

# 基于残差 UNet 的水下 Mueller 矩阵图像去散射算法

李晓欢, 王霞\*, 王丛赫, 张鑫

北京理工大学光电学院光电成像技术与系统教育部重点实验室, 北京 100081

**摘要** 针对高浑浊水体环境散射严重、目标成像不清晰和对比度低的问题, 在传统 UNet 结构的基础上, 结合偏振成像理论, 提出了基于残差 UNet (Mu-UNet) 网络的水下 Mueller 矩阵图像去散射算法。该算法依据 Mueller 矩阵图像提供的目标强度信息和偏振信息, 建立不同浑浊度水下多个目标物的图像数据集。在 UNet 基础上引入残差模块, 利用构建的 Mu-UNet 网络提取目标底层信息, 学习标签图像特征, 重建出对比度高、细节信息更丰富的水下目标复原图像。对比实验结果表明, 所提算法在峰值信噪比方面较原图提升了 89.40%, 结构相似度提升了 82.37%。相比传统算法和 UNet 网络, 所提算法得到的复原图像具有更明显的去散射效果, 细节更精细, 为水下偏振清晰成像探测提供了一种新思路。

**关键词** 图像处理; 水下散射; 偏振成像; Mueller 矩阵; 残差 UNet; 目标探测

中图分类号 O438

文献标志码 A

DOI: 10.3788/AOS202242.2410001

## De-Scattering Algorithm for Underwater Mueller Matrix Images Based on Residual UNet

Li Xiaohuan, Wang Xia\*, Wang Conghe, Zhang Xin

Key Laboratory of Photoelectronic Imaging Technology and System, Ministry of Education, School of Optics and Photonics, Beijing Institute of Technology, Beijing 100081, China

**Abstract** Considering the problems of severe scattering, unclear target imaging, and low contrast in high-turbidity water environments, a residual UNet (Mu-UNet)-based de-scattering algorithm for underwater Mueller matrix images is proposed on the basis of the traditional UNet structure and polarization imaging theory. According to the intensity and polarization information of targets provided by Mueller matrix images, this algorithm establishes the image data sets of multiple targets under different turbidities. The residual module is introduced on the basis of UNet, and the Mu-UNet is used to extract the underlying information of the targets, which learns the characteristics of the labeled images and finally reconstructs the underwater target images with high contrast and detailed information. The comparative experimental results reveal that compared with the original image, the image restored by the proposed algorithm is improved by 89.40% in the peak signal-to-noise ratio, and the structural similarity is improved by 82.37%. Compared with traditional algorithms and UNet, the proposed algorithm can obtain restored images with a more significant de-scattering effect and finer details, which provides a new idea for the detection and high-quality imaging of underwater polarization.

**Key words** image processing; underwater scattering; polarization imaging; Mueller matrix; residual UNet; target detection

## 1 引言

水下目标成像技术在海洋资源勘探、搜救和军事侦察等领域中十分关键<sup>[1-3]</sup>。由于水体的吸收、散射和对光波的衰减作用, 故采集到的图像往往比较模糊, 目

标信息被湮没在背景散射中无法分离, 产生“看不清”的现象, 影响了后续对水下目标的识别与分析<sup>[4-6]</sup>。因此, 如何在高浑浊水体中增强目标图像细节、提升对比度, 进而实现清晰成像, 是水下成像领域的重点研究问题之一<sup>[7]</sup>。

收稿日期: 2022-04-14; 修回日期: 2022-05-17; 录用日期: 2022-05-25

基金项目: 国家自然科学基金(62031018)

通信作者: \*angelniuniu@bit.edu.cn

分析水下成像特点发现,后向散射光是引起图像退化的主要原因。后向散射光属于部分偏振光,而目标直接反射光一般为非偏振光,因此利用光波偏振信息可有效抑制后向散射光的影响,提升图像质量。Schechner等<sup>[8]</sup>在传统水下复原模型的基础上,采用主动偏振光照射目标,获取同一目标的最大和最小光强图像,并通过差分处理抑制后向散射光,获得了清晰的目标图像。在此基础上,诸多学者对水下偏振成像模型和算法进行了改进<sup>[9-13]</sup>,均取得了一定的成果。近些年随着深度学习的发展,各种各样的神经网络不断涌现。其中,卷积神经网络在解算端到端图像映射关系方面具有明显优势,能快速学习图像的特征和结构,提取高维度的信息<sup>[14]</sup>,在透过散射介质成像等领域中表现得尤为出色<sup>[15]</sup>。因此,有学者将深度学习引入水下偏振成像领域中,并取得了一定的效果。Hu等<sup>[16]</sup>提出了基于深度学习的水下偏振成像复原算法,通过构建的Polarimetric dense(偏振密集)网络对自制偏振图像数据集进行训练,实验结果表明在不同浑浊度下不同场景中该算法均较好地复原了目标的图像,验证了深度学习算法在水下偏振成像领域中的可行性。Cheng等<sup>[17]</sup>提出了基于Mueller矩阵的深度学习水下图像复原方法,将Mueller矩阵图像作为训练数据输入到UNet网络中进行训练,显著地提升了目标的细节和纹理信息。虽然深度学习方法的引入能有效提高水下图像的复原质量,但是目前相关算法还较少,主要是由于网络训练需要大量的数据,而水下偏振图像数据集的制作比较耗时,且通过传统的卷积神经网络(CNN)训练的模型常存在过拟合问题,故需要改进网络的结构以提升模型的泛化能力。

为解决上述问题,本文提出了一种基于残差UNet(Mu-UNet)的水下Mueller矩阵图像去散射算法。首先,通过传统偏振成像原理解算出水下目标的Mueller矩阵图像,相比于偏振图像,Mueller矩阵图像信息更加完整,更能全面地反映物体表面的偏振特征,故构建了不同浑浊度下的Mueller矩阵图像数据集。其次,鉴于UNet网络结构在小样本数据集上具有优异的表现,将经典UNet网络结构由4层加深到5层,并引入瓶颈残差模块,在进行多尺度特征融合的同时,解决了网络深度增加所带来的训练困难的问题。最后,将训练好的模型应用在不同水下场景中进行测试,均获得了较好的复原效果,验证了训练模型的泛化性。

## 2 基本原理

### 2.1 Mueller矩阵的获取

通常,采用Stokes矢量 $S$ 来描述一束偏振光的状态,其表达式为

$$S = \begin{bmatrix} I \\ Q \\ U \\ V \end{bmatrix} = \begin{bmatrix} I_0 + I_{90} \\ I_0 - I_{90} \\ I_{45} - I_{135} \\ I_R + I_L \end{bmatrix}, \quad (1)$$

式中: $I$ 是投影在传感器上的总光强; $Q$ 是 $0^\circ$ 方向偏振

分量与 $90^\circ$ 方向偏振分量的光强差; $U$ 是 $45^\circ$ 方向偏振分量与 $135^\circ$ 方向偏振分量的光强差; $V$ 是左旋圆偏振分量与右旋圆偏振分量的光强差。当入射光经过物体表面时,出射光的偏振态会发生一定规律的变化,这种变化可以视作物体对入射偏振光的调制。如果入射光和出射光均用Stokes矢量表示,则二者的关系为

$$S_{\text{out}} = MS_{\text{in}} = \begin{bmatrix} m_{11} & m_{12} & m_{13} & m_{14} \\ m_{21} & m_{22} & m_{23} & m_{24} \\ m_{31} & m_{32} & m_{33} & m_{34} \\ m_{41} & m_{42} & m_{43} & m_{44} \end{bmatrix} S_{\text{in}}, \quad (2)$$

式中: $S_{\text{in}}$ 为入射光的Stokes矢量; $S_{\text{out}}$ 为出射光的Stokes矢量; $M$ 为目标的Mueller矩阵。Mueller矩阵是一个包含16个参量的系数矩阵,矩阵中每个元素都包含了与物体相关的重要信息,反映了目标表面的偏振特性。其中, $m_{11}$ 表示目标对入射光传输、散射和反射的能力, $m_{12}$ 、 $m_{13}$ 、 $m_{14}$ 表示目标对水平线偏振光、垂直线偏振光和圆偏振光的衰减能力, $m_{21}$ 、 $m_{31}$ 、 $m_{41}$ 反映了目标对入射非偏振光的偏振能力,其余9个参量代表目标对入射光的退偏能力和相位延迟能力。从式(2)中可以看出,只要求出入射光和出射光的Stokes矢量,就可以反解出目标的Mueller矩阵。

本文采用偏振片旋转法<sup>[18]</sup>获取目标的Mueller矩阵,通过调节起偏部分的偏振片和 $1/4$ 波片的角度可获得6种不同的入射光偏振态,调节检偏系统的偏振片和 $1/4$ 波片同样可得到6种不同的出射偏振态,最终可获得36种不同的起偏、检偏组合。采集每种组合情况下的强度图像,再利用代数运算得到目标的Mueller矩阵。

### 2.2 Mu-UNet网络模型

传统UNet<sup>[19]</sup>网络采用左右对称的U型结构,通过编码器和解码器逐层提取低级特征与高级语义信息,并利用特有的跳层连接进行特征融合,使得网络对图像的细节特征更加敏感,适用于图像增强及分割任务。本文主要关注水下目标的去散射重建任务,且不同材质的目标具有不同的偏振特性,因此可以视其为一个具有分类和分割思想的图像增强问题。由于传统UNet网络在浅层特征提取后不能充分地表达下一层特征中,且利用跳层连接直接融合深度特征和浅层特征会因差别过大产生语义鸿沟,故在经典UNet结构基础上,本文提出了一种新的结构(Mu-UNet),即将原来UNet的4层下采样结构加深到5层,期望提取到更多的图像细节特征,并在每层下采样后引入残差模块代替单层卷积,这在加深网络的同时,减少了模型优化时因网络过深产生的梯度消失或爆炸问题。

Mu-UNet网络的结构如图1所示,输入为Mueller矩阵图像中的强度图像和偏振图像构成的张量( $256 \times 256 \times 12$ ),输出为经网络训练学习后增强的图像。主体Mu-UNet网络包括5个下采样和5个上采样过程,在由下采样构成的编码器部分,先使用大小为 $1 \times 1$ 的卷积核提取输入的Mueller图像中的强度特征和偏振特征,并改变通道数以控制网络的深度。然后,采用设

计的 Res Block 进一步提取图像特征并对网络进行加深处理,如图 2 所示,其中  $x$  代表残差模块输入的特征图,  $F(x)$  为残差函数,即残差模块的输出。图 2 (a) 所示的残差模块 Res Block 1 通过两个大小为  $3 \times 3$  的卷积层提取特征,并增大感受野,在 Res Block 1 基础上将其改进为具有瓶颈层的残差模块 Res Block 2。如图 2(b) 所示,Res Block 2 先采用大小为  $1 \times 1$  的卷积核进行降维处理,在经过批量归一化 (BN) 和 ReLU 函数激活后,中间采用大小为  $3 \times 3$  的卷积核进行特征提取,最后再用大小为  $1 \times 1$  的卷积核对特征图的通道数进行还原,这样在保证网络深度和感受野的同时,可减少参数和计算量。同时,利用跳层连接学习残差模块输入和输出之间的残差特

征,有利于网络优化并减少额外的模型参数。此后,使用  $2 \times 2$  的最大池化层 (Max Pooling) 对特征图进行下采样,使得特征图的分辨率下降到原来的一半,经过 5 次下采样后,图像分辨率变为  $8 \times 8$ ,此时所提取的特征图中主要为目标及水体的偏振与散射特征。在由上采样构成的解码器部分,利用双线性内插方法进行上采样,并利用跳层连接与编码器中得到的特征图进行通道拼接,使得网络能够充分融合浅层特征和深层语义信息。最终,基于“分类思想”的不同材料目标物的偏振特性被 Mu-UNet 提取的这些高级语义信息所表征,进而在样本测试时可以对不同材料的水下目标物有针对性地恢复,即模型具有一定的泛化能力。

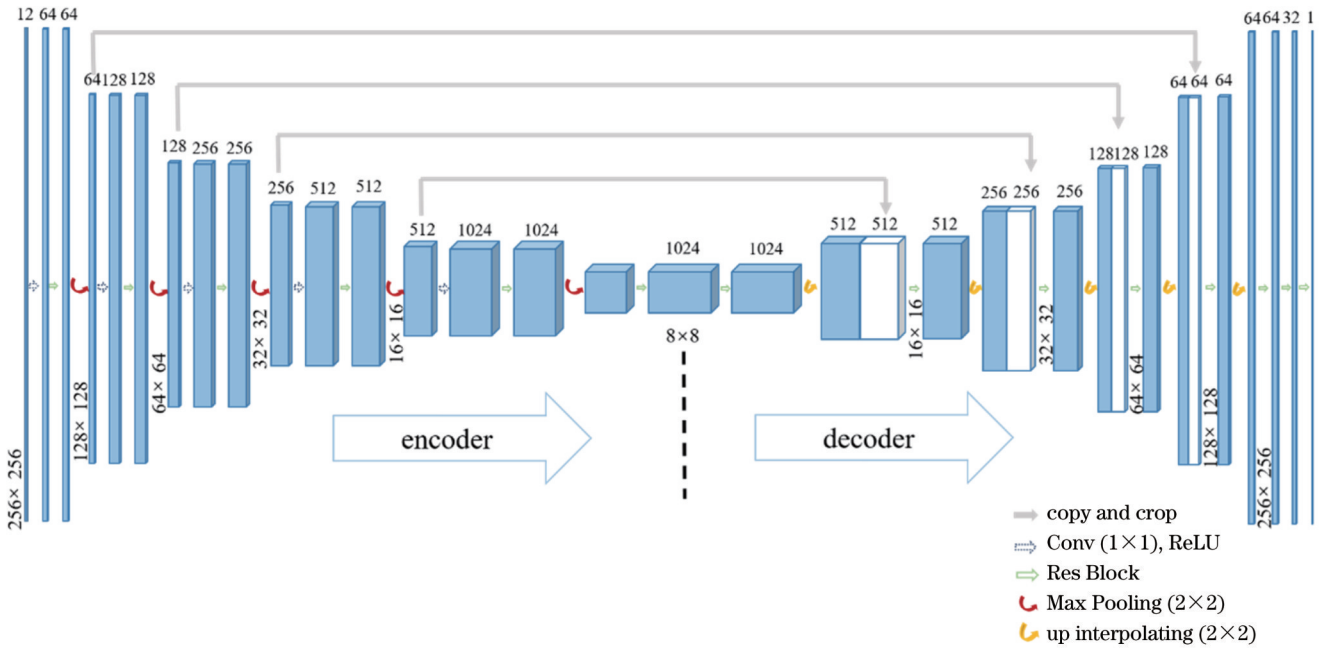


图 1 Mu-UNet 网络的模型结构

Fig. 1 Model structure of designed Mu-UNet network




图 2 网络中残差模块 Res Block 的示意图。(a) 残差模块结构; (b) 改进的具有瓶颈层的残差块结构

Fig. 2 Schematic diagram of residual module Res Block in network. (a) Structure of residual module; (b) improved residual block structure with bottleneck layer

### 3 实验结果与分析

#### 3.1 实验装置及数据集的建立

本文搭建的水下偏振成像系统如图 3 所示。目标被放置在一个大小为  $387 \text{ mm} \times 388 \text{ mm} \times 290 \text{ mm}$  的

有机玻璃水箱中,且距离水箱前壁  $150 \text{ mm}$ ,通过添加不同比例的水和脱脂牛奶(蛋白分子的直径为  $0.04 \sim 0.30 \mu\text{m}$ )来模拟实际海域中悬浮粒子对光波的散射衰减情况。为直观地描述介质的光学特性,引入光学厚度(衰减长度)  $\tau = \mu_s d$  来定量描述,其中  $\mu_s = 0.42c$

为脱脂牛奶的散射系数(单位为  $\text{cm}^{-1}$ ),  $c$  是牛奶在水中的浓度(以百分数表示),  $d$  是目标到成像探测器间的距离。实验中水的高度为 80 mm, 逐步添加 15~50 mL 牛奶来改变水体浑浊度, 对应的光学厚度为 0.79~2.62。

采用中心波长为 532 nm 的绿光发光二极管(LED)作为照明光源, 经过扩束准直后出射一束平行光, 该平行光经起偏部分的线偏振片(P1)和 1/4 波片(Q1)被调制成为不同偏振态的入射光并照射到目标上,

反射的散射光再经检偏部分 1/4 波片(Q2)和线偏振片(P2)进入互补金属氧化物半导体(CMOS)相机。旋转放置在相机前的波片和偏振片后可以采集到不同偏振角度的光强图, 进而得到该场景光的 Stokes 矢量, 最后基于此矢量计算 Mueller 矩阵图像。本实验采用的相机型号为海康威视的 MVL-HF0628M-6MP, 像素数为  $2448 \times 2048$ , 获取的原始图像为 16 bit 的 tif 格式图像。在获取不同目标的图像数据时, 调整起偏器和检偏器的入射角度, 使目标图像位于视场中央。

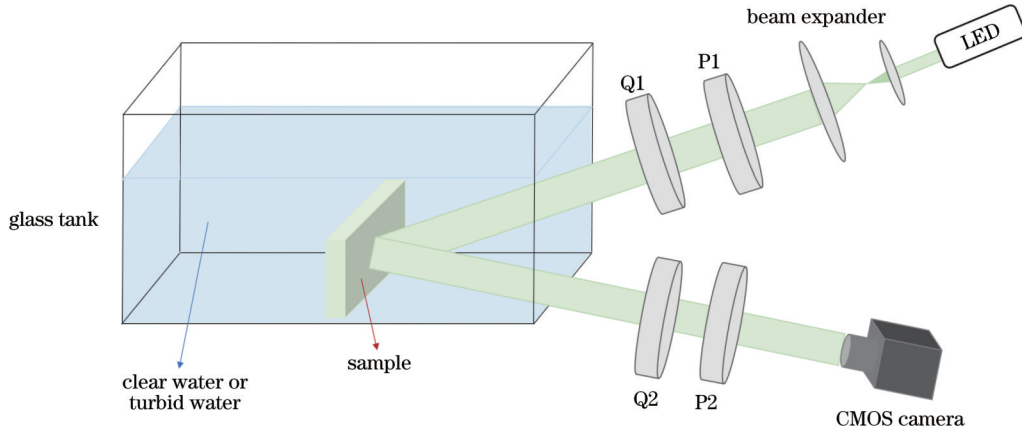


图 3 水下偏振成像实验装置图

Fig. 3 Experimental setup of underwater polarization imaging

基于图 3 的实验装置, 在暗室中对不同目标物进行实验, 排除杂散光干扰。以添加牛奶体积为 30 mL

(光学厚度为  $\tau = 1.57$ ) 时采集的校徽目标为例, 计算得到其 Mueller 矩阵图像, 如图 4 所示。




图 4 校徽目标的 Mueller 矩阵图像

Fig. 4 Mueller matrix images of school badge target

从图 4 可以看到,除强度信息外,其他分量大部分都表征了目标的不同细节信息。为提高算法的训练效率,训练数据应尽可能地提供低级特征,减少冗余数据。观察目标的 Mueller 矩阵图像发现,  $m_{34}$ 、 $m_{42}$ 、 $m_{43}$  和  $m_{44}$  这 4 个矩阵元素包含的目标信息比较少,它们都体现的

是退偏特性和二向色性,主要与水体散射相关。为客观论述,引入 Canny 算子对 16 幅图像进行边缘检测和提取,滤波结果如图 5 所示,其中  $\sigma$  表示提取边缘的精细程度, $\sigma$  越小,提取的边缘轮廓越精细。可以发现,上述 4 个分量的图像对纹理细节的重建贡献的确很小。




图 5 Canny 算子对不同分量的滤波结果。(a)原始图像;(b)  $\sigma = 1.0000$ ;(c)  $\sigma = 0.0010$ ;(d)  $\sigma = 0.0001$

Fig. 5 Filtering results of different components by Canny arithmetic. (a) Origin image; (b)  $\sigma = 1.0000$ ; (c)  $\sigma = 0.0010$ ; (d)  $\sigma = 0.0001$

为定量说明这 4 个分量对算法的贡献,定义低级特征因子(LFF)来表征图像低层次特征的丰富程度,其表达式为

$$M_{LFF} = \frac{e_{ca}}{a_{ct}}, \quad (3)$$

式中: $e_{ca}$ 为Canny算子提取到的所有边缘信息值,如图6(a)所示; $a_{ct}$ 为利用Opencv中自适应阈值分割与轮廓提取所提取出的轮廓面积,如图6(b)所示。在所提取出的轮廓面积上,包含的边缘信息量越多,LFF的值越大,即轮廓细节信息越丰富。

表 1 给出了校徽目标的边缘检测因子  $e_{ca}$ 、轮廓提取因子  $a_{ct}$  和 LFF 的值。




图 6 采用Canny算子与自适应分割提取校徽图像的边缘信息和轮廓图。(a)通过Canny算子提取到的边缘信息量;(b)通过自适应阈值分割与轮廓提取得到的轮廓包围的面积

Fig. 6 Edge information and contour map of school badge image extracted by Canny operator and adaptive segmentation function. (a) Amount of edge information extracted by Canny operator; (b) area enclosed by contour obtained by adaptive threshold segmentation and contour extraction

表 1 校徽 Mueller 矩阵图像 16 个分量的 LFF 值  
Table 1 LFF values of 16 components of Mueller matrix images of school badge

Matrix element	$e_{ca}$	$a_{ct}$	LFF
$m_{11}$	3987	43.5	91.66
$m_{12}$	2235	63	35.47
$m_{13}$	1576	25	63.04
$m_{14}$	3838	204.5	18.77
$m_{21}$	6308	317.5	19.87
$m_{22}$	3945	94	41.97
$m_{23}$	3782	46	82.22
$m_{24}$	3567	295	12.09
$m_{31}$	2952	92.5	31.91
$m_{32}$	4518	337	13.41
$m_{33}$	3923	73.5	53.37
$m_{34}$	3828	509	7.52
$m_{41}$	657	43	15.28
$m_{42}$	3870	483.5	7.82
$m_{43}$	3051	290	10.52
$m_{44}$	1186	111	10.69

从表 1 可以看出,  $m_{34}$ 、 $m_{42}$ 、 $m_{43}$  和  $m_{44}$  这 4 个成分的 LFF 值处于较低的水平,说明细节信息较少,这与主观结果一致。此外,统计了多个目标物不同分量的 LFF 值,得到了与校徽目标基本一致的结论。因此,对于所有目标物,从数据集中删除了这 4 个成分,选择了剩余低层次特征丰富的 12 张图像作为网络的输入,如图 7 所示。




图 7 被选择作为网络输入的 12 张 Mueller 矩阵图像  
Fig. 7 12 Mueller matrix images selected as network input

通过逐步调整牛奶体积,建立不同浑浊程度的水下数据集,共包含 54 组 Mueller 矩阵图像,其中训练集 40 组、验证集 7 组、测试集 7 组,并以清水下目标的强度图像为标签。每组图像由选择的 12 个 Mueller 矩阵图像构成,通过裁剪、旋转对其进行数据增强处理,输入图像的分辨率为  $256 \times 256$ 。本文将几种材料的目标放在一起训练,以便充分感知水下散射的环境,最大限度地发挥 UNet 网络提供的高层语义信息和低层特征相结合的优势。

### 3.2 实验参数设置

水下去散射增强任务是图像端到端的映射,主要关注不同水下情况的图像恢复质量,故选取结构相似度<sup>[20]</sup>(SSIM)和均方误差(MSE)作为损失函数,具体表达为

$$L = L_{SSIM} + L_{MSE}, \quad (4)$$

$$L_{SSIM} = f[l(I_{re}, I_{gt}), c(I_{re}, I_{gt}), s(I_{re}, I_{gt})], \quad (5)$$

$$L_{MSE} = \frac{1}{WHS_b} \sum_{i=1}^{S_b} \sum_{(x,y)} |I_{re}^{(i)}(x,y) - I_{gt}^{(i)}(x,y)|^2, \quad (6)$$

式中: $I_{re}$ 和 $I_{gt}$ 为增强后的图像和真值图像的灰度值; $l$ 、 $c$ 和 $s$ 分别为亮度对比、失真对比和结构对比; $W$ 和 $H$ 为图像的宽度和高度; $S_b$ 为批次大小; $I_{re}^{(i)}$ 、 $I_{gt}^{(i)}$ 分别为单批次中第 $i$ 组的增强图像和真值的灰度值。结构相似度是衡量两张图像相似程度的指标,取值范围为 $0 \sim 1$ ,其值越接近 1,表示相似程度越高。均方误差是衡量两张图像之间的偏差,取值越接近于 0,说明两张图像越相近。

本文在 pytorch1.7.1 框架下进行训练,使用 CUDA 加速,中央处理器(CPU)型号为 Intel i9-7900X,图形处理单元(GPU)型号为 Nvidia RTX

2060Ti。训练过程中采用 Adam 优化器,数据批量大小设置为 4,初始学习率设置为 0.001,以确保目标函数在适当的时间收敛到局部最小值。为对比所提算法与其他算法的性能,采用峰值信噪比(PSNR)<sup>[21]</sup>和结构相似度作为客观评价指标。

### 3.3 实验结果与分析

为体现所设计网络对不同浑浊程度下散射图像复原的通用性,首先以加入的牛奶体积为变量,采集不同浑浊度下的校徽图像,校徽目标原图如图 8 所示。采用所提算法对低浓度(光学厚度为  $\tau = 1.05$ )、中浓度(光学厚度为  $\tau = 1.57$ )、高浓度(光学厚度为  $\tau = 2.36$ )三种水体浑浊度下的校徽目标进行复原,并与其他算法进行对比,复原结果如图 9 所示。可以看出,He 和 Liang 提出的算法可以一定程度上恢复出图像细节,但复原的图像整体亮度不均匀,局部出现了过亮的现象,同时仍有一些散射成分没有被去除。UNet 网络比较好地去除了浮在图像上的“雾”,但图像细节不够突出,去除散射的同时模糊了部分细节特征。所提算法有效地去除了水体对目标的散射,重构



图 8 校徽目标原图

Fig. 8 Original image of school badge target

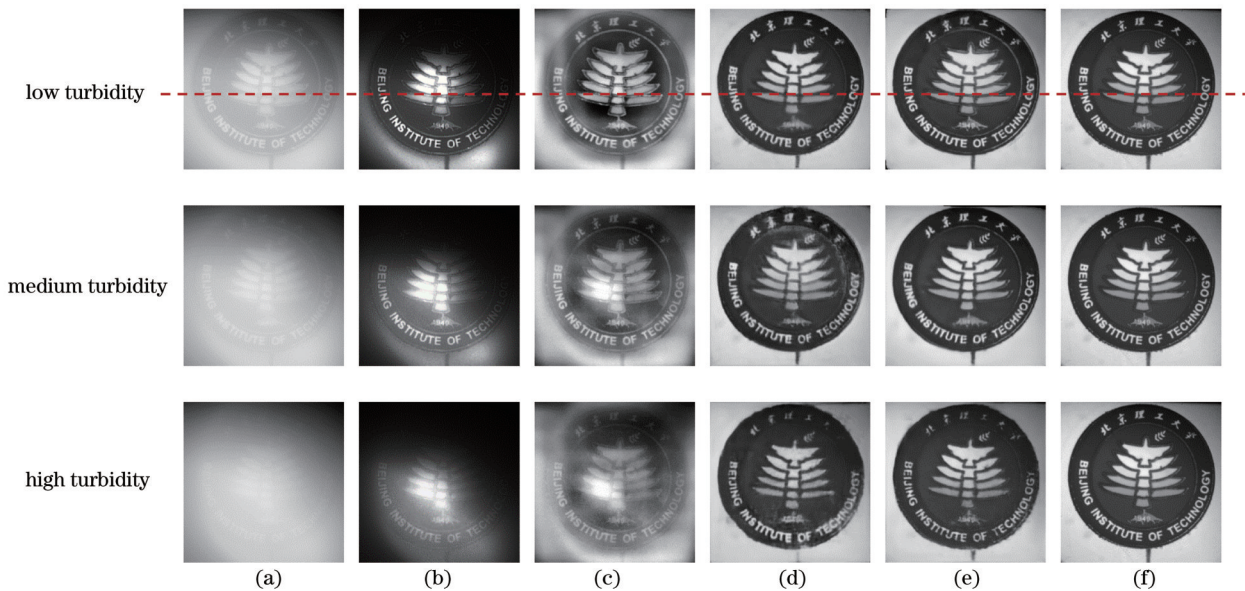


图 9 不同浑浊度下的水下图像复原结果图。(a)原始水下浑浊图像;(b) He 的方法;(c) Liang 的方法;(d) UNet 网络;(e) Mu-UNet 网络;(f)真值

Fig. 9 Restoration results of underwater image under different turbidities. (a) Original underwater image with turbidity; (b) He's method; (c) Liang's method; (d) UNet network; (e) Mu-UNet network; (f) ground truth

图像相比于原图对比度显著提高,较好地复原了图像细节。此外,在中、低浓度下所提算法复原的图像相比于其他算法与真值更为接近,在高浓度条件下,校徽上的字体及轮廓基本完整地展现出来,验证了所设计网络在水体浑浊程度上的通用性。此外,图 10 所示为分别选取图 9(a)~(f)中低浓度情况下穿过背景和目标的第 128 行(从左到右)的强度分布曲线,该曲线直观地反映了本文所对比的各种算法的重建结果与清水下真值结果的吻合程度。可以看出,所提算法重建结果与清水下真值结果基本吻合,且与原图相比,幅值变化更明显,对比度显著提高,验证了所提算法的有效性。

为验证 Mu-UNet 网络训练模型的适用性和对不同材质目标的复原效果,更换了不同的目标来进行测试,结果如图 11 所示。可以看到,对于不同偏振特性的目标,所提算法都有较好的复原效果。例如:对于橡

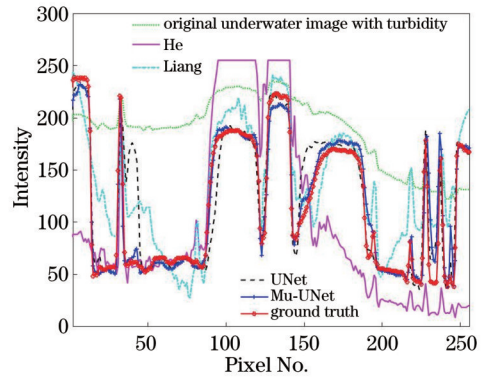


图 10 图 9 中低浓度情况下图像第 128 行像素强度值的统计曲线

Fig. 10 Statistical curves of pixel intensity values of line 128 at low concentration images in Fig. 9

胶圈、眼镜布和塑料花等低偏振度的物体,目标轮廓、




图 11 不同材质目标的水下复原结果图。(a)原始水下浑浊图像;(b) He 的方法;(c) Liang 的方法;(d) UNet 网络;(e) Mu-UNet 网络;(f)真值

Fig. 11 Underwater restoration results of different material targets. (a) Original underwater image with turbidity; (b) He's method; (c) Liang's method; (d) UNet network; (e) Mu-UNet network; (f) ground truth



突起和边缘细节基本上被复原出来,且显著地提升了对比度;对于硬币这种偏振度比较高的物体,能较好地去除目标表面的“雾”,硬币上的字体被突出出来,相比于真值上硬币表面有很多划痕,所提算法对复原图像上的这些划痕进行了平滑处理,从而使得关键信息更为突出。

表 2 展示了所提算法与其他算法客观评价指标的数据对比。可以看到,相较于传统复原算法和经典 UNet 网络,所提算法在 PSNR、SSIM 两种指标下均取得了最优的结果。基于所有测试图像,所提算法在 PSNR 方面较原图提升了 89.40%,SSIM 提升了 82.37%,与主观评价结果基本一致。

表 2 所提算法与其他算法的重建结果对比  
Table 2 Comparison of reconstruction results of proposed algorithm and other algorithms

Image No.	Index									
	Original image		He's method		Liang's method		UNet		Mu-UNet	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
1	12.37	0.21	10.74	0.07	9.08	0.19	12.42	0.26	16.32	0.35
2	13.22	0.26	8.15	0.15	16.57	0.51	15.82	0.46	20.22	0.54
3	9.60	0.48	6.55	0.22	13.3	0.43	19.57	0.69	20.14	0.75
4	11.81	0.61	4.23	0.23	9.56	0.46	13.32	0.63	20.27	0.75
5	8.51	0.27	8.03	0.21	9.23	0.26	16.11	0.58	18.61	0.72
6	10.97	0.50	5.63	0.18	12.48	0.36	25.23	0.83	27.58	0.87

为探讨算法模型对训练样本的依赖性,在现有数据集的基础上,保持测试集数据不变,减少训练样本的数量,调整训练集、验证集比例分别为 4:1 和 2:1,即随机划分数据使得训练集 37 组、验证集 10 组和训练集 10 组、验证集 16 组,在相同的训练硬件和参数条件下进行训练,对比不同训练数量下所得模型对测试集的复原效果。计算三种模型复原后图像的 PSNR 和 SSIM,如表 3 所示。可以看到,当训练样本变少时,所提算法的图像复原质量也会有所下降,但整体比传统算法好,进一步说明了所提模型的有效性。

表 3 不同模型重建结果对比  
Table 3 Comparison of reconstruction results by different models

Model No.	Train/test ratio	PSNR	SSIM
1	6:1	20.52	0.66
2	4:1	18.79	0.57
3	2:1	16.66	0.51

在算法运行效率方面,比较了传统算法与深度学习算法同时处理一张大小为  $256 \times 256$  的图像所需的时间,如表 4 所示。可以发现,基于深度学习的算法整体比传统算法要快,所提 Mu-UNet 网络与传统 UNet 网络计算效率基本持平,但复原效果强于 UNet 网络,进一步说明了所提算法的优越性。

表 4 不同算法处理单幅图像的运行时间  
Table 4 Running time of single image processed by different algorithms

Method	Times cost /s	Platform
He's	1.170	Matlab (CPU)
Liang's	7.190	Matlab (CPU)
UNet	0.157	Pytorch (GPU)
Mu-UNet	0.215	Pytorch (GPU)

最后,利用 Mu-UNet 网络训练的模型测试了在训练集中从未出现过的目标硬币,重构结果如图 12 所示。值得注意的是:低浓度(光学厚度为  $\tau = 1.04$ )情况下,原始图像上硬币的部分细节可以识别,复原后图像对比度得到显著提升,硬币边缘处文字细节被突显出来;逐渐提高牛奶浓度,达到中浓度(光学厚度为  $\tau = 1.84$ )时,原始强度图像上硬币细节无法辨认,复原后的图像中“ONE CENT”字体能被识别,背后的图案也清晰可见,表明所提算法的有效性;高浓度(光学厚度为  $\tau = 2.62$ )情况下,经算法复原后的图像整体轮廓被显现出来,部分纹理细节依稀可见,可以大致识别出目标,但复原效果比低浓度时差一些,主要是高浓度情况下,目标反射光受浑浊溶液中粒子散射严重,故采集到的原始图像细节信息非常少,肉眼几乎看不到任何信息。采用训练好的模型进行测试时,算法依靠训练时学习到的目标偏振信息和水体散射特征能基本复原出边缘和有突起的细节,证实了所提网络训练的模型是正确且合理的,验证了其泛化能力和鲁棒性。

目前,本文提出的算法在实验室条件下获取的小样本数据集上取得了比较好的复原效果。牛奶悬浊液一定程度上能模拟水中粒子的散射,理论上算法模型也适用于部分真实水下场景复原。在未来研究中,获取实际水域中目标的 Mueller 矩阵图像作为数据集,采用迁移学习方法进行模型微调,使其适用于真实水域中的目标重建。

## 4 结 论

水下偏振成像技术可有效利用光波的偏振信息解决水下成像问题。通过搭建主动偏振成像系统,在暗室环境下采集不同浑浊度水体下不同目标的偏振图像,由此构建融合了强度信息和偏振信息的 Mueller 矩阵图像数据集,并提出了基于残差 Mu-UNet 网络的水下图像复原算法。实验结果表明,所提算法能有效




图 12 未被训练的目标复原结果图

Fig. 12 Restoration results of untrained targets

地去除水体散射的影响,恢复图像细节,且显著提高图像对比度,证实了融合强度信息和偏振信息有利于提高水下图像的恢复质量。此外,从网络训练模型的泛化性方面验证了深度学习可有效应用于偏振领域。在未来的研究中将考虑详细地研究散射水体的偏振特性,利用深度学习学习方法学习散射造成的图像退化机理,针对系统入射角度、反射角度建立更完善的水下散射模型,以更好地重构与增强浑浊水下图像,并将其应用于真实水域的目标重建任务中。

## 参 考 文 献

- [1] Panetta K, Gao C, Agaian S. Human-visual-system-inspired underwater image quality measures[J]. IEEE Journal of Oceanic Engineering, 2016, 41(3): 541-551.
- [2] 郭继昌,李重仪,郭春乐,等.水下图像增强和复原方法研究进展[J].中国图象图形学报,2017,22(3): 273-287.  
Guo J C, Li C Y, Guo C L, et al. Research progress of underwater image enhancement and restoration methods [J]. Journal of Image and Graphics, 2017, 22(3): 273-287.
- [3] 管风,韩宏伟,张晓晖.水下目标激光成像的可视化模型[J].中国激光,2020,47(5): 0510002.  
Guan F, Han H W, Zhang X H. Model for visualization of laser imaging of underwater targets[J]. Chinese Journal of Lasers, 2020, 47(5): 0510002.
- [4] 王明军,李乐,易芳,等.模拟真实水体环境下目标激光点云数据的三维重建与分析[J].中国激光,2022,49(3): 0309001.  
Wang M J, Li L, Yi F, et al. Three-dimensional reconstruction and analysis of target laser point cloud data under simulated real water environment[J]. Chinese Journal of Lasers, 2022, 49(3): 0309001.
- [5] Singh H, Adams J, Mindell D, et al. Imaging underwater for archaeology[J]. Journal of Field Archaeology, 2000, 27(3): 319-328.
- [6] Xu Y, Wen J, Fei L K, et al. Review of video and image defogging algorithms and related studies on image restoration and enhancement[J]. IEEE Access, 2016, 4: 165-188.
- [7] 刘飞,孙少杰,韩平丽,等.水下偏振成像技术研究及进展[J].激光与光电子学进展,2021,58(6): 0600001.  
Liu F, Sun S J, Han P L, et al. Development of underwater polarization imaging technology[J]. Laser & Optoelectronics Progress, 2021, 58(6): 0600001.
- [8] Schechner Y Y, Karpel N. Recovery of underwater visibility and structure by polarization analysis[J]. IEEE Journal of Oceanic Engineering, 2005, 30(3): 570-587.
- [9] Amer K O, Elbouz M, Alfalou A, et al. Enhancing underwater optical imaging by using a low-pass polarization filter[J]. Optics Express, 2019, 27(2): 621-643.
- [10] 封斐,吴国俊,吴亚凤,等.基于全局估计的水下偏振成像算法[J].光学学报,2020,40(21): 2111002.  
Feng F, Wu G J, Wu Y F, et al. Algorithm for underwater polarization imaging based on global estimation[J]. Acta Optica Sinica, 2020, 40(21): 2111002.
- [11] 刘飞,孙少杰,韩平丽,等.基于稀疏低秩特性的水下非均匀光场偏振成像技术研究[J].物理学报,2021,70(16): 164201.  
Liu F, Sun S J, Han P L, et al. Clear underwater vision

- in non-uniform scattering field by low-rank-and-sparse-decomposition-based polarization imaging[J]. *Acta Physica Sinica*, 2021, 70(16): 164201.
- [12] 胡浩丰, 李嘉琦, 李校博, 等. 三自由度偏振差分水下成像技术[J]. *光学学报*, 2021, 41(3): 0329001.  
Hu H F, Li J Q, Li X B, et al. Underwater polarization difference imaging with three degrees of freedom[J]. *Acta Optica Sinica*, 2021, 41(3): 0329001.
- [13] Liang J, Ju H J, Ren L Y, et al. Generalized polarimetric dehazing method based on low-pass filtering in frequency domain[J]. *Sensors*, 2020, 20(6): 1729.
- [14] Li D, Yao A B, Chen Q F. PSConv: squeezing feature pyramid into one compact poly-scale convolutional layer [M]//Vedaldi A, Bischof H, Brox T, et al. *Computer Vision-ECCV 2020. Lecture notes in computer science*. Cham: Springer, 2020, 12366: 615-632.
- [15] Zhang J C, Shao J B, Luo H B, et al. Learning a convolutional demosaicing network for microgrid polarimeter imagery[J]. *Optics Letters*, 2018, 43(18): 4534-4537.
- [16] Hu H F, Zhang Y B, Li X B, et al. Polarimetric underwater image recovery via deep learning[J]. *Optics and Lasers in Engineering*, 2020, 133(23/24): 106152.
- [17] Cheng H Y, Chu J K, Chen Y T, et al. Polarization-based underwater image enhancement using the neural network of Mueller matrix images[J]. *Journal of Modern Optics*, 2022, 69(5): 264-271.
- [18] 幸琳, 赖晓涛, 王楠, 等. 混浊介质后向散射特性的 Mueller 矩阵实验测量[J]. *生物物理学报*, 2008, 24(1): 77-82.  
Xing C, Lai X T, Wang N, et al. Experimental research of Mueller matrix for backscattered property of turbid media[J]. *Acta Biophysica Sinica*, 2008, 24(1): 77-82.
- [19] 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.
- [20] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612.
- [21] Huynh-Thu Q, Ghanbari M. Scope of validity of PSNR in image/video quality assessment[J]. *Electronics Letters*, 2008, 44(13): 800-801.