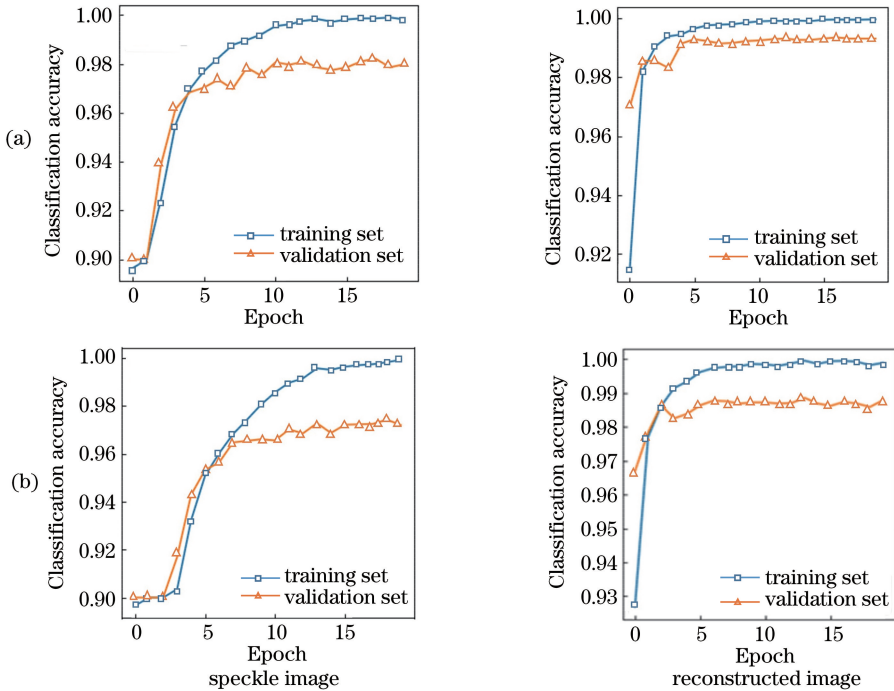


图 9 训练集和验证集中不同长度光纤的分类准确率。(a) 0.1 m;(b) 10 m

Fig. 9 Classification accuracy of different fiber lengths in training set and validation set. (a) 0.1 m; (b) 10 m

在不同光纤长度下,对散斑重建的效果进行对比,如图 10 所示。可知:当光纤长度为 0.1 m 时重建准确率最好;随着光纤长度的不断增加,光纤长度达到 20 m 时散斑依旧可以得到很好的重建,但是局部细节略有些失真,这是因为较长光纤本身的结构与环境对散斑的采集有一定影响,从而影响重建效果。

3.5 与同类方法的定量比较

为了验证 DenseUnet 在重建效果方面的优势,以 1 m 光纤为例,对 DenseUnet 和传统的 Unet 的重建结果进行对比,如图 11 所示。可知:采用传统的 Unet 模型进行重建时,重建结果的边缘信息缺失,边界模糊;但是 DenseUnet 重建效果良好,数字的边缘与背景比较清晰,这归结于采用的密集连接

SLM input	fiber length			
	0.1 m	1 m	10 m	20 m
0	0	0	0	0
1	1	1	1	1
2	2	2	2	2
3	3	3	3	3
4	4	4	4	4
5	5	5	5	5
6	6	6	6	6
7	7	7	7	7
8	8	8	8	8
9	9	9	9	9

图 10 不同长度光纤下,散斑重建效果图

Fig. 10 Results of speckle reconstruction under different fiber lengths

实现了各层之间的特征融合与优化,并且加深了模型深度,提高了模型学习能力。

为了更加精确量化网络性能,对 DenseUnet、文献[13]中传统 Unet、没有采用长距级联操作的 DenseUnet(用 DenseUnet-表示)的重建性能进行比较。引入结构相似系数(SSIM)与峰值信噪比(PSNR)这两种性能评价指标来量化重建图像的质量,其中 PSNR 是基于图像之间的像素误差的,此评价指标并未考虑到人眼的视觉特性(如结构对比度等);SSIM 是一种全参考的图像性能指标。将二者共同作为本实验的性能评价指标,它们分别定义为

$$S_{\text{SIM}}(X, Y) = \frac{(2\mu_X\mu_Y + C_1)(2\sigma_{XY} + C_2)}{(\mu_X^2 + \mu_Y^2 + C_1)(\sigma_X^2 + \sigma_Y^2 + C_2)}, \quad (4)$$

$$\begin{cases} R_{\text{PSN}} = 10 \times \lg \frac{255^2}{E_{\text{MS}}} \\ E_{\text{MS}} = \frac{1}{N_x \times N_y} \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} [I(i, j) - \hat{I}(i, j)]^2 \end{cases}, \quad (5)$$

式中: μ 为均值; σ 为协方差; N_x 与 N_y 均为图像大小; C_1 与 C_2 为常量,避免除 0,一般分别默认为 $(0.01 \times 255)^2$ 与 $(0.03 \times 255)^2$; $I(i, j)$ 与 $\hat{I}(i, j)$ 分别为真实像素与预测像素值。使用这两种指标量化 DenseUnet 与传统 Unet 的重建性能,结果如表 2 所示。




图 11 不同网络模型重建结果的对比。(a)多模光纤输出的散斑图像;(b) DenseUnet 模型的重建结果;(c)传统 Unet 模型的重建结果;(d)原始图像(ground truth)

Fig. 11 Comparison of reconstruction results of different network models. (a) Speckle images output from multimode fiber; (b) reconstruction results of DenseUnet; (c) reconstruction results of traditional Unet; (d) original image (ground truth)

表 2 不同模型的重建质量

Table 2 Reconstruction quality of different models

Fiber length / m	Index	DenseUnet	Unet	DenseUnet-
0.1	SSIM	0.898	0.719	0.658
	PSNR	41.943	34.022	11.978
	Classification accuracy / %	98.20	95.33	85.25
1	SSIM	0.790	0.712	0.622
	PSNR	36.440	28.108	11.402
	Classification accuracy / %	97.60	92.67	79.67
10	SSIM	0.780	0.540	0.594
	PSNR	36.072	12.125	11.344
	Classification accuracy / %	97.20	73.33	68.72
20	SSIM	0.760	0.422	0.517
	PSNR	35.943	11.917	13.002
	Classification accuracy / %	97	53	68.67

由表 2 可知: 无论使用哪种评价指标, DenseUnet 模型的重建质量远高于传统的 Unet 和 DenseUnet-模型; 随着光纤长度不断增加, 两种评价指标都不断降低, 并且对于传统的 Unet 而言, 当光纤的长度达到 10 m 及以上时, 两种性能评价指标急剧下降, 表明重建图像失真严重; 对于 0.1, 1, 10 m 的光纤, DenseUnet-的重建准确率都不如 Unet, 但是对于 20 m 光纤, DenseUnet-的重建准确率要高于传统的 Unet; 对于 DenseUnet 而言, 即使光纤长度达到 20 m, 两种性能评价指标依旧很高, 表明图像重建质量较好。图像重建的效果与重建图像的分类准确率有一定的相关性, 即重建效果越好, 对应的分类准确率也就越高, DenseUnet 重建图像的分类准确率都要高于传统的 Unet 和 DenseUnet-的分类准确率, 这得益于 DenseUnet 的长距级联操作与密集连接, 网络模型能够更好地学习特征。由此可知, 对于不同长度的光纤, DenseUnet 具有较强的鲁棒性。

4 结 论

对基于 DenseUnet 的光纤成像系统进行实验研究。该传感系统按照软件和硬件的区别可以分成两个部分, 一部分为搭建空间光路, 通过空间光调制器调制目标图像, 然后将目标图像耦合进多模光纤内进行传输, 并用 CCD 相机采集多模光纤输出端的散斑; 另一个部分则是利用 DenseUnet 来将散斑复原为输入端的目标图像。对 DenseUnet 和传统的 Unet 重建结果进行对比, 实验结果表明, DenseUnet 对散斑图像进行重建时效果较好。最后对不同长度光纤产生的散斑进行重建, 实验结果表

明, 即使光纤长度明显增加, 所提网络仍然可以高精度复原图像。所提基于神经网络的光纤成像系统不仅精度高, 可以实现图像远距离传输, 而且该系统的稳定性也得到了验证。

参 考 文 献

- [1] Li S, Deng M, Lee J, et al. Imaging through glass diffusers using densely connected convolutional networks[J]. *Optica*, 2018, 5(7): 803-813.
- [2] Rahmani B, Loterie D, Konstantinou G, et al. Multimode optical fiber transmission with a deep learning network[J]. *Light: Science & Applications*, 2018, 7: 69.
- [3] Fan P F, Zhao T R, Su L. Deep learning the high variability and randomness inside multimode fibres [EB/OL]. (2018-07-18) [2020-06-21]. <https://arxiv.org/abs/1807.09351>.
- [4] 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.
- [5] Lu H M, Li Y J, Uemura T, et al. Low illumination underwater light field images reconstruction using deep convolutional neural networks [J]. *Future Generation Computer Systems*, 2018, 82: 142-148.
- [6] Zhao J, Sun Y Y, Zhu H B, et al. Deep-learning cell imaging through Anderson localizing optical fiber[J]. *Advanced Photonics*, 2019, 1(6): 066001.
- [7] Vellekoop I M, Mosk A P. Focusing coherent light through opaque strongly scattering media[J]. *Optics Letters*, 2007, 32(16): 2309-2311.
- [8] Huang H L, Chen Z Y, Sun C Z, et al. Focusing laser beams through opaque scattering media [J]. *Chinese Journal of Lasers*, 2015, 42(6): 0602004. 黄惠玲, 陈子阳, 孙存志, 等. 激光光束经过不透明

- 散射介质的聚焦[J]. 中国激光, 2015, 42(6): 0602004.
- [9] Yaqoob Z, Psaltis D, Feld M S, et al. Optical phase conjugation for turbidity suppression in biological samples[J]. Nature Photonics, 2008, 2(2): 110-115.
- [10] Li C M Y. Optical phase conjugation (OPC) for focusing light through/inside biological tissue [J]. Infrared and Laser Engineering, 2019, 48(7): 0702001.
- [11] Popoff S M, Lerosey G, Carminati R, et al. Measuring the transmission matrix in optics: an approach to the study and control of light propagation in disordered media [J]. Physical Review Letters, 2010, 104(10): 100601.
- [12] Sun X Y, Wang J N, Li W, et al. Dynamic target imaging through scattering media based on optical transmission matrix[J]. Chinese Journal of Lasers, 2018, 45(12): 1205001.
孙雪莹, 王剑南, 李伟, 等. 基于光学传输矩阵实现透过散射介质的动态目标成像[J]. 中国激光, 2018, 45(12): 1205001.
- [13] Li Y Z, Xue Y J, Tian L. Deep speckle correlation: a deep learning approach towards scalable imaging through scattering media [EB/OL]. (2018-09-26) [2020-06-21]. <https://arxiv.org/abs/1806.04139>.
- [14] Sun Y W, Shi J H, Sun L, et al. Image reconstruction through dynamic scattering media based on deep learning[J]. Optics Express, 2019, 27(11): 16032-16046.
- [15] Zhou L N, Xiao Y, Chen W. Imaging through turbid media with vague concentrations based on cosine similarity and convolutional neural network[J]. IEEE Photonics Journal, 2019, 11(4): 1-15.
- [16] Lyu M, Wang H, Li G W, et al. Learning-based lensless imaging through optically thick scattering media [J]. Advanced Photonics, 2019, 1(3): 036002.
- [17] Borhani N, Kakkava E, Moser C, et al. Learning to see through multimode fibers [J]. Optica, 2018, 5(8): 960-966.
- [18] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [19] Huang G, Liu Z, van der Laurens M, et al. Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI. New York: IEEE Press, 2017: 2261-2269.
- [20] Lin M, Chen Q, Yan S C, et al. Network in network [EB/OL]. (2014-03-04) [2020-06-21]. <https://arxiv.org/abs/1312.4400>.
- [21] Haykin S, Bart K. Gradient based learning applied to document recognition [J]. Intelligent Signal Processing, 2001: 306-351.