

基于改进残差网络的水下图像重建方法

宋娅菲 谌雨章 沈君凤 曾张帆

湖北大学计算机与信息工程学院 武汉 430062

(1012677264@qq.com)

摘要 自然水体成像中湍流及悬浮颗粒等环境因素会造成水下采集的图像存在扭曲失真、分辨率低、背景模糊等问题,为了解决上述问题并进一步提高图像重建和复原的质量,提出了一种改进的基于残差网络的图像超分辨率重建方法,该方法将网络中的残差密集块和自适应机制进行融合,有效解决深度学习网络中经常遇到的梯度爆炸问题,同时能够抑制无用信息的学习,充分利用重要特征信息。为了使网络适应水下噪声环境,通过自建水下系统对目标板分别在清水中和浑浊微湍流水域中进行采集并对其进行图像配对生成训练对,并在河流和海洋水域下采集图像生成测试集。实验结果表明,在微湍流的海洋水域和河流水域中,较传统的水下图像处理和神经网络算法,使用改进的残差网络算法能够很好地对水下图像进行重建,重建图像的边缘信息得到了极大的保留,图像的重建效果更好。

关键词:残差网络;深度学习;超分辨率重建;自适应机制;水下图像处理

中图法分类号 TN911.73;TP183

Underwater Image Reconstruction Based on Improved Residual Network

SONG Ya-fei, CHEN Yu-zhang, SHEN Jun-feng and ZENG Zhang-fan

School of Computer Science and Information Engineering, Hubei University, Wuhan 430062, China

Abstract Natural environment factors such as turbulence and suspended particles in water imaging can cause image distortion, low resolution, and fuzzy background of underwater acquisition. In order to solve the above problems and further improve the quality of image reconstruction and rehabilitation, this paper puts forward an improved image super-resolution reconstruction based on residual network method. This method will in residual dense network of fusion and adaptive mechanism, effectively solve the deep learning gradient explosion problems often encountered in network, also can inhibit learning of useless information, make full use of the important feature information. In order to adapt the network to the underwater noise environment, a self-built underwater system is used to collect the target plate in clear water and turbid micro-turbulent waters respectively, and the training pair of image generation is performed on the target plate, and the test set of image generation is collected under rivers and ocean waters. The experimental results show that in the micro-turbulent ocean and river waters, compared with the traditional underwater image processing and neural network algorithm, the improved residual network algorithm can reconstruct the underwater image very well.

Keywords Residual network, Deep learning, Superresolution reconstruction, Adaptive mechanism, Underwater image processing

1 引言

随着陆地资源越来越缺乏,人们对海洋资源越来越重视,水下目标检测与识别技术越来越广泛地应用于海洋军事、深海生态系统等研究领域。但由于水体中存在大量的悬浮颗粒,在光的传播过程中对其造成色散与吸收作用,导致设备所采集到的水下图像存在对比度低、颜色失真、表面雾化、信息丢失等问题,人眼难以正确识别目标。由于水下环境复杂,有多种因素对图像成像质量造成影响,然而传统的水下图像增强算法无法综合考虑各方面影响^[1-2],因此,如何在水下图像可视性较差的情况下,找到一种快速、准确、有效的方法来对其进行增强和复原,已是水下图像处理领域中研究的重点。

目前为止,国内外学者对此已经进行了大量研究。Yang等^[3]、Huo等^[4]提出了基于暗通道的先验算法,分别引入颜色失真去除算法和自适应色彩校正参数算法来改善水下图像颜色失真、背景模糊等问题。Serikawa等^[5]提出了使用联合三边滤波器对图像进行去雾的算法,有效提高了图像的重建质量,减小了重建所需要的时间,但该算法没有考虑人工光源的影响。考虑到水下光学条件复杂,Lu等^[6]针对水下噪声提出了一种超分辨率重建算法,对噪声环境具有良好的鲁棒性。Nakagawa等^[7]针对水中含有的泥沙等物体提出一种基于kinect水下三维图像重建方法,重建后的深度图具有良好的精度。

基于各种数学模型和物理模型的水下图像复原算法需要进行复杂的公式推导和繁重的计算工作,并不智能,且对先验

基金项目:湖北省自然科学基金面上项目(2019CFB733);湖北省大学生创业训练计划基金资助项目(S201910512024,201710512051)

This work was supported by General program of Natural Science Foundation of Hubei Province(2019CFB733) and Student's Platform for Innovation and Entrepreneurship Training Program of Hubei Province (S201910512024,201710512051).

通信作者:谌雨章(hubueyz@foxmail.com)

知识具有依赖性^[8-9]。

近年来,深度学习算法的优越性在物体识别和分类等领域掀起了一股热潮,这些算法经过改进后同样可以进行图像复原和增强。Done等^[10]提出的基于卷积神经网络的单帧图像超分辨率重建算法(Image Super Resolution Using Convolutional Neural Network, SRCNN),解决了经典方法需要手工设计特征这一问题,实现了各层网络自动学习图像特征,提高了图像重建的精度,但其较浅的网络结构限制了对图像的重建能力。由文献^[11]可知,神经网络越深,网络性能越好,但过深的神经网络训练时容易出现梯度消失的现象。He等^[12]为了解决这一问题,提出了深度残差学习(Deep Residual Learning),将多个卷积层级联得到的输出和输入图像相加再用Relu函数进行激活,得到高分辨率图。Kim等^[13]和Lim等^[14]相继提出了VDSR和EDSR等算法,分别通过对残差网络引入梯度剪裁和删减BN层,使得图像复原效果更好。然而这些传统的深度学习算法都默认提取到的所有特征同样重要,无法抑制无用信息。为了加强对重要特征的学习,本文提

出了一种改进的残差网络,增强水下图像从低端到高端的映射关系,得到高分辨率的水下图像。

2 本文方法

2.1 图像超分辨率重建方法的整体结构

受到RDBNet^[15]和SENet^[16]的启发,我们提出了基于改进残差网络的水下图像重建方法。RDBNet中提出的残差密集块、局部特征融合和全局特征融合这3种结构不仅可以有效解决深度学习中的梯度弥散现象,还可以充分学习神经网络中的各层特征信息。然而,传统的卷积神经网络默认各个通道的权重相等即各特征重要性一样,对两种重要性不同的特征赋予相同的权重,大大降低了图像的重建效果,限制了算法的鲁棒性。因此,我们借鉴SENet结构,将文献^[16]提出的SEBlock进行改造,并融合进残差密集块网络,得到改进的残差网络。此网络不仅可以加深网络深度,还可以自适应学习图像特征,加快模型的收敛速度。

本文提出的改进基于残差的网络结构如图1所示。




图1 网络结构图

Fig.1 Network structure

用于学习图像信息的网络是图1的上半部分,该部分由四大模块构成:特征提取层、改进的残差网络、全局特征融合层、重建层。当输入水下图像时,网络会对它的特征信息进行捕捉和学习,重建得到图像的高频信息。图1的下半部分则是使用双三插值来获取图像的低频信息,将高频和低频特征进行融合得到最终的超分辨率重建图像。

为了有效获取图像的高频信息,本文引入GooleNet^[17]的思想,首先使用两个卷积层进行卷积操作来提取图像的浅层特征。第一个卷积层使用大小为 3×3 的卷积核,从LR中提取到的特征图中的特征信息可表示为:

$$X_i^j = f\left(\sum_{i \in M_j} X_i^{j-1} \times W_{i,j}^l + b_j^l\right) \quad (1)$$

其中, X 为特征图中像素点的值; l 为卷积层的层数; i 和 j 为像素点的位置; f 为神经网络采取的激活函数; M 为卷积核; W 和 b 分别为卷积核中的权值和常数偏置。为了方便叙述,我们将式(2)所得结果简化成:

$$F_{-1} = f_{C1}(I_{LR}) \quad (2)$$

其中, f_{C1} 表示卷积运算;对 F_{-1} 再次做卷积运算来进一步提取浅层特征得到 F_0 ,并将此结果作为低频信息部分进行全局残差学习。 F_0 可表示为:

$$F_0 = f_{C2}(F_{-1}) \quad (3)$$

其中, f_{C2} 为使用 1×1 卷积核对图像进行卷积运算,目的是降低特征图的维数,减小输入参数,降低后面残差网络的训练难度。卷积结果作为后续残差块网络的输入,进行局部特征提取,再使用局部特征融合自适应地从以前的和当前的局部特

征中学习更有效的特征。在充分获得稠密局部特征的基础上,将每个残差模块的输出结果进行全局特征融合,对全局层次特征进行整体学习和自适应学习,再引入全局跳跃链接将 F_0 与更新后的全局特征进行残差学习,充分利用输入图像的所有特征信息实现特征复用,有效减少网络冗余,最终所得到的特征图可表示为:

$$F_f = F_0 + F_{GFF}(F_1, \dots, F_n) \quad (4)$$

其中, F_{GFF} 为全局特征融合运算; F_1, \dots, F_n 为局部密集特征; F_f 是提取的低分辨率图像LR的局部和全局特征。

对于上采样部分,使用一个亚像素卷积层和一个卷积层进行重建,得到:

$$IHF = f_{recon}(f_{up}(F_f)) \quad (5)$$

其中, f_{recon} 和 f_{up} 分别为上采样运算和重建运算,为重建后所得到的输入图像的高频信息。

2.2 改进的残差网络

在上述方法提取密集特征时,我们使用的改进的残差网络结构如图2所示。




图2 改进的残差网络

Fig.2 Improved residual network

在特征提取过程中,所有子模块两两相连,网络每一个子模块的输入都是前面所有子模块的梯度信息,并且经过该层学习后的信息被传递给后面的模块继续学习,防止信息在卷积过程中丢失,以充分提取特征。每个子模块的具体结构如图3所示。




图3 改进的残差块

Fig. 3 Improved residual block

在子模块中,首先对输入到网络中的图像用 3×3 的卷积核进行卷积得到特征信息,然后进行全局平均池操作,把提取的信息聚合在一起生成一组具有全局感受野的特征图,计算公式如下:

$$Z_C = H_{AGP}(x_C) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_C(i, j) \quad (6)$$

其中, $H_{AGP}(\cdot)$ 为全局平均池操作; $x_C(i, j)$ 为 C 通道所提取的特征 x_C 所在位置 (i, j) 处的像素值。

根据文献[16],为了建立各通道间的依赖关系,经过全局平均池化操作后选用两个全连接层组成一个瓶颈结构,在减少计算量的同时增加了通道间的非线性关系,能够更高效、准确地反映各通道间复杂的关系性。对数据的具体运算可表示为:

$$k_C = \sigma(W_2 \delta(W_1 z_C)) \quad (7)$$

其中, $\delta(\cdot)$ 和 $\sigma(\cdot)$ 分别代表 ReLU 和 Sigmoid 运算。第一个全连接层中我们选用 $r=16$ 来降维,文献[16]已证明在此值时网络的整体计算量和整体性能最平衡。

最后将各通道的值乘以式(8)中对应的 k_C 得到各权重被重新调整后的输入:

$$x_C' = k_C \cdot x_C \quad (8)$$

其中, x_C 是没有经过 SEblock 提取的特征信息, x_C' 是该层信息被重新调整后的结果。

减小输入图像和重建后的图像之间的误差,可以使得网络不断非线性拟合原始的输入图像的数据值,实现学习高频部分和低频部分之间端到端的映射关系。通过构造最小化目标函数,不断地训练网络来更新卷积神经网络的参数值,当目标函数收敛时,输入图像和重建后图像之间的欧氏距离最小,重建图像的质量效果最好,此时得到的网络参数为最优解:

$$W, b = \arg \min_{w, b} \frac{1}{2N} \| Z_i - \hat{Z}_i \|_2^2 \quad (9)$$

本文在训练高频部分信息的密集卷积神经网络时采用了残差学习的思想,在图像重建过程中构造了本网络模型的重建误差函数,定义为:

$$Loss = \frac{1}{N} \sum_{i=1}^N |r - F(\lim_{x \rightarrow \infty} X_i; \lambda)| \quad (10)$$

其中, N 是训练样本的数量,为输入的第 i 幅低分辨率图像, $\lambda = \{W_1, W_2, \dots, W_n, b_1, b_2, \dots, b_n\}$, r 是标准的高分辨率输出 Z_i 与低分辨率输入 X_i 的残差图像信息。

3 实验与分析

3.1 数据集的建立及图像预处理

为了验证所提方法在不同水域中增强图像效果的鲁棒性和泛化能力,本文自建水下成像系统获取4种不同的数据集:在清水中基于目标板的水下图像、在东湖和长江流域中基于目标板的水下图像、在东湖和长江流域中采集到的真实水下图像、在巴厘岛海洋流域采集到的真实水下图像。带有目标板的数据集作为训练集,采集到的真实水下场景图片为测试集。图4是此次实验成像系统的原理图。





图4 成像系统原理

Fig. 4 Imaging system schematic

图5(a)是长江浑浊水水域中目标板的图像,图5(b)是清水中目标板的图像。可以看出,清水中的图像的成像质量比较高,基本没有噪声,而长江水中的图像含较多噪声,清晰度很低。通过局部配对生成训练样本对进行训练,获得的神经网络具有适应水下噪声环境的能力。



(a) 清水中目标板的局部图 (b) 浑浊水中目标板的局部图

图5 数据集配对图

Fig. 5 Data set matching diagram

表1 数据集组成

Table 1 Data set composition

项目	训练集	校验集	测试集
数量	16725	2090	2090
尺寸	64×64	64×64	64×64

训练一个好的神经网络需要大量的数据样本,为了解决数据样本不足,提升训练数据的有效性,本文对所获得的图像库进行了数据扩充。将得到的尺寸为 500×500 的训练样本对先进行 64×64 颜色空间转换并提取 64×64 通道,再将图像的大小处理为 64×64 的图像块,然后利用放大、缩小、旋转、镜像等方法扩充数据集。选取其中 80% 作为训练集,

10%作为校验集,10%作为测试集。训练集、校验集和测试集中图片的数目及尺寸如表1所列。

3.2 评价指标

本文将以人眼感受为主的主观评价法和基于数据计算的客观评价法相结合来评价各类图像重建算法的优劣。主观评价是最直观和简单的评价方法,但是很容易受观察条件的影响,客观评价在某些程度上可以弥补主观评价的不足^[18]。

由于水下采集到的图像都含有一定噪声,无法将高清图像与重建后的图像进行对比,本文选取无参考图像的重建评价指标:拉普拉斯和(LS)、灰度平均梯度(GMG)和模糊度量(BM)。LS表示有用图像信息的丰富性;BM描述了图像失真的程度;GMG反映图像边缘信息。LS和GMG的值越大,BM值越小,说明图像恢复重建效果越好。本团队之前研究已对该指标进行了详细叙述^[19-21],本文不再详细解释。BM,LS,GMG的表达式如下:

$$\begin{aligned}
 BM &= \max(sZ_{\text{vertical}}, sZ_{\text{horizontal}}) \\
 sZ_{\text{vertical}} &= \sum_{i,j=1}^{m-1, n-1} Z_{\text{vertical}}(i, j) \\
 sZ_{\text{horizontal}} &= \sum_{i,j=1}^{m-1, n-1} Z_{\text{horizontal}}(i, j) \\
 \begin{cases} Z_{\text{vertical}} = |F(i, j) - F(i-1, j)| \\ Z_{\text{horizontal}} = |F(i, j) - F(i, j-1)| \end{cases}
 \end{aligned} \quad (11)$$

其中, $i \in (0, m-1)$, $j \in (0, n-1)$; Z_{vertical} 和 $Z_{\text{horizontal}}$ 代表在垂直和水平方向上的不同图像; $F(i, j)$ 表示图片上 (i, j) 位置的像素值; (m, n) 代表该图像的大小。根据上式模糊度可以被归一化到 $(0, 1)$ 范围内。

$$\begin{aligned}
 LS &= \sum_{i=1}^{M-1} \sum_{j=1}^{N-1} |8 * f(x, y) - f(x, y-1) - f(x-1, y) - \\
 & f(x+1, y) - f(x, y+1) - f(x-1, y-1) - f(x- \\
 & 1, y+1) - f(x+1, y-1) - f(x+1, y+1)| / ((N- \\
 & 2)(M-2))
 \end{aligned} \quad (12)$$

其中, M, N 代表图像性大小; x 和 y 代表像素的位置。

$$\begin{aligned}
 GMG &= \frac{1}{(M-1)(N-1)} \sum_{i=1}^{M-1} \sum_{j=1}^{N-1} \\
 & \sqrt{\frac{[f(x, y+1) - f(x, y)]^2 + [f(x+1, y) - f(x, y)]^2}{2}}
 \end{aligned} \quad (13)$$

其中, (x, y) 代表该像素点的位置; (m, n) 代表该图像的大小。

为了展现所提算法的有效性,本文选取两个对水下图像具有较好重建效果的传统图像重建算法和两个应用较广的超分辨率重建算法来进行对比,具体为凸集投影算法(POCS)、Fast-a-Robust-Super-Resolutio(BTV)、SRCNN、EDSR。

3.3 实验结果分析

3.3.1 江河湖底水下实验

在长江和东湖流域的微湍流水环境下进行图像采集,图像样品由水下成像系统中的COMS图像传感器捕获继而传输给图像处理模块。图5和图6为采集到的图像样本和各算法处理结果。从主观角度上讲,使用的BTV算法不适用于水下图像处理,而传统的深度学习算法SRCNN网络对水下图像的重建效果一般,对比度较低,且边缘出现模糊。其余重建图像的边缘信息更完整,重建效果更好。这是由于SRCNN网络仅针对单一模糊因子进行训练,这对含有复杂干扰信息的水下图像的处理不具有适用性。




图6 河流中采集到的图像一的各类方法重建结果对比图

Fig. 6 Comparison of reconstruction results of various methods of image 1 collected in river




图7 河流中采集到的图像二的各类方法重建结果对比图

Fig. 7 Comparison of reconstruction results of various methods of image 2 collected in river

采用BM,LS和GMG3个指标对5种算法的重建图像进行评价,评价结果见表2和表3。可以看出,SRCNN算法相较于其余4种算法均表现出高BM值和较低的LS,GMG值,表明图像重建效果较差。而EDSR相较传统的水下超分辨率重建算法POCS在去模糊、图像清晰度和细节还原方面都有了较大的提高,图像的重建效果更好,体现了深度学习算法的优越性。而本文方法相较于EDSR在引入更深的网络层的同时还增强了网络对有用特征的学习,因此重建效果更好。

表2 河流中采集到的图像一的重建结果对比

Table 2 Comparison of reconstruction results of image 1 collected in river

Index	POCS	BTV	SRCNN	EDSR	Proposed
BM	0.1138	0.2225	0.3574	0.2807	0.1348
LS	30496987	8705807	1972183	33191024	48148900
GMG	50860390	1534336	493873	6594554	8535785

表3 河流中采集到的图像二的重建结果的对比

Table 3 Comparison of reconstruction results of image 2 collected in river

Index	POCS	BTV	SRCNN	EDSR	Proposed
gBM	0.2553	0.2752	0.3298	0.2182	0.1260
LS	9384465	5618872	1378093	20643851	71220072
GMGg	1606297	974239	306788	3849913	1183189

3.3.2 海底水下实验

在巴厘岛的微湍流水域进行拍摄的图像和基于5种重建算法的处理结果如图8、图9所示。图像处理的客观评价结果如表4、表5所列。在海洋环境下的实验结果相较于在河流的微湍流水域中的处理结果,两种传统的水下处理算法的 BM 值均明显上升而 LS 、 GMG 明显下降,尽管本文所算法的 LS 值也出现明显下降,但是与传统的算法相比仍能体现出其在海洋流域中对图像的细节复原和丰富度方面具有较强的鲁棒性。

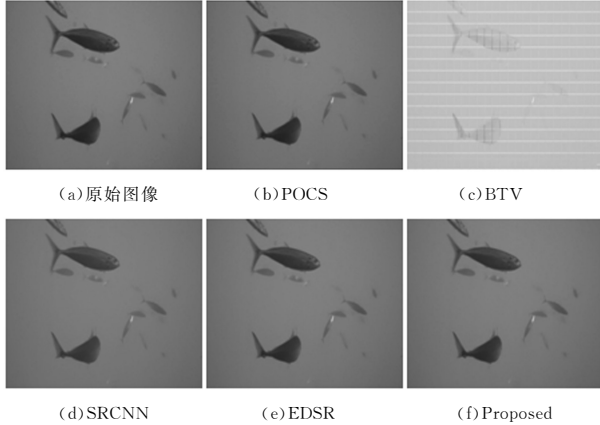


图8 海洋中采集到的图像1的各类方法重建结果对比图

Fig. 8 Comparison of reconstruction results of various methods of image 1 collected in ocean




图9 海洋中采集到的图像2的各类方法重建结果对比图

Fig. 9 Comparison of reconstruction results of various methods of image 2 collected in ocean

表4 海洋中采集到的图像1的重建结果的对比

Table 4 Comparison of reconstruction results of image 1 collected in ocean

Index	POCS	BTV	SRCNN	EDSR	Proposed
BM	0.2869	0.2613	0.4438	0.3666	0.1158
LS	13823047	7914449	1315747	19582732	27776546
GMG	2398245	1411510	387726	4404269	44903045

表5 海洋中采集到的图像2的重建结果的对比

Table 5 Comparison of reconstruction results of image 2 collected in ocean

Index	POCS	BTV	SRCNN	EDSR	Proposed
BM	0.2835	0.2935	0.4572	0.3229	0.1160
LS	11524790	5285081	1127035	17830156	26299456
GMG	2014556	967487	328704	3805133	41923881

结束语 本文提出了一种改进的残差神经网络运用于水下图像重建,主要贡献为在残差密集网络中引入了自适应机制,并且自建水下成像系统采集河流和海洋微湍流水域中的水下图像生成真实水下数据集。由实验结果可知,相较传统的水下复原技术和传统神经网络,使用融入注意力机制的改进残差网络重建得到的水下图像的 BM 明显下降, LS 、 GMG 都有明显的提高,重建图像的质量明显提高,图像边缘保持和边缘锐度都得到明显改善,整体图像更加清晰。

然而,基于深度学习的水下图像重建算法面对复杂的水下环境,无法适应所有环境因素的干扰,其可拓展性还有待研究,所以下一步的工作重点则是在算法的基础上引入合适的物理模型,使其在面对恶劣的水下环境时有更好的鲁棒性。

参考文献

- [1] CHEN Y, YANG W, TAN H, et al. Image enhancement for LD based imaging in turbid water[J]. Optik - International Journal for Light and Electron Optics, 2016, 127(2): 517-521.
- [2] CHEN Y Z, YE T, CHENG C J, et al. Degradation and optimal recovery of underwater turbulent imaging[J]. Optoelectronic Engineering, 2018, 45(12): 55-65.
- [3] YANG A P, ZHENG J, WANG J, et al. Underwater image restoration based on color distortion removal and dark channel priori[J]. Journal of Electronics and Information Technology, 2015, 37(11): 2541-2547.
- [4] HUO G Y, YAN S Y, WU W L, et al. Underwater image processing based on dark channel priors and adaptive color correction[J]. Electrooptic & Control, 2019, 26(11): 70-74.
- [5] SERIKAWA S, LU H. Underwater image dehazing using joint trilateral filter[J]. Computers & Electrical Engineering, 2014, 40(1): 41-50.
- [6] LU H, LI Y, NAKASHIMA S, et al. Underwater image super-resolution by descattering and fusion[J]. IEEE Access, 2017, 5: 670-679.
- [7] NAKAGAWA Y, KIHARA K, TADOH R, et al. Super resolving of the depth map for 3D reconstruction of underwater terrain using Kinect[C] // 2016 IEEE 22nd International Conference on Parallel and Distributed Systems (ICPADS). IEEE, 2016: 1237-1240.
- [8] ZHANG Q B, ZHANG X H, HAN H W. An underwater photoelectric image quality optimization method based on deep convolutional neural network [J]. Acta Optica Sinica, 2008, 38(11): 96-104.
- [9] XU Y, SUN M S. Underwater image enhancement method based on convolutional neural network [J]. Journal of Jilin University (Engineering Edition), 2018, 48(6): 1895-1903.
- [10] DONG C, LOY C C, HE K, et al. Learning a deep convolutional network for image super-resolution[C] // European Conference on Computer Vision. Springer, Cham, 2014: 184-199.
- [11] SCHMIDHUBER J. Gradient Flow in Recurrent Nets: the Difficulty of Learning Long-Term Dependencies [M] // Gradient Flow in Recurrent Nets: The Difficulty of Learning Long-Term Dependencies. Wiley-IEEE Press, 2001.
- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 770-778.

- [9] ZHU W,WANG F Y. On three types of covering rough sets [J]. IEEE Transactions on Knowledge and Data Engineering, 2007(19):1131-1144.
- [10] ZHU W. Topological approaches to covering rough sets[J]. Information Sciences, 2007(177):1499-1508.
- [11] ZHU W. Relationship among basic concepts in covering-based rough sets[J]. Information Sciences, 2009(179):2478-2486.
- [12] YAO Y Y, Y B X. Covering based rough set approximations[J]. Information Sciences, 2012(200):91-107.
- [13] ZHANG Y L, LI C Q, LIN M L, et al. Relationships between generalized rough sets based on covering and reflexive neighborhood system[J]. Information Sciences, 2015(319):56-67.
- [14] D'EER L, RESTREPO M, CORNELIS C, et al. Neighborhood operators for covering-based roughsets [J]. Information Sciences, 2016(336):21-44.
- [15] YAO H, ZHU W. Condition for neighborhoods in covering based rough sets to form a partition[J]. arXiv:1209.5480v1 [cs. AL] 25 Sep 2012.
- [16] YANG B, HU B Q. On some types of fuzzy covering-based rough sets[J]. Fuzzy Sets and Systems, 2017(312):36-65.
- [17] WANG C Z, CHEN D G, SUN B Q, et al. Communication between information systems with covering based rough sets[J]. Information Sciences, 2012(216):17-33.
- [18] ZHOU J L, GUAN Y Y, XU F S, et al. On some types of fuzzy covering-based rough sets[J]. Fuzzy Sets Syst., 2017(312):36-65.




ZHOU Jun-li, born in 1993, postgraduate. Her main research interests include rough sets and fuzzy sets.



GUAN Yan-yong, born in 1964, Ph.D., professor, master supervisor. His main research interests include rough sets and fuzzy sets, etc.

(上接第 504 页)

- [13] KIM J, KWON LEE J, MU L K. Accurate image super-resolution using very deep convolutional networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:1646-1654.
- [14] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2017:136-144.
- [15] ZHANG Y, TIAN Y, KONG Y, et al. Residual dense network for image super-resolution[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:2472-2481.
- [16] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:7132-7141.
- [17] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015:1-9.
- [18] 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.
- [19] CHEN Y Z, YANG W L, TAN H Y, et al. Image enhancement for LD based imaging in turbid water[J]. Optik - International Journal for Light and Electron Optics, 2016, 127(2):517-521.
- [20] CHEN Y, YANG K. MAP-regularized robust reconstruction for underwater imaging detection [J]. Optik-International Journal for Light and Electron Optics, 2013, 124(20):4514-4518.
- [21] ZHANG M, CHEN Y, PAN Y, et al. A Fast Image Deformity Correction Algorithm for Underwater Turbulent Image Distortion[J]. Sensors, 2019, 19(18):3818.



SONG Ya-fei, born in 1999, postgraduate. Her main research interests include image processing and deep learning.



CHEN Yu-zhang, born in 1984, Ph.D., associate professor. His main research interest include laser and LED in water, night vision or underwater scattering medium radiation transmission theory and computer simulation, image acquisition and restoration and reconstruction algorithms, image processing algorithms embedded including the research of Android development.