

基于稠密级联卷积神经网络的水下图像增强

陈清江, 解亚丽*

西安建筑科技大学理学院, 陕西 西安 710055

摘要 为了解决水下退化图像出现的色彩偏差等问题, 提出一种基于稠密级联卷积神经网络的水下图像增强算法。首先将退化的水下图像从传统的红、绿、蓝(RGB)颜色空间转换到色调、饱和度、亮度(HSV)颜色空间, 保持色调分量和亮度分量不变, 利用级联卷积神经网络对饱和度分量增强。然后在特征提取网络编解码过程中引入了新的稠密块。稠密块将残差连接、跳跃连接和多尺度卷积结合起来, 纠正颜色失真。纹理细化网络是利用了 6 个纹理细化单元对所得到的细化图像进一步提取特征信息。最后将通过级联卷积神经网络进行提取的 S 通道图与 H、V 通道图进行合并, 得到增强的水下图像。实验结果表明, 提出算法增强的水下图像的水下彩色图像质量评价平均可达到 0.616875, 水下图像质量测量平均可达到 5.197000。对比算法表明, 提出的水下图像增强算法不仅增强效果良好, 且增强的结果更符合人类视觉习惯。

关键词 机器视觉; 水下图像; 卷积神经网络; 编解码框架; 计算机视觉; 稠密块

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP202259.2215004

Underwater Image Enhancement Based on Dense Cascaded Convolutional Neural Network

Chen Qingjiang, Xie Yali*

School of Science, Xi'an University of Architecture and Technology, Xi'an 710055, Shaanxi, China

Abstract To solve the low contrast problem of underwater degraded images, an underwater image enhancement algorithm based on a deep cascaded convolutional neural network is proposed. First, the degraded underwater image is converted from traditional red, green, and blue to hue, saturation, and value color space, which retains the hue and lightness component without changes, and the cascaded convolutional neural network is employed to examine the saturation component improvement. New dense blocks are introduced in the process of feature extraction network encoding and decoding. The dense block combines residual connection, skip connection, and multiscale convolution to correct color distortion. The texture refinement network employs six texture refinement units to extract feature information from the refined image. Finally, the S-channel image is extracted using the cascaded convolutional neural network, which is combined with the H- and V-channel images to achieve an improved underwater image. The experimental findings reveal that the average underwater color image quality estimation of underwater images improved using the proposed algorithm can reach 0.616875, and the average underwater image quality measurement can reach 5.197000. The comparison algorithm findings reveal that the proposed underwater image enhancement algorithm not only has a good improvement effect but also ensures the improved images are in line with human vision.

Key words machine vision; underwater image; convolutional neural network; coding and decoding framework; computer vision; dense block

1 引言

近年来, 由于科技进步以及人类对自然探索的好奇心, 水下成像技术在深海探测、水下机器人、海洋生

物监测等方面发挥了重要作用。但是, 光在水下会发生吸收和散射现象^[1], 从而会严重降低获取的水下图像质量, 所以很少有可以满足人们需要的清晰的水下图像。因此, 获得高质量的水下图像对于水下摄影、海

收稿日期: 2021-07-26; 修回日期: 2021-10-08; 录用日期: 2021-10-13

基金项目: 国家自然科学基金(61403298)、陕西省自然科学基金(2015JM1024)、陕西省教育厅专项科研计划项目(2013JK0586)

通信作者: *2696453994@qq.com

洋工程师^[2]、水下考古^[3]和水下机器人发射^[4]都具有重要意义。

人们为了提高单幅水下图像的质量而研究了各种各样的图像增强、图像复原和深度学习的方法。Ancuti等^[5]基于一些常用传统图像增强算法直接处理水下图像像素值。例如限制对比度自适应图像增强算法^[6](CLAHE)以增强特定的图像特征。水下暗通道先验(UDCP)是由Dreus等^[7]提出的另外一种用于水下图像增强的方法。这几种方法在某些程度上的确提高了水下图像的视觉质量,但仍存在伪影、增强过度、颜色偏差等问题。而基于图像复原的方法^[8-9]利用物理成像模型和图像先验信息作为约束条件来恢复清晰图像。Henke等^[10]提出了一种基于特征的颜色常量算法来修复水下图像的颜色失真。Ancuti等^[11]提出了一种基于图像融合(FE)的方法来提高水下图像质量。然而,这些方法在水下图像恢复中仍然存在局限性。深度卷积神经网络由于具有非常强大的监督学习模型,是近年来非常流行的用于图像处理的算法,因此一些学者将深度学习应用于水下图像处理^[12-15]。Zhu等^[16]提出了用CycleGAN来进行水下图像增强。Guo等^[17]提出一种基于弱监督的颜色转换的水下图像颜色修复(WSTCT)来增强水下图像。

由于深度卷积神经网络经常被用于目标识别^[18]和图像去雾^[19]中,并且在已知的水下物理成像模型的基础上,受Wang等^[20]提出的平行卷积神经网络增强水下图像、Chen等^[21]提出的级联残差生成对抗网络和林森等^[22]提出的网络输入的启发,本文提出了一种具有两部分网络的稠密级联卷积神经网络模型,并结合训练数据集对其进行了训练。所提出的网络可以进行更精确的特征提取以提升水下图像的质量。该网络的主要特点有:1)以编码解码为基本框架,受U形结构网络^[23]的启发,在U形结构网络中加入了稠密块,每个稠密块都有3个特征映射,以充分利用图像的局部特征,卷积和反卷积用于创建网络来学习同一图像的不同特征,6个特征细化单元用于进一步提取特征。通过像素级融合,获得清楚图像;2)在编解码框架中加入残差连接^[24],实验证明其结构能更有效地学习细节特征;3)构建了端到端的清晰水下图像,这些图像没有依赖任何水下图像模型和先验知识,具有更强的适用性。通过主观和客观的评估,表明与其他算法相比,该网络算法对增强不同类型的水下图像具有良好的效果。

2 基本原理

2.1 编码解码

自动编码器(AE)是一种用于函数提取和降维的特殊神经网络。最简单的AE由隐藏层和输出层组成。在训练期间,映射对输入向量进行编码,以获得编码向量。解密代码矢量映射并检索新创建的矢量。图1是一个AE的例子。




图1 AE示例

Fig. 1 Example of autoencoder (AE)

2.2 卷积和反卷积

卷积层是由一系列卷积滤波器组成,每个卷积层的输出如下式所示:

$$f^{l+1} = \text{ReLU}(f^l * k^{l+1} + b^{l+1}), \quad (1)$$

式中: f^l 和 f^{l+1} 分别代表第 l 层和第 $l+1$ 层对应的特征图; k^{l+1} 为卷积核的大小; b^{l+1} 为偏置;ReLU是非线性激活函数。卷积层输出的特征图大小计算公式为

$$\begin{cases} w_{\text{out}} = \frac{w_{\text{in}} + 2 * \rho + k}{s} + 1 \\ h_{\text{out}} = \frac{h_{\text{in}} + 2 * \rho + k}{s} + 1 \end{cases}, \quad (2)$$

式中: w_{out} 和 h_{out} 分别对应输出特征图的宽和高; w_{in} 和 h_{in} 分别对应输入特征图的宽和高; k 为卷积核的大小; ρ 为填充方式; s 为卷积核步长。

反卷积(Deconvolution)的本质还是卷积,只是在进行卷积之前,会进行一个自动的padding补充,从而使得输出的矩阵和指定输出的矩阵的形状相同。因此,在编码部分的卷积运算过程中丢失的细节特征,会通过解码部分的反卷积运算来恢复。反卷积层的过程可以表示为

$$G_i(Y) = \sigma[W_i * G_{i-1}(Y) + B], \quad (3)$$

式中: $G_i(Y)$ 为第 i 层反卷积层的输出; W_i 为反卷积层的权重参数; $G_{i-1}(Y)$ 为第 $i-1$ 层卷积层的输出特征图。因此,该层输出图像块的大小可以表示为

$$o = s(I - 1) + R - 2\rho, \quad (4)$$

式中: I 为输出的反卷积层图像的大小; R 为反卷积核的大小; s 为步长; ρ 为零填充。

3 提出的稠密级联卷积神经网络算法

经统计实验发现水下图像的色偏色弱主要分布在色调、饱和度、亮度(HSV)空间的饱和度分量,单独改变饱和度分量不影响整体图像的细节信息,于是本文提出保持亮度分量与色调分量不变,将饱和度分量通过稠密级联卷积网络进行增强。稠密级联卷积网络分为两部分:特征提取网络和纹理细化网络。特征提取网络采用编码解码结构,并且由文献^[25]可得,稠密

块设计的原则是加强特征传播和鼓励特征重用,因此本文在编解码框架中引入了具备这两个原则的新的稠密块,它的目的是找出网络中最优的局部稀疏结构,从而可以有效地纠正颜色偏差,恢复图像细节。整个编解码结构通过卷积层滤除噪声,利用反卷积层恢复丢失的细节并且逐像素细化图像。纹理细化网络是为减少伪影和细节模糊,添加了6个纹理细化单元对第一部分得到的细化图像进行进一步的纹理特征提取。在卷积运算之前应用非线性激活函数 ReLU 可以使像素点更集中于某个区域,减少过拟合现象,从而有效地恢复水下图像更多的特征信息。在本文网络的最后一步,将这6个纹理细化单元得到的特征图进行融合。

3.1 特征提取网络

编解码器网络中的卷积层和反卷积层是对称的。卷积层过滤噪声并存储水下图像中的重要细节部分,但卷积层无法恢复低质量图像。因此,在降噪后引入

反卷积层以细化特征,并在卷积层和反卷积层加入残差连接,使低层次特征在反卷积过程中得到保护。网络结构见图2。在本文的编码解码过程中,为了能够充分利用图像的局部特征,每一个卷积后都添加了一个稠密块,稠密块的详细结构见图3。该稠密块充分利用图像的局部信息,可以恢复图像细节,纠正颜色失真。每个稠密块在最右边利用1*1卷积以便直接连接来自上一层卷积的输出。而中间两个特征映射分别采取3*3,5*5的卷积用来提取不同的特征信息,在稠密块的最后一层,利用1*1的卷积来促进特征融合,提高计算效率。在这一部分网络中,所有的卷积步长为1,填充方式为零填充,正则化采取L₂正则化且系数为0.001,且在每一个卷积操作后都添加了一层批量规范化(BN)层,采用的激活函数是非线性ReLU函数。采取正则化是为了防止出现过拟合现象。每个卷积层下面的数字代表这一层的每一个卷积的个数。

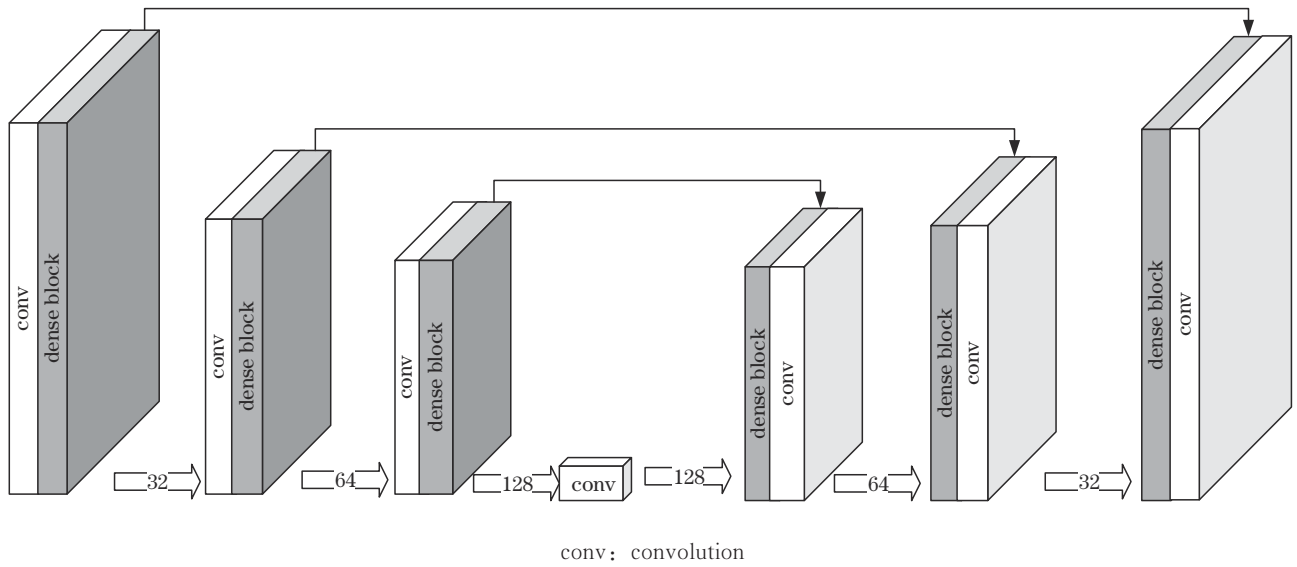


图2 特征提取网络

Fig. 2 Feature extraction network

3.2 纹理细化网络

为减少伪影和细节模糊,加入6个纹理细化单元进行纹理特征提取,并且每个纹理细化单元结构相同。同特征提取网络一样,所有的卷积核大小均是3*3,步长为1,填充方式为零填充,正则化采取L₂正则化且系数为0.001,并且在每一个卷积操作后都添加了一层BN层,采用的激活函数是非线性ReLU函数。图4(a)表示纹理细化网络,图4(b)表示纹理细化单元。

3.3 损失函数

为了训练神经网络中的参数以L₁,L₂和像素损失函数的线性表示作为整个网络的损失函数。L₁损失函数和L₂损失函数是两个常用的函数。L₁损失函数也被叫做最小化绝对误差(MAE)。MAE就是最小化真实的清晰图像y_{true}和预测的增强图像y_{pred}之间差值的绝对值的和,L₁损失函数表达式为

$$L_1 = \sum |y_{true} - y_{pred}| \quad (5)$$

L₂损失函数也被叫做最小化平方误差(MSE)。MSE就是最小化真实的清晰图像y_{true}和预测的增强图像y_{pred}之间差值的平方的和,L₂损失函数表达式为

$$L_2 = \sum (y_{true} - y_{pred})^2 \quad (6)$$

像素损失L_w是指将一个输入图像进行增强后得到的图像与清晰的地面图像做差,然后取一范数,用数学公式表示为

$$L_w = \sum \|y_{true} - y_{pred}\|_1 \quad (7)$$

而本文为了更好地加快网络的收敛速度以及图像增强的质量,采取了L₁损失函数、L₂损失函数和像素损失L_w的线性相关的函数作为本文整体网络的损失函数,即

$$L = \alpha_1 L_1 + \alpha_2 L_2 + \alpha_3 L_w \quad (8)$$

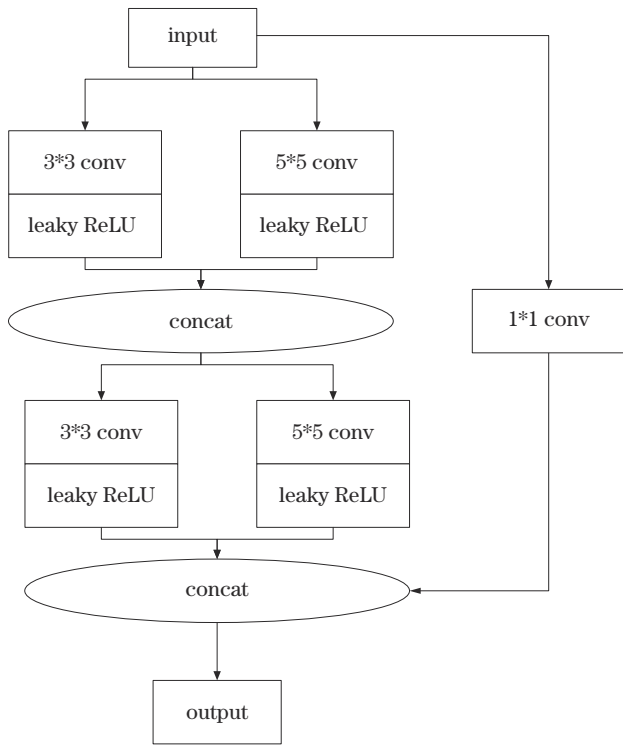


图 3 稠密块结构

Fig. 3 Dense block structure

式(8)是本文整体网络的损失函数,其中 L 是本文网络的整体损失函数, α_1 、 α_2 和 α_3 根据网络训练所得,根据

实验结果, α_1 、 α_2 和 α_3 分别为 2、0.7 和 1。

4 实验结果与分析

本节描述了实验集的来源,实验参数设置和实验步骤,并且为验证本文算法的鲁棒性和有效性,将本文算法与其他典型算法(包括基于深度学习的算法和传统算法)进行实验对比,将提出的用于水下图像增强的稠密级联卷积神经网络与其他几种水下图像增强方法进行了比较。比较的方法有 CLAHE^[6]、UDCP^[7]、FE^[11]、CycleGAN^[16]和 WSCT^[17]。然后从主观评价和客观评价两方面对处理图进行对比分析,证明本文算法在水下图像增强方面具有很强的实用性。最后为了说明本文模型设计的有效性,还对不同的网络模型进行了对比实验分析。

4.1 数据集

本文所使用的数据集来自 UIEB dataset^[26]。并且挑选其中的 740 幅真实的退化水下图像。对其运用 7:3 的比例划分成训练集与测试集,再将划分好的训练集和测试集中的图像进行 90°和 270°的翻转,以此来扩充训练集和测试集。最后,在实验对比图中,挑选出 8 张水下拍摄常见的场景,例如水下考古与珊瑚群簇进行对比。图 5 展示了退化的水下图像、退化的水下图像对应的清晰水下图像、退化水下图像对应的 HSV 颜色空间图像及其各分量图像。

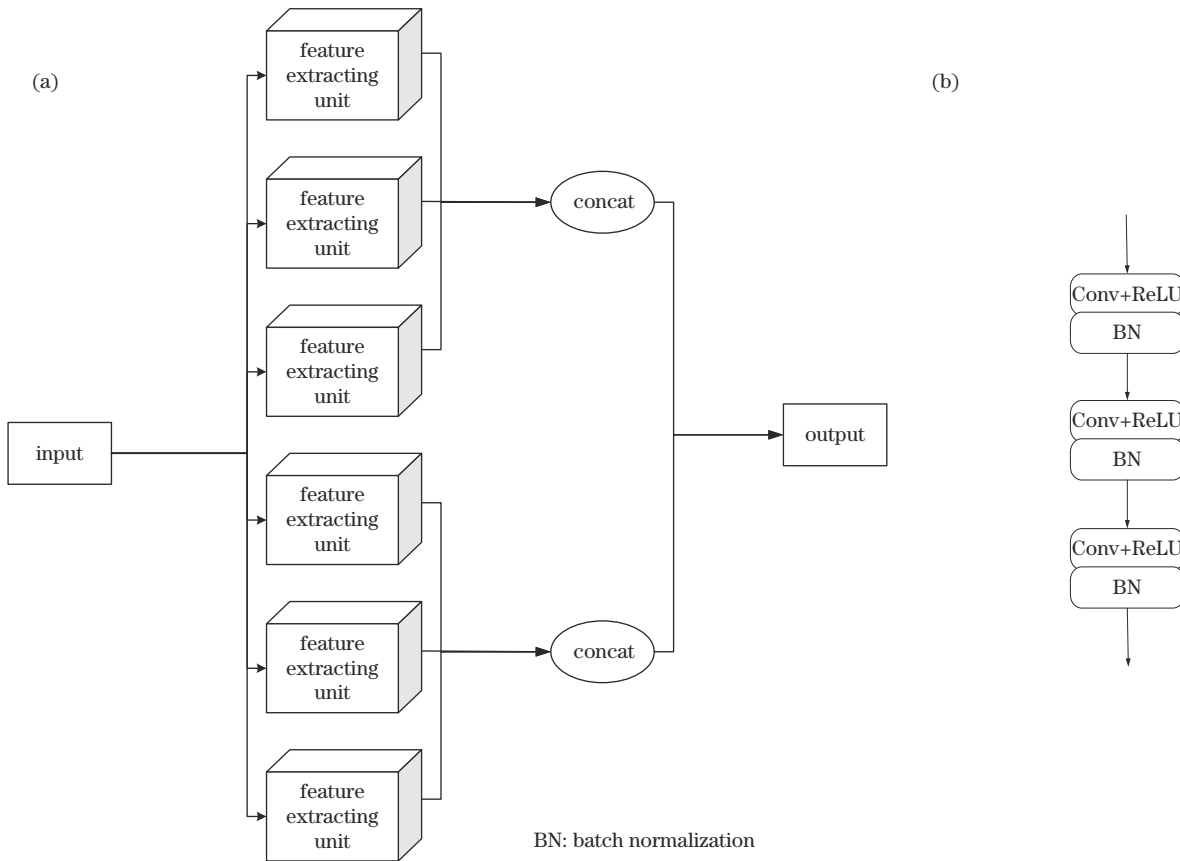


图 4 纹理细化结构。(a) 纹理细化网络;(b) 纹理细化单元

Fig. 4 Structure of texture refinement. (a) Texture refinement network; (b) texture refinement unit

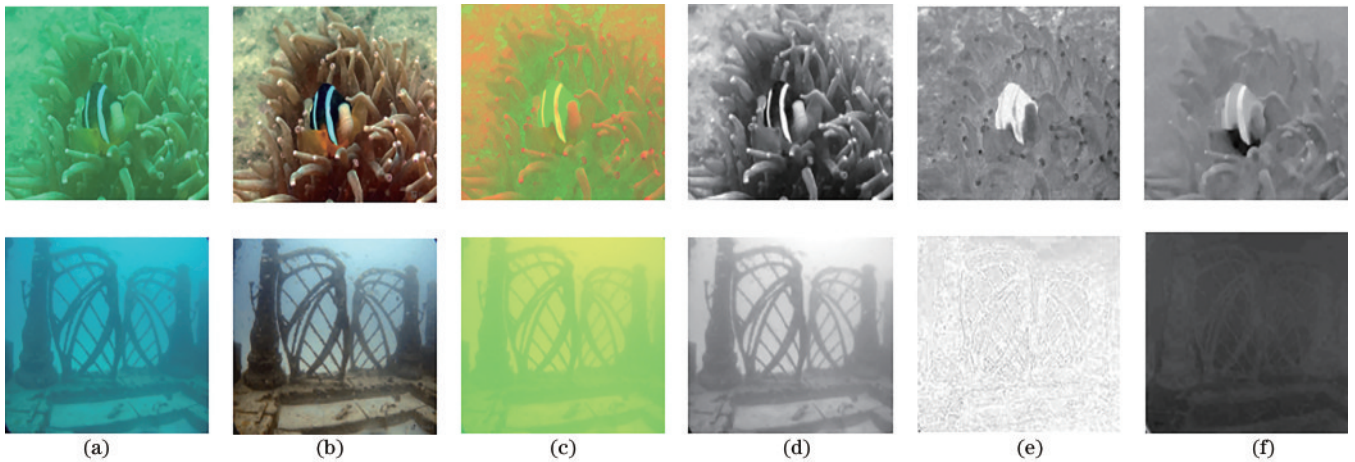


图 5 退化的水下图像、退化的水下图像对应的清晰水下图像和退化的水下图像对应的 HSV 颜色空间图像及其各分量图像。(a)退化的 coral 和 whale skeleton 和 (b) 分别对应的清晰水下图像、(c) 分别对应的 HSV 颜色空间图像、(d) 分别对应的 H 分量图像、(e) 分别对应的 S 分量图像和 (f) 分别对应的 V 分量图像

Fig. 5 Degraded underwater image, clear underwater image corresponding to degraded underwater image, HSV color space image corresponding to degraded underwater image and its component images. (a) Degraded images, (b) corresponding clear underwater images, (c) corresponding HSV color space images, (d) corresponding H component images, (e) corresponding S component images, and (f) corresponding V component images of coral and whale skeleton

4.2 实验条件、参数设置及实验步骤

实验条件: 本文采用 Tensorflow2.1 深度学习框架进行训练和测试, 所使用的计算机硬件配置如下: GPU 为 Nvidia GeForce 1660Ti (6 GB)。CPU 为 Intel Core i7-15750H, 内存为 16 GB, 主频为 2.40 GHz。

参数设置: 本文网络中所有的输入都是长和宽为 256 的 RGB 图像, 优化器为 Adam, 学习率为 0.0001, 批量大小 (batchsize) 为 1, 迭代次数 (epoch) 为 3000。

实验步骤: 1) 获取水下图像数据集; 2) 将水下图像数据集的 RGB 图像转化为 HSV 颜色空间各分量的图像; 3) 对水下图像的饱和度 (S) 分量图像, 通过稠密级联卷积神经网络模型进行训练与测试; 4) 将 HSV 颜色空间中饱和度 (S) 分量增强后的图像与其余两个分量的图像合并, 并转换到 RGB 图像, 以此获得增强后的水下图像; 5) 分析模型对比实验的增强结果。

所提算法流程如图 6 所示。

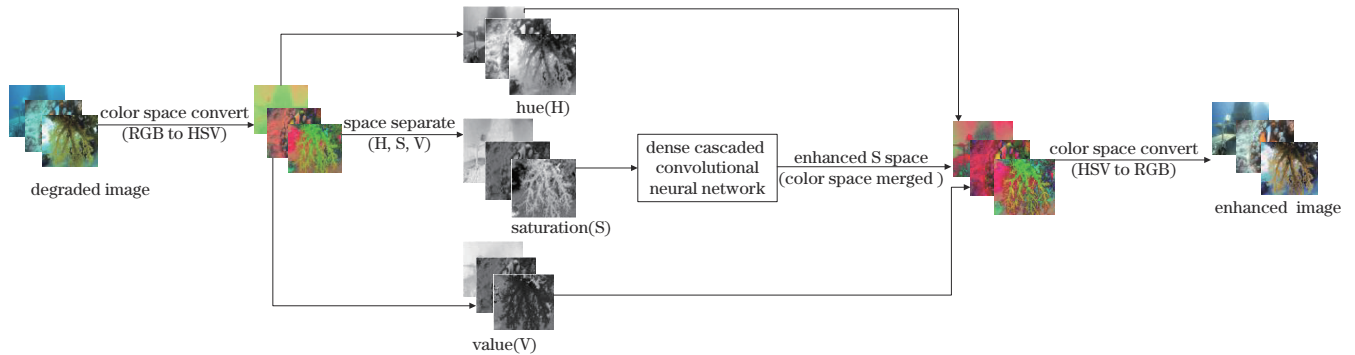


图 6 提出算法流程图

Fig. 6 Flow chart of proposed algorithm

4.3 主观评价

从实验对比图 7 可以看出, CLAHE 算法^[6]对恢复水下退化图像色偏方面效果很差, 如 Image1 和 Image2, 对颜色校正的处理基本无效果。UDCP 算法^[7]在处理色偏问题上, 由于没有进行矫正处理, 导致处理后的水下图像仍然呈现出严重的绿色, 甚至整体画面偏暗红。WSCT 算法^[17]处理之后整体偏绿, 细节纹理特征比较清晰。FE^[11]和 CycleGAN 算法^[16]的去雾效果良好, 但是 FE 算法^[11]出现了局部泛白的情况,

如 Image1 和 Image5, 而 CycleGAN 算法^[17]颜色恢复效果比较差, 导致细节恢复不清晰, 如 Image1 和 Image2。

实验对比图 7 中方框部分表明, 针对出现色偏的水下图像 (类似 Image 2), WSCT 算法^[17]在局部出现泛白, UDCP 算法^[7]呈现出整体偏绿的情况; 针对出现光斑的水下图像 (类似 Image4), WSCT 算法^[17]出现过拟合导致的黑斑, UDCP 算法^[7]过分增强, FE 算法^[11]出现了增强过度的颜色失真现象; 而在有雾问题的水

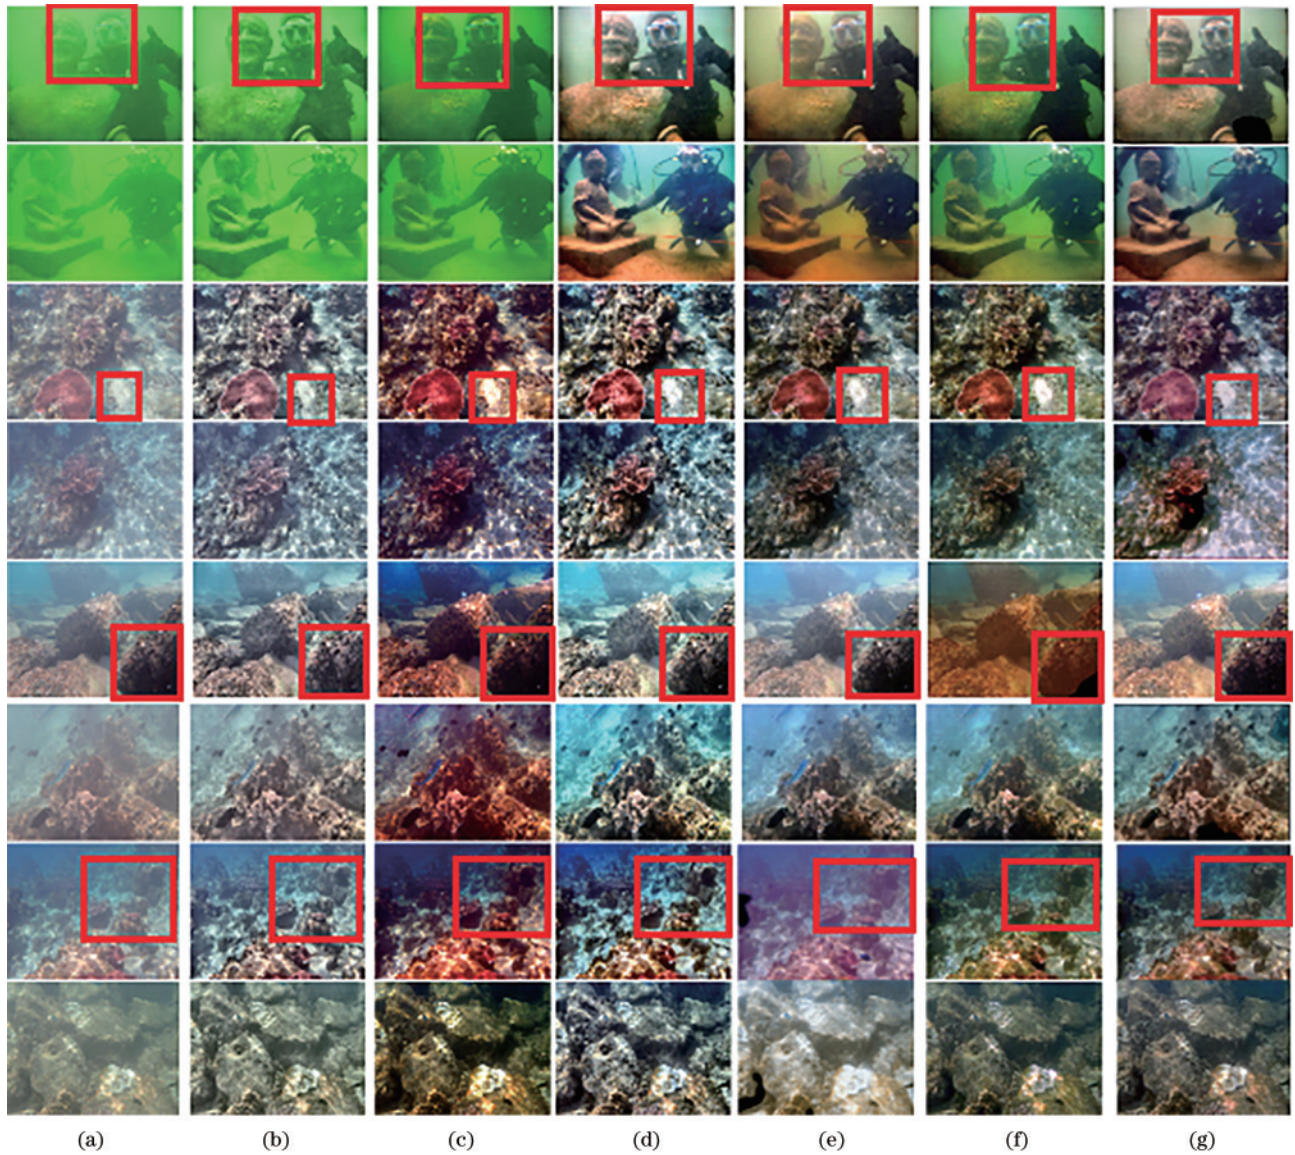


图 7 各算法实验结果图。(a)原始图;(b) CLAHE;(c) UDCP;(d) FE;(e) CycleGAN;(f) WSCT;(g)提出算法
Fig. 7 Experimental results of different algorithms. (a) Original images; (b) CLAHE; (c) UDCP; (d) FE; (e) CycleGAN; (f) WSCT;
(g) proposed algorithm

下图像(类似 Image6),CLAHE算法^[6]出现了增强过度的颜色失真现象,CycleGAN算法^[16]和 WSCT 算法^[17]颜色恢复不清晰。

经过对比分析,本文提出算法在颜色信息校正(如 Image1 和 Image2)、弱化光斑(Image3 和 Image4)和去雾(如 Image5 和 Image6)方面更具有优势。说明提出算法更具有实用性。

4.4 客观评价

在本文网络中选择了水下彩色图像质量评价(UCIQE)^[27]和水下图像质量测量(UIQM)^[28]来评价增强后的图像。UCIQE 利用色度、饱和度和对比度的线性组合,分别量化不均匀的颜色投射、模糊和低对比度。UIQM 包括水下图像色度测量(UICM)、水下图像清晰度测量(UISM)和 underwater 图像对比度测量(UICoM)3 个方面。UCIQE 和 UIQM 的值越高表示

图像质量越好。UIQM 与 UICM、UISM 和 UICoM 线性相关关系为

$$U = \sigma_1 C + \sigma_2 S + \sigma_3 M, \quad (9)$$

式中: U 是 UIQM; C 是 UICM; S 是 UISM; M 是 UICoM; $\sigma_1, \sigma_2, \sigma_3$ 是从网络训练所得出来的系数。经过实验, σ_1, σ_2 和 σ_3 分别为 0.0281、0.2953 和 3.5753。表 1 和表 2 详细列出了提出方法和其他几种算法所得结果的 UCIQE 和 UIQM。

在表 1 和表 2 中,UCIQE 和 UIQM 度量的最佳结果以黑粗体标记。由于 FE^[11]有明显的过度增强现象,所以导致平均 UCIQE 值降低从而排名第 2。CycleGAN^[16]虽然经过 50000 次迭代训练,但因为循环一致性损失不适合水下场景所以平均 UIQM 值排在第 4。WSCT^[17]增强算法是根据水下成像模型来预估参数所以平均 UIQM 值位于第 3,平均 UCIQE 值位于

表 1 提出方法和其他几种算法所得结果的 UCIQE 对比

Table 1 UICQE comparison of results of proposed method and several other algorithms

UCIQE	CLAHE	UDCP	FE	CycleGAN	WSCT	Proposed
Image1	0.438	0.480	0.594	0.620	0.602	0.597
Image2	0.413	0.453	0.616	0.617	0.603	0.664
Image3	0.521	0.553	0.586	0.610	0.612	0.613
Image4	0.475	0.616	0.614	0.658	0.556	0.603
Image5	0.563	0.641	0.603	0.601	0.618	0.638
Image6	0.491	0.417	0.597	0.593	0.519	0.603
Image7	0.549	0.608	0.647	0.584	0.596	0.624
Image8	0.489	0.564	0.579	0.548	0.557	0.593
Average	0.492375	0.541500	0.604500	0.603875	0.582875	0.616875

表 2 提出方法和其他几种算法所得结果的 UIQM 对比

Table 2 UIQM comparison of results of proposed method and several other algorithms

UIQM	CLAHE	UDCP	FE	CycleGAN	WSCT	Proposed
Image1	1.423	1.248	4.315	4.306	3.237	4.953
Image2	0.481	0.855	4.183	3.794	2.900	4.385
Image3	5.560	5.574	5.490	5.555	5.658	5.960
Image4	4.809	4.139	5.250	4.166	4.902	4.921
Image5	4.914	4.554	4.496	4.210	4.708	5.297
Image6	4.959	4.973	4.393	4.366	4.421	5.015
Image7	4.783	4.982	4.962	4.925	4.858	5.307
Image8	5.131	4.903	5.399	5.209	5.153	5.738
Average	4.007500	3.903500	4.811000	4.566375	4.479625	5.197000

第 2。与其相比,本文提出算法的平均 UIQM 值大于其他算法,平均 UCIQE 值也大于大多数算法。

4.5 不同模型实验对比与结果分析

为了更好地验证本文提出算法中稠密块以及在 U 型结构中添加残差连接的实用性,对比本文提出的级联稠密卷积神经网络(即 model1),做了以下几个模型对比实验:

- 1) 未加入稠密块的卷积神经网络(model2);
- 2) 具有 4 个稠密块的稠密卷积神经网络(model3);
- 3) 具有 8 个稠密块的稠密卷积神经网络(model4);
- 4) 在 U 型结构中去除掉残差连接的稠密卷积神经网络(model5)。

model2、model3、model4、model5 的具体模型如图 8 所示。不同模型对同一幅水下图像增强后的结果如图 9 所示。在图 9 中,未添加稠密块的 model2 对色偏几乎没有增强效果,而增加了稠密块的本文网络模型(model1)很好地解决了色偏问题;图 9 也表明在增强细节信息方面,在 U 型结构中添加残差连接的模型要比未添加残差连接的模型(model5)表现更加良好。表 3 也展示了不同模型的针对同一幅水下图像

表 3 提出模型和其他几种模型所得结果的客观评价指标对比
Table 3 Subjective evaluation index comparison of results of proposed model and several other models

Evaluation index	UCIQE	UIQM	Time /s
Model1	0.5861	5.2145	0.53
Model2	0.4927	4.8713	0.49
Model3	0.5146	4.9857	0.51
Model4	0.6027	5.3064	0.60
Model5	0.5061	5.0149	0.52

Shipwreck 的客观评价指标。

从表 3 可以看出,本文提出的稠密卷积神经网络(model1)由于具有新添加的稠密块,在主观上可以消除色彩偏差和对比度低等问题,在客观指标上都优于 model2 和 model3,说明具有稠密块的级联卷积神经网络能更好地获得符合人类视觉习惯的清晰水下图像。

在图 10 中,添加了 8 个稠密块的神经网络(model4)虽然在客观指标上表现更好,但是从表 3 中的运行时间来看,会因为引入更多参数而增加训练时间。因此,综合训练时间来考虑,本文提出网络使用 6 个稠密块,即 model1 作为最终版本。




图 8 不同模型示意图。(a) model2; (b) model3; (c) model4; (d) model5

Fig. 8 Diagram of different models. (a) model2; (b) model3; (c) model4; (d) model5




图 9 不同模型的实验结果。(a) model2 结果;(b) model3 结果;(c) model4 结果;(d) model5 结果;(e) 提出模型结果
 Fig. 9 Different model's results. (a) model2's result; (b) model3's result; (c) model4's result; (d) model5's result;
 (e) proposed model's result

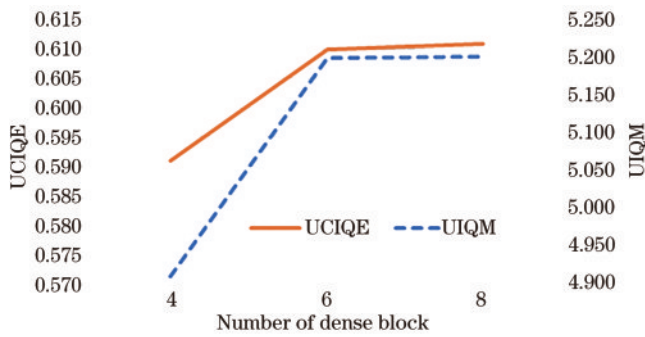


图 10 不同稠密块个数的客观评价指标

Fig. 10 Objective evaluation indicators for different number of dense blocks

5 结 论

针对水下图像颜色失真、雾化和低对比度等问题,设计了基于稠密级联卷积神经网络的水下图像增强算法。该神经网络的输入主要是退化的水下图像 HSV 分量中的饱和度分量。在稠密级联卷积神经网络中,采用编解码框架,并且提出了一个新的稠密块,有效地修正色差,提高饱和度。同时,采用 6 个纹理细化单元进一步细化特征,增强网络学习能力。实验结果表明,相比于对比算法,所提出的稠密级联卷积神经网络在不同情况的水下环境中,UCIQE 和 UIQM 这两个指标

分别可以达到 0.616875 和 5.197000,说明提出的方法具有实用性。但该方法在某些场景的水下图像增强中会出现过度增强现象,所以未来拟考虑把传统的水下图像增强方法与基于深度学习的水下图像增强的方法结合起来,进一步提高水下图像增强的质量。

参 考 文 献

- [1] Mobley C D. Light and water: radiative transfer in natural waters[M]. New York: Academic Press, 1994.
- [2] 钱立进, 金海红, 范之国, 等. 抑制视场光源干扰的水下图像复原方法研究[J]. 光学学报, 2021, 41(18): 1801001. Qian L J, Jin H H, Fan Z G, et al. Underwater image restoration method suppressing interference of light source in field of view[J]. Acta Optica Sinica, 2021, 41(18): 1801001.
- [3] Johnson-Roberson M, Bryson M, Friedman A, et al. High-resolution underwater robotic vision-based mapping and three-dimensional reconstruction for archaeology[J]. Journal of Field Robotics, 2017, 34(4): 625-643.
- [4] 宋杰. 无人水下发射试验设施方案设计构想[J]. 水下无人系统学报, 2020, 28(2): 220-224. Song J. Design ideas of unmanned underwater launch test facility[J]. Journal of Unmanned Undersea Systems, 2020, 28(2): 220-224.
- [5] Ancuti C O, Ancuti C, de Vleeschouwer C, et al. Color balance and fusion for underwater image enhancement[J].

- IEEE Transactions on Image Processing, 2018, 27(1): 379-393.
- [6] Reza A M. Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement[J]. The Journal of VLSI Signal Processing-Systems for Signal, Image, and Video Technology, 2004, 38(1): 35-44.
- [7] Drews P L J, Jr, Nascimento E R, Botelho S S C, et al. Underwater depth estimation and image restoration based on single images[J]. IEEE Computer Graphics and Applications, 2016, 36(2): 24-35.
- [8] Li C Y, Guo J C, Cong R M, et al. Underwater image enhancement by dehazing with minimum information loss and histogram distribution prior[J]. IEEE Transactions on Image Processing, 2016, 25(12): 5664-5677.
- [9] Menaker D, Treibitz T, Avidan S. Color restoration of underwater images[C]//Proceedings of the British Machine Vision Conference 2017, September 4-7, London, UK. London: British Machine Vision Association, 2017.
- [10] Henke B, Vahl M, Zhou Z L. Removing color cast of underwater images through non-constant color constancy hypothesis[C]//2013 8th International Symposium on Image and Signal Processing and Analysis (ISPA), September 4-6, 2013, Trieste, Italy. New York: IEEE Press, 2013: 20-24.
- [11] Ancuti C, Ancuti C O, Haber T, et al. Enhancing underwater images and videos by fusion[C]//2012 IEEE Conference on Computer Vision and Pattern Recognition, June 16-21, 2012, Providence, RI, USA. New York: IEEE Press, 2012: 81-88.
- [12] 王越, 王德兴, 袁红春, 等. 基于金字塔注意力机制和生成对抗网络的水下图像增强[J]. 激光与光电子学进展, 2021, 58(16): 1610006.
- Wang Y, Wang D X, Yuan H C, et al. Underwater image enhancement based on pyramid attention mechanism and generative adversarial network[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1610006.
- [13] Massot-Campos M, Oliver-Codina G. Underwater laser-based structured light system for one-shot 3D reconstruction[C]//SENSORS, 2014 IEEE, November 2-5, 2014, Valencia, Spain. New York: IEEE Press, 2014: 1138-1141.
- [14] Hossain M A, Karmaker A, Alam M S. A low latency MAC protocol with reduced handshaking for provisioning spatial fairness in underwater sensor network[J]. International Journal of Wireless Information Networks, 2021, 28(2): 147-161.
- [15] 封斐, 吴国俊, 吴亚风, 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.
- [16] Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//2017 IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2242-2251.
- [17] Li C Y, Guo J C, Guo C L. Emerging from water: underwater image color correction based on weakly supervised color transfer[J]. IEEE Signal Processing Letters, 2018, 25(3): 323-327.
- [18] 杨其利, 周炳红, 郑伟, 等. 注意力卷积长短时记忆网络的弱小目标轨迹检测[J]. 光学精密工程, 2020, 28(11): 2535-2548.
- Yang Q L, Zhou B H, Zheng W, et al. Trajectory detection of small targets based on convolutional long short-term memory with attention mechanisms[J]. Optics and Precision Engineering, 2020, 28(11): 2535-2548.
- [19] 杨燕, 刘珑珑, 张得欣, 等. 结合自适应雾气估计的快速单幅图像去雾[J]. 光学精密工程, 2019, 27(10): 2263-2271.
- Yang Y, Liu L L, Zhang D X, et al. Fast single image dehazing combined with adaptive haze estimation[J]. Optics and Precision Engineering, 2019, 27(10): 2263-2271.
- [20] Wang K Y, Hu Y, Chen J, et al. Underwater image restoration based on a parallel convolutional neural network[J]. Remote Sensing, 2019, 11(13): 1591.
- [21] 陈清江, 张雪. 混合残差学习与导向滤波算法在图像去雾中的应用[J]. 光学精密工程, 2019, 27(12): 2702-2712.
- Chen Q J, Zhang X. Application of hybrid residual learning and guided filtering algorithm in image defogging [J]. Optics and Precision Engineering, 2019, 27(12): 2702-2712.
- [22] 林森, 刘世本. 基于多尺度生成对抗网络的水下图像增强[J]. 激光与光电子学进展, 2021, 58(16): 1610017.
- Lin S, Liu S B. Underwater image enhancement based on multiscale generative adversarial network[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1610017.
- [23] Laina I, Rupprecht C, Belagiannis V, et al. Deeper depth prediction with fully convolutional residual networks[C]//2016 Fourth International Conference on 3D Vision (3DV), October 25-28, 2016, Stanford, CA, USA. New York: IEEE Press, 2016: 239-248.
- [24] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [25] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [26] Li C, Guo C, Ren W, et al. An underwater image enhancement benchmark dataset and beyond[J]. IEEE Transactions on Image Processing, 2019, 29: 4376-4389.
- [27] Guo Y C, Li H Y, Zhuang P X. Underwater image enhancement using a multiscale dense generative adversarial network[J]. IEEE Journal of Oceanic Engineering, 2020, 45(3): 862-870.
- [28] Wu D, Yuan F, Cheng E. Underwater no-reference image quality assessment for display module of ROV[J]. Scientific Programming, 2020, 2020: 8856640.