

基于机器学习的散射环境下光学调控及成像的研究进展*

甘文凤¹, 张希仁^{2**}, 张 洪¹, 黎 燕¹

(1. 国家电网有限公司西南分部, 成都 610000; 2. 电子科技大学 光电科学与工程学院, 成都 610054)

摘 要: 对基于机器学习的散射环境下光学调控及成像目前研究的现状进行梳理。从网络类型、网络结构、训练方法等方面分析现有技术的优势与不足, 对其发展脉络进行梳理。在此基础上, 进一步讨论了基于机器学习的散射环境下光学调控及成像技术的未来发展方向。

关键词: 机器学习; 支持向量机; 深度学习; 散射介质; 光学成像

中图分类号: TN21 **文献标志码:** A **文章编号:** 1005-488X(2020)04-0239-12

Optical Controlling and Imaging Through Scattering Media Using Machine Learning

GAN Wenfeng¹, ZHANG Xiren², ZHANG Hong¹, LI Yan¹

(1. State Grid Southwest Division, Chengdu 610000, CHN; 2. School of Optoelectronic Science and Engineering, University of Electronic Science and Technology of China, Chengdu 610054, CHN)

Abstract: The application history and research progress in machine-learning-based optical controlling and imaging through scattering media were reviewed, and several representative machine learning algorithms and network architectures were analyzed in detail. Finally, the research progress and trend of the machine learning used in optical controlling and imaging through scattering media were summarized. Existing problems and future research priorities were discussed as well.

Key words: machine learning; supported vector machine; deep learning; scattering media; optical imaging

收稿日期: 2020-05-13

* 基金项目: 国家自然科学基金项目(61775030)

作者简介: 甘文凤(1973—), 男, 高级工程师, 主要从事电力信息通信及图像处理等方面的研究; (E-mail: 1597326999@qq.com)

张希仁(1977—), 男, 副教授, 主要从事光学成像、调控光在散射介质中的传输及光学检测等方面的研究; (E-mail: xiren3208@163.com)

张 洪(1978—), 男, 高级工程师, 长期从事电力系统通信及图像处理等方面的研究。(E-mail: sepczy@163.com)

** 通讯作者

引 言

在强散射环境如烟、雾、云、生物组织等情形下,由于介质对光有强的散射效应导致波前发生严重畸变形成散斑,使得传统光学成像系统并不能对隐藏在散射介质中的目标成像。因此,如何在强散射环境下对目标进行识别与成像已经成为光学成像领域如烟雾成像^[1-2]、图像传输^[3]、无透镜成像^[4]、水下成像^[5]、生物医学成像^[6]等的重要研究内容和课题,也是当前研究前沿和热点之一。

为了解决上述问题,近年来,国内外先后提出了光学相干层析成像^[7]、波前整形^[8-9]、相位共轭^[10-11]、传输矩阵^[12-13]、散斑相关成像^[14-15]、飞行时间(TOF)^[16]等多种新的成像机理和实验方法来实现对隐藏在散射介质中的物体成像。但这些技术也存在一些不足:如波前整形技术优化时间长;相位共轭和传输矩阵方式的光学系统复杂,且需要校正和扫描过程;TOF采用脉冲光源且需要条纹相机或单光子雪崩二极管(SPAD)作为探测器,系统构建昂贵。此外,这些技术都必须建立物理模型并通过反演算法实现对被散射介质隐藏的目标成像。而这些物理模型都是模拟光在散射介质传输过程,其精度依赖于成像系统的几何结构和其它物理参数,这导致反演过程在数学上是一个病态问题。而物理模型和实际系统之间的偏差也会严重削弱这类散射成像系统的性能。这些因素极大地限制了这类基于模型的成像技术的推广与应用。鉴于此,有必要引入新的理论和技术用于此类极端环境下的目标成像,降低这类光学成像系统对物理模型的依赖关系,并使得光学成像系统适应不同强散射环境下的目标成像。

近年来,机器学习特别是深度学习取得的突破性进展^[17],在许多具有挑战性的成像问题如超分辨率成像^[18-19]、降噪^[20-21]、分割^[22]、压缩成像^[23-24]、层析成像^[25-26]、数字标注^[27]、全息成像^[28-29]、相位恢复^[30-31]等中,都展示了强大的性能。与传统的基于模型的方式相比,机器学习能拟合任意复杂度的连续函数,实现输入到输出之间的复杂映射关系。端到端的机器学习不需要任何的前提和先验知识,而仅仅利用大的数据集完成对成像问题的学习,生成学习模型,实现对图像的恢复。而散射环境下的成像问题也属于此类逆问题,因此,机器学习也逐渐被用于散射环境下光学成像。显然,基于机器学习的强散射环境下光学成像不依赖于具体物理模型,这克服

了物理模型不准确的缺点,也不需要复杂光学系统来提取相位或者传输矩阵,仅仅通过目标图像和散斑对学习网络进行训练,就可建立散斑与成像之间的对应关系,极大简化了强散射环境下光学成像过程。文中将对近年来用于散射环境下光学成像的机器学习中的支持向量机、深度学习等技术进行介绍,分析各种方法的优缺点,最后给出结论和展望。

1 散射环境下光学调控与成像原理

在散射介质环境下,在散射介质入射面和探测面之间的光的传播仍遵循光的衍射理论,一般情况下表示为:

$$y = F(x) \quad (1)$$

其中 x 为散射介质的输入光场模式, y 是通过散射介质在成像面上的散斑, $F(\bullet)$ 表示为入射面到探测面之间的函数关系,一般用菲涅尔衍射描述。

传统方法实现散射环境下光传输的调控、对目标成像或聚焦基本原理如图1(a)所示,利用波前调制器件如空间光调制器(spatial light modulator, SLM)、数字微镜器件(digital micromirror device, DMD)、折变晶体等补偿因散射介质产生的相位差、对散射/随机介质的入射光波前相位进行调控,使透过随机介质的光束在目标点发生相干增强,实现聚焦和成像。其调控过程是以光的衍射、干涉、散射和随机矩阵等理论(描述散射介质的散射特性)为基础,建立光束前向传输物理模型(都可用式(1)表示)来描述光在散射介质中的传输过程。衍生的调控技术主要有波前成形、相位共轭、传输矩阵等,显然这类方法高度依赖于模型精度,不同的光学系统对应的模型不同,因此这种方法移植性和普适性差。

为了克服传统的基于模型的散射介质入射光场调控方法的不足,机器学习逐渐被引入来描述散射介质的输入输出光场之间的复杂关系,一般情况可表示为:

$$x = F^{-1}(y) \quad (2)$$

其中, $F^{-1}(\bullet)$ 为 $F(\bullet)$ 的反函数。

由于机器学习中的支持向量机、人工神经网络、深度学习网络等在理论上可拟合任意连续函数,因此,可利用机器学习来描述散射介质的输入模式和输出的散斑之间的关系(公式(2)),基本原理如图1(b)所示,利用散斑图和原始图像对网络进行训练,再利用训练后的网络对未知图像的散斑进行

测试,从而实现图像恢复。文章将重点介绍机器学习在散射环境下的目标识别、目标成像和波前调控等方面的应用。

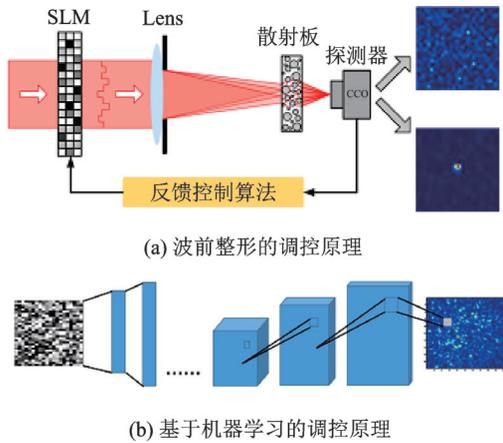


图1 散射环境下两种调控方式

Fig.1 Two light control methods in scattering media

2 强散射环境下目标识别

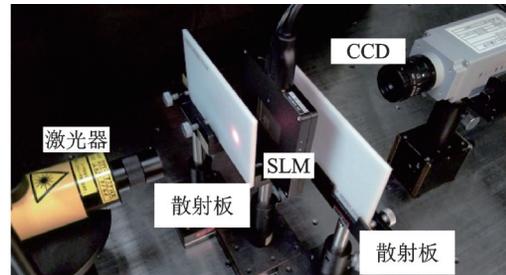
通过散射介质对目标进行识别和分类在生物学和安全领域有重要应用价值,也是光学成像领域中的重要课题。传统方法是采用自相关或傅里叶系数提取散斑图像特征,再采用分类器对图像进行分类、进行识别^[32-33],但是需要选择合适的特征提取算法对模糊图像的特征进行提取(甚至许多情况下人工进行提取选取),显然这会增加算法选取的难度,且不具有普适性。此类技术仅适用于弱散射环境下目标(图像模糊或存在散斑,但仍能呈现图像特征)的识别,而不能用于在强散射环境(形成散斑,无图像轮廓)下目标识别。因此,许多学者提出了基于机器学习的强散射环境下目标识别方法。其核心思想是对目标的散斑统计特性进行学习、实现目标分类与识别。

基于机器学习的散射环境下目标识别主要包括传统机器学习如支持向量机(SVM)、人工神经网络(NN)、随机森林(Random Forest)等和深度学习如卷积网络(CNN)、生成对抗网络(GAN)等。

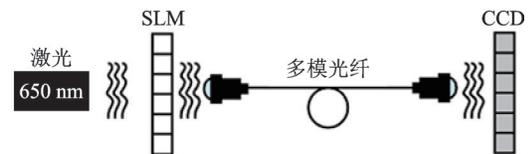
2.1 基于传统机器学习的强散射环境下目标识别

Horisaki等率先利用支持向量先后实现了通过散射介质和多模光纤的目标,对人脸和非人脸进行了识别^[34-35]。实验过程包括样本采集、模型训练和测试三个步骤。其中样本采集是利用光学成像系统(如图2(a)和(b)所示)收集散斑和对应图像(图像

显示在SLM上、CCD采集对应散斑);再将散斑和对应原始图像作为训练样本对支持向量机进行训练;最后利用训练后的模型对未知散斑进行分类识别。基于散斑的分类流程如图3所示^[36]。



(a) 经过散射板的人脸识别^[34]



(b) 经过多模光纤的人脸识别^[35]

图2 两种环境下人脸识别的实验平台

Fig.2 Two experiment setups for face recognition

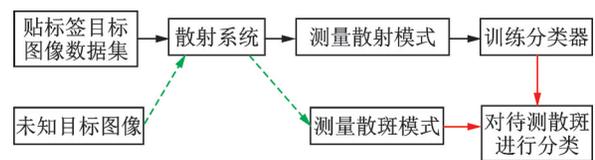


图3 散斑分类流程^[36]

Fig.3 Flow chart of speckle pattern classification

样本采集过程中,作者采用随机抽样的方式提取部分散斑像素(分别为25, 50, 100, 200, 400和800个像素)作为SVM输入以降低SVM输入的维度、提高SVM的训练速度,节省训练时间。文献[34]进一步分析了识别精度与像素数及训练样本数目之间的关系。测试结果也表明识别率随着采样的像素数目增加而逐渐增加。当采样精度为800像素时,其识别精度更高,达到了97.6%(强散射板)和94.8%(弱散射板),取得了较好的识别效果。

文献[34,35]的工作奠定了基于机器学习的散射环境下目标识别与成像的工作基础,后续的很多研究工作都是沿着这一思路进行的。但Horisaki小组提出的方法仅能实现单类目标(人脸)分类。为了改进Horisaki的方法,上海交通大学的Chen等^[36]提出了基于散斑的分类方法。他们首先从理论上证明了散斑和原目标图像的自相关矩阵具有相同的奇异值,随后利用四种分类算法(PCA+SVM,

SRC, K-SVD 和 Kernel KSVD)对多类目标的散斑进行分类,取得了较高的分类精度。该方法表明深入挖掘散斑包含的目标信息,建立散斑和目标之间关系,有助于改进目标分类效果。

2.2 基于深度学习的强散射环境下目标分类

随着机器学习技术在散射环境下目标分类问题中得到应用,许多小组先后将最新的机器学习理论——深度学习用于被散射介质^[37]或光纤等隐藏的目标分类问题^[38-39]。MIT 的 Satat 等^[37]将 VGG (Visual Geometry Group) 网络引入到散射环境下的目标分类的问题中,其流程和实验系统如图 4(a)和(b)所示,其实验系统是基于飞行时间的光学成像系统。与前面介绍的方法(直接通过光学成像系统生成训练集)不同的是, Satat 等利用蒙特卡洛 (Monte Carlo, MC) 离线模拟在各种实验参数下光子传播特性,仿真计算生成训练集对卷积神经网络进行训练,使训练网络能适应在不同参数下成像系统的成像特性(对标定参数具有不变性)。在网络结构方面,文献[37]将 VGG 网络结构的 3×3 空间滤波器扩展为 $3 \times 3 \times 10$ 三维时空卷积滤波器(最后一项代表时间)。对 MNIST 数字集的分类精度达到 74%。木偶的各种姿态精度如图 5 所示。结果表明,不需要任何标定,光学系统就可通过深度学习网络对被散射介质隐藏的目标进行分类。

Satat 等提出的技术主要有三方面优势:一是利用蒙特卡洛算法合成在各种物理参数下的训练数据,不需要通过光学系统产生,这极大降低成像质量对光学系统的依赖性;二是分类过程对光学系统的物理参数变化依赖性小。但此方法也存在以下不足:没有对目标成像;实验原理是基于飞行时间的成像原理,实验系统成本较高,这在一定程度上限制了该技术的应用。

2.3 分类算法分类精度比较

从前面可知,无论是传统的机器学习还是最新的深度学习都可用于解决散射环境下目标识别问题。对于传统的机器学习方法,由于各种方法对散斑特性的学习能力不同,导致其识别精度也存在差异。

文献[35]~[37]利用各自的光学系统分别对传统的分类算法进行分析比较。文献[35]对比分析了 SVM、神经网络(neural network, NN)和自适应提升算法(adaptive boosting, AB)三种方法的识别精

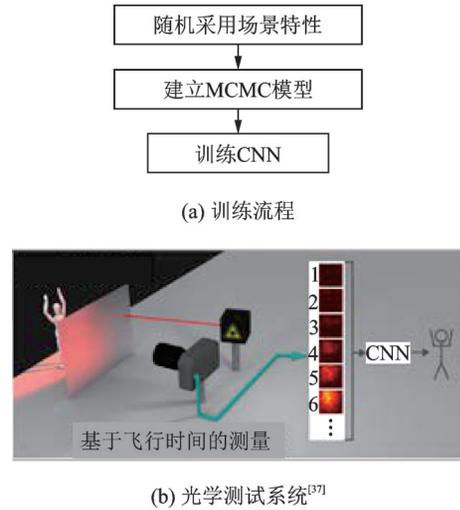


图 4 基于散斑的目标分类原理

Fig.4 Object classification through scattering media

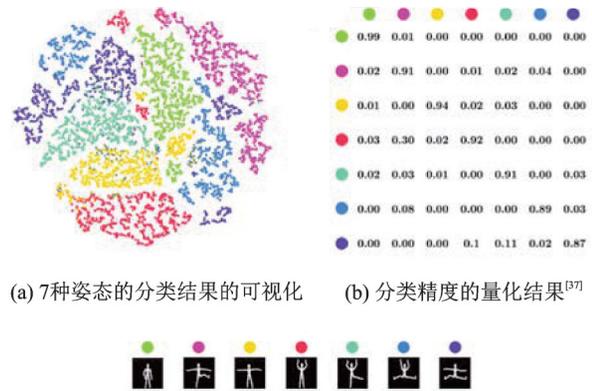


图 5 各种姿态的分类测试结果

Fig.5 Classification of seven poses on synthetic test dataset

度。实验结果表明当散斑采样率都为 800 像素时, SVM, AB 和 NN 的人脸识别精度分别达到了 92.2%, 87.7% 和 89.1%。显然,支持向量机的识别精度最高,神经网络次之,自适应提升算法识别精度最差。而文献[36]对比分析了基于目标散斑的自相关特性的目标分类算法, PCA+SVM, SRC, K-SVD 和 Kernel KSVD 四种分类算法分类精度如表 1 所示,显然四种算法的分类精度相差不多。

表 1 4 分类算法对 MINIST 数据分类精度比较^[36]

Tab.1 Speckle pattern classification accuracies of related four methods

算法	分类精度/(%)	
	训练样本数	训练样本数
	10 000	50 000
PCA+SVM	91.25	95.28
SRC	95.28	97.55
KSVD	95.8	97.00
Kernel KSVD	96.00	97.88

而文献[37]对VGG、均值采样、KNN、SVM、随机森林、单层网络等分类方法进行了对比分析,如表2所示。测试结果表明基于VGG网络的分类精度要比其它分类算法高很多。显然,由于传统的机器学习的分类算法对采集的散斑特征的学习能力比深度学习差,导致其分类的精度比深度学习的低。

表2 6种分类算法用于强散射环境下目标分类结果对比^[37]

Tab.2 Comparison of different six approaches on classification of the clean and realistic datasets

分类算法	训练集	
	合成数据	真实数据
Mean example	33.3	33.3
KNN	53.0	30
SVM	57.1	20
Random forest	68.8	30
Single layer network	68.2	23.8
VGG	84	76.6

3 强散射环境下光学成像

3.1 基于经典机器学习的强散射环境下光学成像

相比其它基于特征提取的识别方式^[40-41],Horisaki提出的目标识别方法不需要提取特征、也不需要建立物理模型,具有显著优势。但是,在识别过程中,作者仅仅利用了散斑图像少部分像素,而其余像素都丢失了。这种方式虽然节省了训练时间,但没有充分利用散斑图像信息。因此,这种技术不能实现散射环境下的图像恢复。为了克服这种不足,Horisaki小组提出利用支持向量回归(support vector regression, SVR)从散射环境下的散斑中恢复目标图像^[42]。其采用的实验系统如图6所示,SLM1和SLM2用于加载原始图像,CCD采集对应的散斑。光束两次穿过SLM导致光束被调控两次,使得波前调控和记录的散斑呈现非线性关系。因此,不能采用经典的传输矩阵模型^[8]和方法^[12]恢复图像。为提高训练速度,作者仍随机采样部分像素作为输入对SVR进行训练和测试,测试结果如图7所示。结果显示SVR可初步用于人脸图像恢复。但训练后的SVR模型只能对单一的人脸图像进行恢复,却不能用于其它的图像恢复。显然SVR模型难以实现从散斑图中对多种类型目标图像进行恢复,其原因在于SVR模型较简单,难以表征多种类型图像的特征。

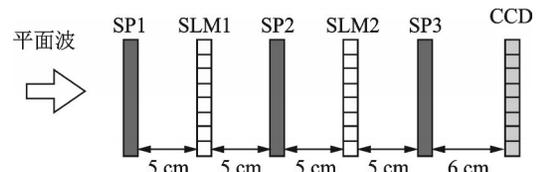
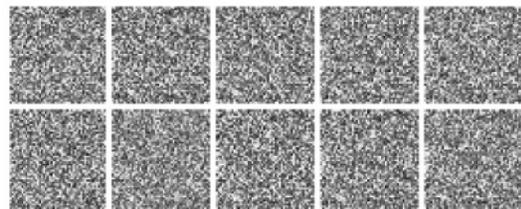


图6 基于SVR的散射介质图像恢复^[42]

Fig.6 Setup for the experimental demonstration



(a) 测试人脸



(b) 采集的散斑图



(c) SVR恢复的人脸^[42]

图7 测试结果^[42]

Fig.7 Ten examples of the experimental test pairs

为解决上述问题,使训练的模型能恢复多种类型的图像,上海交通大学的Chen等对Horisaki的光学成像系统进行简化^[36,43-44],先后利用SVR实现了散射介质中的目标成像。文献[36]提出基于散斑分类的支持向量回归算法(speckle pattern classification based support vector regression, SPC-SVR),其基本原理为:首先对不同类型图像的散斑进行分类,然后再利用每一类的散斑和目标图像分别对SVR进行训练、获取每类的回归模型,从而实现对不同类型的目标图像的恢复,其流程如图8所示。测试结果(如图9所示)表明与传统的散射成像方法如波前成形、鬼成像和相位提取技术相比,采用SPC-SVR方法能更好地实现图像恢复,并且分类精度越高,图像恢复质量更好。

实验表明,通过大量的散斑和对应图像对SVM进行训练,的确可建立散斑和图像之间的函数关系,实现对散射环境下的目标分类、对单目标成像,

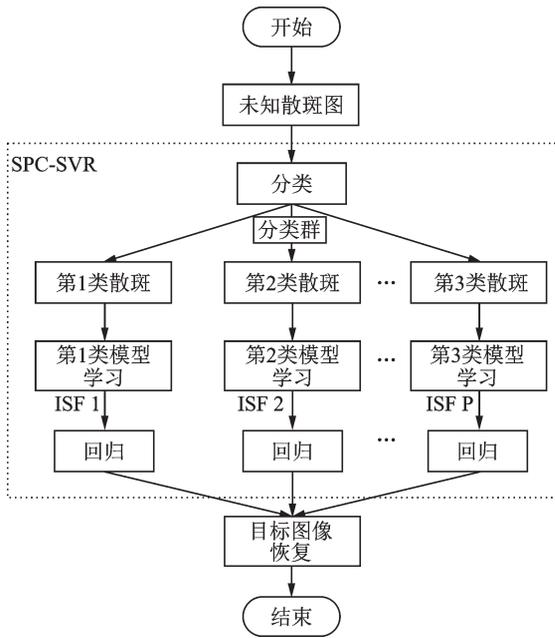


图 8 图像恢复工作流程^[36]

Fig.8 Flow chart of reconstruction of images

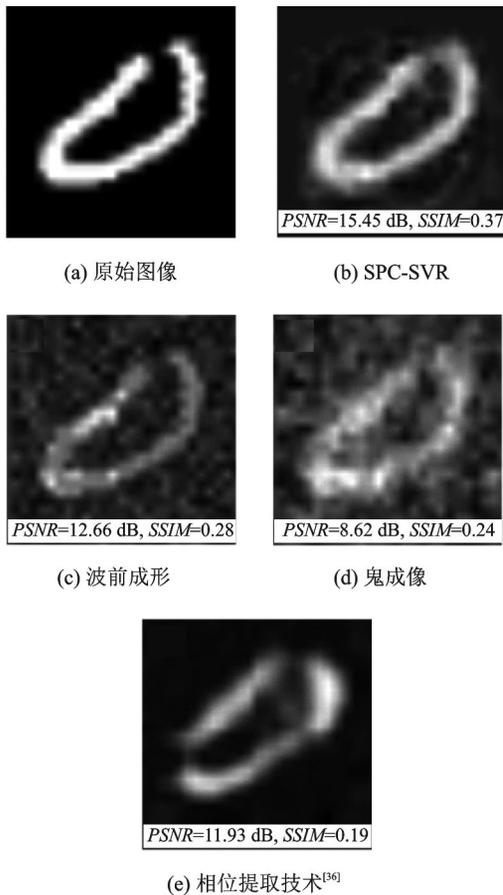


图 9 不同方法成像效果^[36]

Fig.9 Reconstructions with different methods

但是也存在一些不足:仅仅利用SVM不能实现对各种目标成像(需要借助其它技术如分类才能解决

多类目标成像问题);在前面提及的文献中,核函数都是采用非线性的径向基函数,对于许多线性散射介质,其输入和输出光场是线性关系,文献并没有讨论和分析核函数是否可采用线性函数。

3.2 基于深度学习的强散射环境下光学成像

深度学习(deep learning, DL)是以人工神经网络为基础的,由Hinton等人^[45]在2006年提出。深度学习是一种特征学习方法,把原始数据通过一些简单的、非线性的模型转变成为更高层次的、更加抽象的表达。相对于传统的优化算法^[46],深度学习人工干预少,解决了经典的人工神经网络优化困难、应用受限等问题。近年来,在基于深度学习的图像恢复等复杂逆问题方面取得了重大进展,其展现的性能和功能方面都超越了传统的基于模型的图像恢复技术^[17,47]。中国科学院上海光学精密机械研究所LYU等提出利用深度神经网络(DNN)实现对隐藏在散射板后的目标进行成像^[48-49]。

文献[48]采用实验平台和网络结构如图10(a)和10(b)所示。在网络结构方面,该方法的网络结构设计简单,采用了2个重塑层、4个隐藏层和1个输出层。重塑层1是将 64×64 散斑重塑为 1×4096 向量,隐藏层神经元数分别为8192、44096、2048和16384,输出层为784个神经元。在训练策略方面,该方法采用ReLU(rectified linear units)为激活函

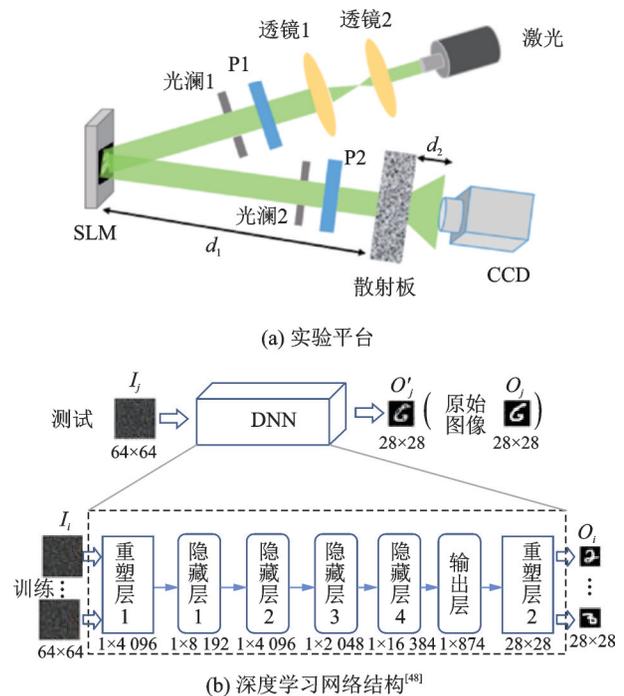


图 10 实验原理

Fig.10 Principle of experiments

数,采用均方误差(MSE)作为损失函数,采用随机梯度下降法(Stochastic gradient descent, SGD)最小化损失函数,改进网络训练速度。

实验中仅通过数字(MNIST集)及对应的散斑对网络进行训练,训练后的网络不仅实现了从未知散斑中恢复对应的数字图像(如图11第2行所示),还能从散斑中恢复对应的字母图像,这是经典机器学习如SVM方法无法完成的,这也表明对于散射环境下的成像,深度学习具有极大优势。此外,实验中采用厚的聚苯乙烯散射材料(厚度3 mm,大约是光子平均散射长度的13.4倍),减弱了记忆效应^[50],导致散斑相关和相位恢复^[11-12]等基于记忆效应的传统成像方法失效,如图11第4行所示。DNN恢复的图像的轮廓非常清晰,背景散斑也非常少,其图像恢复质量要优于传统技术如波前成形、相位共轭和传输矩阵技术,这也进一步说明传统技术的局限性。但从测试结果看出,由于神经网络固有的问题(网络局部最优化和过拟合问题)导致成像图像中存在暗条纹和黑点,这需要对网络结构以及优化算法进一步改进。

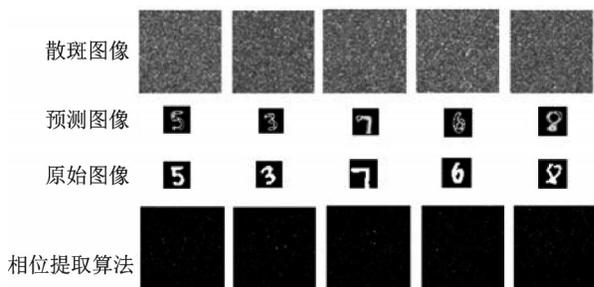
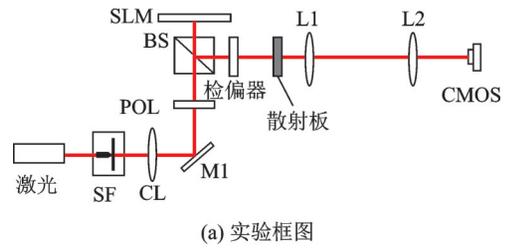


图11 测试结果^[48]

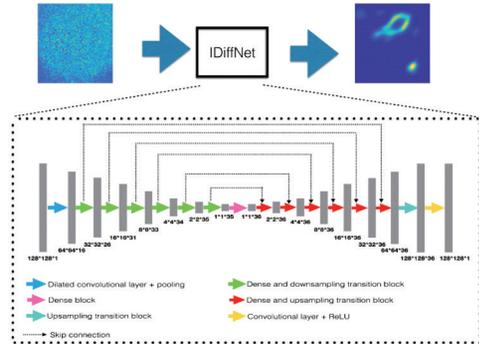
Fig.11 The experimental results

Li等以密接卷积网络(the densely connected convolutional network, Dense Net)为基础,详细分析了在不同训练集、散射介质和损失函数等条件时的成像质量^[51],其实验平台和学习网络分别如图12(a)和(b)所示。在网络结构方面,系统中采用了“编码-解码”结构,其中利用密接和下采样过滤块为编码器从散斑中提取特征,密接+上采样作为解码器实现图像恢复。为了实现散斑图和物平面之间的映射关系,系统采用了膨胀卷积(膨胀率为2)和5×5的滤波器。同时通过跳跃连接忽略图像恢复中高频信息。

训练过程中采用了两个损失函数——绝对平均误差MAE和负Pearson相关系数(negative Pearson correlation coefficient, NPCC)。



(a) 实验框图



(b) IDiffNet网络结构^[51]

图12 实验原理

Fig.12 Principle of experiments with images through diffuse media

从成像质量来看,散射介质的散射越强,图像恢复越困难。另外,网络性能也严重依赖于训练数据集。Li通过对三种数据集(Faces-LFW、ImageNet和MNIST)的测试发现,通过ImageNet集训练的网络性能最好,图像恢复质量高,采用MNIST数据集(有较强稀疏性)训练的网络在三个网络中适应性最差,存在严重的过拟合现象,不能对其它的图像进行恢复。从成像效果来看,在强散射介质情况下,图像恢复能力和清晰度差,这需要再优化网络结构和损失函数,从而改善成像质量。

其它课题组也先后利用深度学习网络实现了在非线性光纤(全柔性玻璃空气散射光纤)中的图像传输和恢复^[52-53]、散射环境下图像恢复^[54]。但是,这些实验及模型仅仅适用于散射介质和光通过散射介质上固定位置时的目标分类和成像,对不同位置 and 不同样品,则需要重新构建物理模型或需对机器学习模型重新进行训练,这限制了其在散射介质成像中的应用。

为了克服上述缺陷,波士顿大学的Tian小组构建了一种卷积神经网络(光学实验平台如图13所示),学习多个散射板形成的散斑的统计特性,训练后的网络能有效体现所有散射板的统计信息,因此能对不同散射板的散斑进行恢复^[55],其原理和采用的神经网络结构分别如图14和图15所示。网络甚至能实现通过未知散射板形成的散斑图恢复对应原始图像。显然,相对于前面所述方法(拟合散射

介质的输入输出的函数关系,且仅对一个散射介质有效),该方法具有更好的泛化特性,为散射介质成像提供了新的思路。

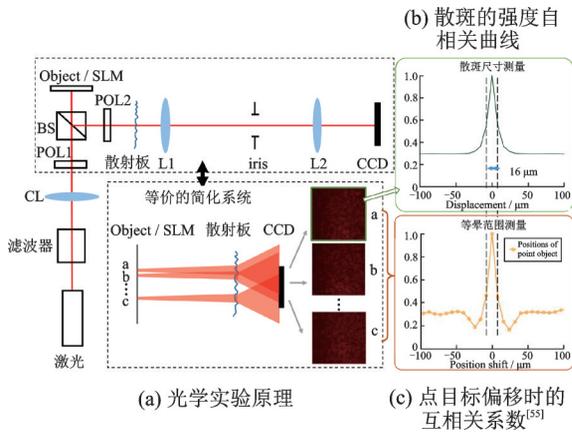
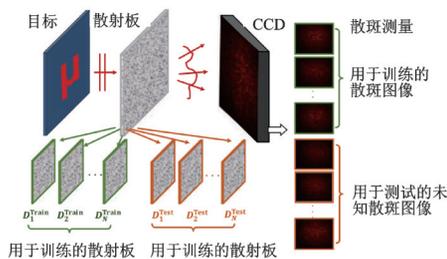
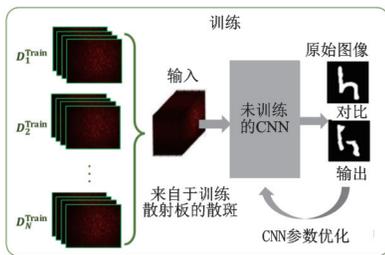


图 13 实验原理

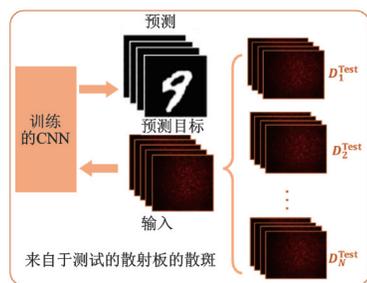
Fig.13 Principles of experiments



(a) 散斑测量过程



(b) 训练过程



(c) 测试过程^[55]

图 14 基于深度学习的散射成像原理

Fig.14 DL-based imaging through scattering technique

中国科技大学基于U-net结构和Adam优化器的深度学习网络实现了对通过散射介质和多模光

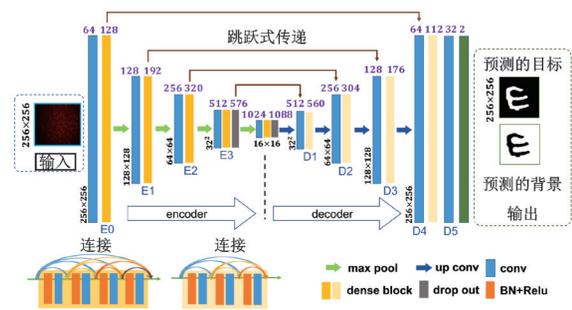


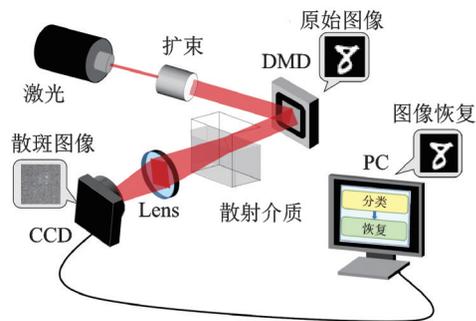
图 15 实验中采用的卷积网络结构^[55]

Fig.15 Proposed CNN architecture to learn statistical relationship between speckle patterns and unscattered objects

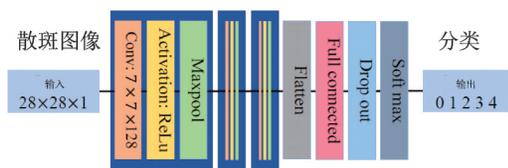
纤的目标图像的恢复,并且仅采用手写数字数据集训练的网络也能实现对手写字母的图像恢复。同时,通过同一网络,成功实现了通过散射介质不同位置形成的散斑对图像的恢复。因此,该网络模型具有一定的鲁棒性^[56],且也降低了实验过程中对系统稳定性的严苛要求。而对于时变随机介质,上海交通大学的Su提出了基于散斑的图像分类及恢复技术,其模型主要由分类网络和生成对抗网络(GAN)组成^[57],主要流程为:

(1) 实验中采用的数据集为手写数字集MNIST,采集的光学实验平台如图 16(a)。每个时变散射环境(实验中采用5种不同浓度的脂肪乳溶液模拟不同的时变散射环境)下采集5 000张散斑图,共采集25 000张散斑图。

(2) 每种类型图像中的4 000张和对应的散斑图



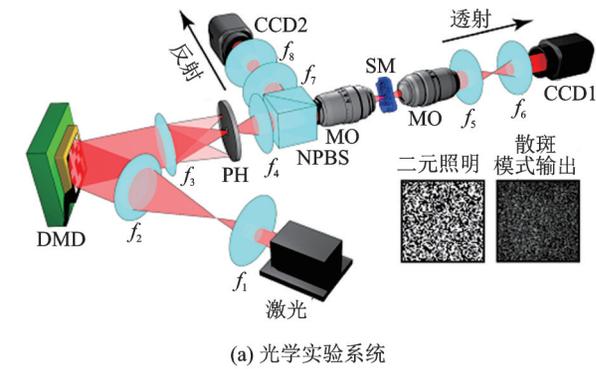
(a) 光学实验系统



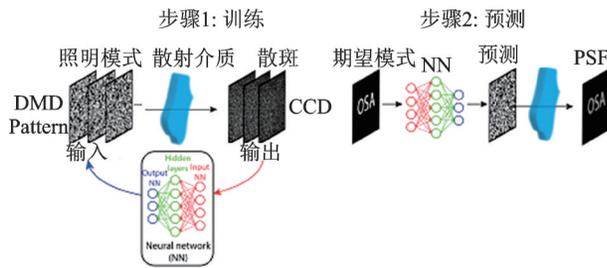
(b) 分类网络^[57]

图 16 实验原理

Fig.16 Principle of experiments



(a) 光学实验系统

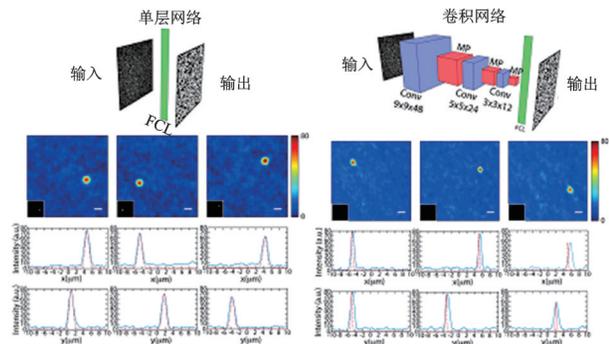


(b) 基于神经网络的散射介质中光束调控流程^[59]

图 20 实验原理

Fig.20 Principles of experiments

(digital micromirror device)加载的随机二元调控模式作为输出对网络进行训练,建立网络模型;测试过程中,将光学系统期望的输出模式输入网络计算调控模式,将调控模式输入DMD中对波前进行调控,则可在光学系统的CCD上观察到期望图像。Turpin的实验展示了利用SLNN实现对散射介质如散射板、光纤和白纸等入射波前调控、在特定位置的聚焦或成像,如图21所示,其调控性能与传输矩阵方式^[60]类似。Turpin等也对比分析了SLNNs和CNN调控性能,实验结果发现CNN的调控性能却比SLNN差,这主要因为SLNN的线性特性与介



(a) 利用单层网络实现聚焦 (b) 利用CNN实现聚焦^[59]

图 21 利用学习网络实现聚焦

Fig.21 Focusing with neural networks

质的线性特性一致,而CNN通过网络结构设计不仅能描述线性映射关系,也可描述非线性映射关系,这导致了CNN在调控性能方面比SLNN差。但是,CNN不依赖于物理模型,具有更强的泛化性,且网络参数数目更少(相对于SLNN,降低了80%)。另外,Turpin在文献中也尝试了利用两个SLNN建立前向散射和后向散射之间的映射关系,并利用这种关系实现了通过后向散射对前向散射的调控,其训练过程和测试结果如图22所示。但是利用传统技术却难以实现这种调控。

5 各种算法性能比较

表3总结比较了各种机器学习算法的结构、用途和优缺点等。其中,SVR算法不仅能用于散射介质的成像,也可实现对散射介质的入射光波前进行调控,但成像比较模糊,质量差。而基于深度学习的各种网络能实现对散射介质成像,质量较好,并

表 3 主要机器学习的算法比较

Tab.3 Comparison of machine learning algorithms

算法名称	网络结构	损失函数	用途	评价函数	算法性能评价
SVR ^[34-35,42,58]	支持向量回归	/	目标识别、波前调控	识别精度,PSNR	较差,不能识别非人脸图像
SPC-SVR ^[36]	分类+支持向量回归	/	图像恢复	PSNR和SSIM	准确率高,但图像较模糊
CNN ^[37]	VGG	/	目标识别	识别率	精度较高
DNN ^[48]	2个重塑层、4个隐藏层和1个输出层	MSE	图像恢复	/	准确率高,但存在过拟合,模型可迁移
IDiffNet ^[51]	密集卷积网络	MAE、NPCC	图像恢复	/	准确率高,恢复质量较差
DL ^[55]	编码-解码的U-net结构	平均交叉熵	图像恢复	/	图像恢复质量高
DNN ^[56]	U-net结构	二元交叉熵	图像恢复	MSE和相关系数	图像恢复质量高
DL ^[57]	分类网络+GAN	MSE和交叉熵	图像恢复	PCC、PSNR、SSIM	图像恢复质量较高
SLNN ^[60]	单层感知+非线性激活函数	/	波前调控	MSE	网络参数较多
CNN ^[60]	3个卷积层+最大池化操作	/	波前调控	MSE	参数较少

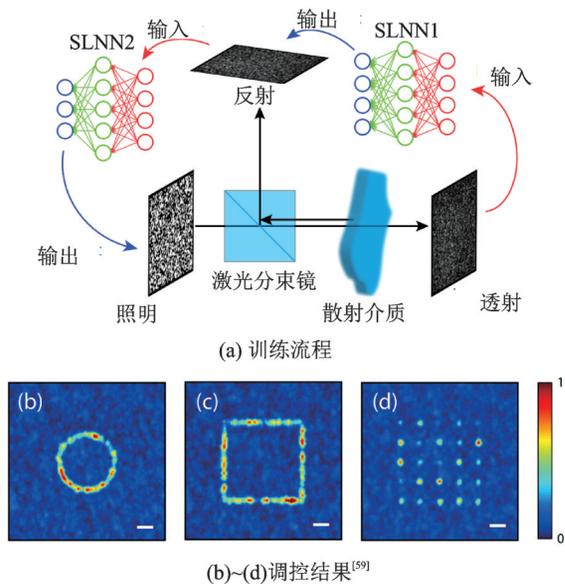


图22 利用单层神经网络实现基于反射光束调控透射光束
Fig.22 Control of transmitted light using reflected light by single-layer network

且通过训练,可实现对多个散射介质的成像,具有一定的泛化性,这是传统算法不可比拟的。

6 结论和展望

机器学习在强散射环境下的目标识别、分类与成像中具有广泛的应用前景,目前已经成为复杂环境下光学成像领域的研究热点,国内外多个研究小组也在此领域做了初步的研究工作,并在学习网络类型和结构的建立、数据集采集、光学实验平台以及训练方式上都做出了有益的尝试。展望今后的发展方向,在以下问题中尚存在着挑战与机遇:

1. 学习网络构建:在强散射环境中,由于需要从散斑图像中提取出能表征目标图像的特征(这显然比机器视觉中特征提取更为复杂),这必然会增加网络的复杂程度,也会增加网络对目标的识别难度。因此,需要在现有的机器学习/深度学习理论基础,提出新的网络结构;另外,如何更好地利用散斑时空特性来指导网络结构设计,使得设计出的学习网络更适合散射环境下的成像,从而改进散射环境下目标识别与成像的性能,这也需要进一步挖掘与探索。

2. 面向实际应用场景的机器学习方法:现有文献中采用的散射环境大都是以散射板为散射样品,其散斑特性具有时间不变性。但实际应用环境如烟、雾、尘、雨、云、生物组织等具有时变特性,如何针对这些应用环境设计光学成像系统和学习网络,

如何收集学习样本是需要进一步探索的课题。另外,如何将这些环境下的先验信息与深度网络结构、代价函数以及训练方式结合是有潜力的研究方向。

3. 非相干光源照明环境下的机器学习方法:现有文献中光学实验都是采用的相干光源作为照明光源,但实际应用场景中多为非相干光源。在非相干光源照明下,借助深度神经网络强大的学习能力,研究散射环境时的目标分类和成像具有重要的理论意义和应用价值。

4. 基于机器学习的散射环境下的光场调控:已有的报道中大部分都是分析和讨论在散射环境下利用散斑为输入、目标图像为输出对机器学习模型进行训练,实现目标成像和识别。但较少涉及利用机器学习方式调控光束在散射介质中的散射、传输甚至吸收等特性, these 问题是生物医学光子学、光与物质相互作用过程中的重要问题,如何利用机器学习讨论上述问题具有重要的理论和应用价值。

总之,机器学习包括深度学习在强散射环境下目标识别与成像领域中已初步展现了巨大的潜力。但是,仍有很多尚未完善的工作,需要更多的研究者开展富有创新性的工作。

参 考 文 献

- [1] Berman D, Treibitz T, Avidan S. Non-local image dehazing [C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 2016: 1674-1682.
- [2] Holodovsky V, Schechner Y Y, Levin A, et al. In-situ multi-view multi-scattering stochastic tomography [C]. IEEE International Conference on Computational Photography, Las Vegas, NV, USA, 2016: 1-12.
- [3] Li G, Yang W, Wang H, et al. Image transmission through scattering media using ptychographic iterative engine [J]. Applied Sciences, 2019, 9: 849.
- [4] Nick A, Grace K, Heckel R, et al. Diffuser Cam: lensless single-exposure 3D imaging [J]. Optica, 2018, 5(1): 2334-2536.
- [5] Sheinin M, Schechner Y Y. The next best underwater view [C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 2016: 3764-3773.
- [6] Mosk A P, Lagendijk A, Leroosey G, et al. Controlling waves in space and time for imaging and focusing in complex media [J]. Nature Photonics, 2012, 6(5): 283-292.
- [7] Huang D, Swanson E A, Lin C P, et al. Optical coherence tomography [J]. Science, 1991, 254(5035): 1178-1181.
- [8] Vellekoop I M, Mosk A P. Focusing coherent light through opaque strongly scattering media [J]. Optics Letters, 2007, 32(16): 2309-2311.
- [9] Vellekoop I M. Feedback-based wavefront shaping [J]. Optics Express, 2015, 23(9): 12189-12206.
- [10] 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.

- [11] Si K, Fiolka R, Cui M. Fluorescence imaging beyond the ballistic regime by ultrasound pulse guided digital phase conjugation [J]. *Nature Photonics*, 2012, 6(10):657-661.
- [12] Popoff S, Lerosey G, Fink M, et al. Image transmission through an opaque material [J]. *Nature Communications*, 2010, 1(1):81-1-81-5.
- [13] 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): 197-202.
- [14] Bertolotti J, Putten E G, Blum C, et al. Noninvasive imaging through opaque scattering layers [J]. *Nature*, 2012, 491(7423): 232-234.
- [15] Katz O, Heidmann P, Fink M, et al. Non-invasive single-shot imaging through scattering layers and around corners via speckle correlations [J]. *Nature Photonics*, 2014, 8(10): 784-790.
- [16] Satat G, Heshmat B, Naik N, et al. Advances in ultrafast optics and imaging applications [J]. *SPIE Defense Security*, 2016. 9835: 98350Q.
- [17] LeCun Y, Bengio Y, Hinton G E. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [18] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, HI, USA, 2017: 105-114.
- [19] Rivenson Y, Göröcs Z, Günaydin H, et al. Deep learning microscopy [J]. *Optica*, 2017, 4(11): 1437-1443.
- [20] Burger H C, Schuler C J. Image denoising: Can plain neural networks compete with BM3D? [C]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Providence, Rhode Island, USA, 2012: 2392-2399.
- [21] Zhang K, Zuo W, Chen Y, et al. Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising [J]. *IEEE Trans. Med. Imaging*, 2017, 26(7): 3142-3155.
- [22] Ronneberger O, Fischer P, Brox T, et al. U-Net: Convolutional networks for biomedical image segmentation [C]. *Medical image computing and computer assisted intervention*, Munich, Germany, 2015: 234-241.
- [23] Yao H, Dai F, Zhang D, et al. Dr2-net: Deep residual reconstruction network for image compressive sensing [J]. *Neurocomputing*, 2019, 359: 483-493.
- [24] Kulkarni K, Lohit S, Turaga P, et al. Reconnet: Non-iterative reconstruction of images from compressively sensed measurements [C]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, NV, USA, 2016: 449-458.
- [25] Jin K H, McCann M T, Froustey E, et al. Deep convolutional neural network for inverse problems in imaging [J]. *IEEE Trans. Med. Imaging*, 2017, 26(9): 4509-4522.
- [26] Nguyen T, Bui V, Nehmetallah G. Computational optical tomography using 3-D deep convolutional neural networks [J]. *Optical Engineering*, 2018, 57(4): 043111-1-043111-12.
- [27] Christiansen E M, Yang S J, Ando D M, et al. In silico labeling: Predicting fluorescent labels in unlabeled images [J]. *Cell*, 2018, 137(3): 792 - 803.
- [28] Rivenson Y, Zhang Y, Günaydin H, et al. Phase recovery and holographic image reconstruction using deep learning in neural networks [J]. *Light-Science & Applications*, 2018, 7(2): 17141.
- [29] Ren Z, Xu Z, Lam E Y. Learning-based nonparametric autofocusing for digital holography [J]. *Optica*, 2018, 5(4): 337-344.
- [30] Nguyen T, Bui V, Lam V, et al. Automatic phase aberration compensation for digital holographic microscopy based on deep learning background detection [J]. *Optics Express*, 2017, 25(13):15043-15057.
- [31] Sinha A, Lee J, Li S, et al. Lensless computational imaging through deep learning [J]. *Optica*, 2017, 4(9): 1117-1125.
- [32] Tyo J S, Rowe M P, Pugh E N, et al. Target detection in optically scattering media by polarization difference imaging [J]. *Appl. Opt.* 1996,35(11): 1855-1870.
- [33] Shin D, Lee J J, Lee B G. Recognition of a scattering Recognition 3D object using axially distributed image sensing technique [J]. *ARN J. Eng. Appl. Sci.* 2014;9: 2085-2088.
- [34] Ando T, Horisaki R, Tanida J. Speckle-learning-based object recognition through scattering media [J]. *Optics Express*, 2015, 23(26): 33902-33910.
- [35] Takagi R, Horisaki R, Tanida J. Object recognition through a multi-mode fiber [J]. *Optical Review*, 2017, 24(2):117-120.
- [36] Chen H, Gao Y, Liu X, et al. Imaging through scattering media using speckle pattern classification based support vector regression [J]. *Optics Express*, 2018, 26(20): 26663-26678.
- [37] 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.
- [38] Navid B, Eirini K, Christophe M, et al. Learning to see through multimode fibers [J]. *Optica*, 2018, 5(8):960-966.
- [39] Wang P, Di J. Deep learning-based object classification through multimode fiber via a CNN-architecture speckle net [J]. *Applied Optics*, 2018, 57(28): 8258-8263.
- [40] Zdunek A, Adamiak A, Pieczywek P M, et al. The biospeckle method for the investigation of agricultural crops: a review [J]. *Optical Lasers Engineering*, 2014, 52: 276 - 285.
- [41] Nassif R, Nader C A, Afif C, et al. Detection of golden apples' climacteric peak by laser biospeckle measurements [J]. *Applied Optics*, 2014, 53(35): 8276 - 8282.
- [42] Horisaki R, Takagi R, Tanida J. Learning based imaging through scattering media [J]. *Optics Express*, 2016, 24(13): 13738-13743.
- [43] Chen H, Gao Y, Liu X. Speckle reconstruction method based on machine learning [J]. *Proc. SPIE.*, 2018, 10711: 107111U-1-107111U-4.
- [44] Chen H, Gao Y, Liu X, et al. Imaging through scattering media via support vector regression [J]. *Optics Communications*, 2019: 126-131.
- [45] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [46] Afonso M V, Bioucas-Dias J M, Figueiredo M A T. Fast image recovery using variable splitting and constrained optimization [J]. *IEEE Trans. Med. Imaging*, 2010, 19(9): 2345-2356.
- [47] Lucas A, Iliadis M, Molina R, et al. Using deep neural networks for inverse problems in imaging: beyond analytical methods [J]. *IEEE Signal Processing Magazine*, 2018, 35(1): 20-36.