

基于蓝图可分离卷积的轻量级水下 图像超分辨率重建

李艳¹, 谌雨章¹, 郭煜玮², 胡世斌¹

(1. 湖北大学 计算机与信息工程学院, 武汉 430062; 2. 国电河南新能源有限公司, 郑州 450003)

摘要: 由于水体中存在的悬浮颗粒以及高频随机运动的湍流引起光的散射和吸收而导致水下图像存在纹理模糊、分辨率低、扭曲失真等系列问题, 而目前存在的大部分深度学习图像超分辨率重建算法存在着计算复杂、模型的复杂度大、内存占用高等不足; 针对这些不足, 提出基于蓝图可分离卷积的轻量级水下图像超分辨率重建网络, 该模型分为浅层特征提取、深度特征提取、多层特征融合以及图像重建 4 个阶段, 深度特征提取阶段中, 在 BSRN 的基础上去除特征蒸馏分支、采用增加通道数进行补偿, 同时利用 3 个蓝图卷积来进行残差局部特征学习以简化特征聚合, 实现网络的轻量化; 实验结果表明, 所提出的方法在运行时间、参数量、模型复杂度方面均优于目前已提出的超分算法, 放大倍数为 2 和 4 时, 峰值信噪比 (PSNR) 和结构相似度 (SSIM) 均值分别达到了 31.556 0 dB、0.862 0 和 27.708 8 dB、0.721 3, 重建质量获得进一步提升。

关键词: 深度学习; 蓝图可分离卷积; 超分辨率重建; 轻量级网络; 水下图像

Super-Resolution Reconstruction of Lightweight Underwater Images Based on Blueprint Separable Convolution

LI Yan¹, CHEN Yuzhang¹, GUO Yuwei², HU Shie¹

(1. School of Computer and Information Engineering, Hubei University, Wuhan 430062, China;

2. Guodian Henan New Energy Co., Ltd., Zhengzhou 450003, China)

Abstract: Abstract: Due to the scattering and absorption of light caused by suspended particles in water and the turbulence of high-frequency random motion, underwater image has a series of problems such as blurred texture, low resolution and distortion. However, most existing deep learning image super-resolution reconstruction algorithms have the problems of complex computation, large complexity of model and high memory occupation. To solve this problem, a lightweight underwater image super-resolution reconstruction network based on blueprint separable convolution is proposed. The model is divided into four stages: shallow feature extraction, deep feature extraction, multi-layer feature fusion and image reconstruction, In the depth feature extraction stage, feature distillation branches are removed on the basis of blueprint separable residual network (BSRN) and the number of channels is increased for compensation. At the same time, the three blueprints convolution is used to carry out the residual local feature learning to simplify the feature aggregation and realize the lightweight of the network. The experimental results show that the proposed method is superior to the currently proposed hyperspectral algorithm in terms of running time, parameter quantity and complexity of the model. When the amplification factor is 2 and 4, the peak signal-to-noise ratio (PSNR) and structure similarity (SSIM) average values reach 31.556 0 dB, 0.862 0 and 27.708 8 dB, 0.721 3 respectively, and the reconstruction quality is further improved.

Keywords: deep learning; blueprint separable convolution; super resolution reconstruction; lightweight network; underwater image

0 引言

目前, 随着地球人口的增多, 在陆地空间和资源压力日益增加的条件下, 对于水下空间及资源的开发变得十分迫切, 因此水下图像处理领域的研究已引起广泛关注。但是由于水中光线的选择性衰减与水中粒子散射问题、水中浮游物以及水体本身的散射和吸收作用, 水下图像会表现出颜色扭曲、细节模糊、对比度低、明亮的伪影等其他失

真的问题, 这给水下工作带来了极大的挑战和困难, 因此近年来有许多学者为提高水下图像的质量专注研究水下图像的处理。

已经有许多算法应用在水下图像增强, 包括基于暗通道先验知识^[1]、基于 Retinex 算法^[2]等, 该类方法由于水中成像的特殊性存在局限性, 因此近年来水下图像超分辨率重建引起了学者们的广泛关注, 陈龙彪^[3]等人在卷积网络

收稿日期: 2022-11-08; 修回日期: 2022-11-14。

基金项目: 教育部产学研合作协同育人项目(202101142041); 大学生创新创业训练计划项目(国家级 202010512020)。

作者简介: 李艳(1997-), 女, 湖南长沙人, 硕士研究生, 主要从事图像处理、深度学习方向的研究。

谌雨章(1984-), 男, 湖北武汉人, 博士, 副教授, 主要从事光电探测、图像处理方向的研究。

引用格式: 李艳, 谌雨章, 郭煜玮, 等. 基于蓝图可分离卷积的轻量级水下图像超分辨率重建[J]. 计算机测量与控制, 2023, 31(6): 191-197.

中引入改良的密集块应用到水下图像进行重建；宋娅菲等人^[4]将残差密集块与自适应机制相融合，提出了基于残差的水下图像重建方法；袁红春等人^[5]在普通残差网络上引用了信息蒸馏机制和空间注意力模块。在图像超分辨率算法中，深度学习已经成为图像处理领域的主流算法，随着科技与时代的进步以及网络重建性能的不不断提升，网络结构越来越复杂、参数量显著增加，这造成了巨大的计算开销，为此轻量级网络也开启了高飞猛进的发展模式。2017年Lim等人^[6]提出了增强型深度残差网络（enhanced deep super-resolution network），首次在图像超分辨率重建处理中移除传统残差网络中的BN层以简化网络体系结构，将内存需求减少约40%，轻量化思想初步得以实现；后来Zhang等人深度残差通道注意网络（RCAN, residual channel attention networks）中提出残差嵌套（RIR, residual in residual）结构使网络绕过低频信息来提高特征处理的效率，同时引入通道注意力（CA, channel attention）机制来提取具有更重要信息的特征，模型性能取得了极大提升^[7]。

但是这些方法由于网络深度的增加网络参数量也随之增加，导致了重建速度的降低，并没有实质上的实现轻量级网络的构建。为解决此问题，Hui等人^[8]提出的信息蒸馏网络（IDN, information distillation network）利用蒸馏块和跳跃连接逐步提取丰富有效的特征，减少了滤波器的数量，在保持更好的重建精度的同时实时速度更快，Hui等人^[9]后来提出的多尺度特征蒸馏网络（IMDN, information multi-distillation network）对IDN进行改进，构造了级联多蒸馏块（IMDB, information multi-distillation module）来提取分层特征，并根据特征的重要性进行聚合；紧接着Liu等人^[10]提出了基于残差的特征蒸馏网络（RFDN, residual feature distillation network）进一步对IMDN进行了改进，提出的特征蒸馏连接使得特征提取块更加简洁。2022年Li等人^[11]提出了蓝图可分离残差网络（BSRN, blueprint separable residual network），通过引入蓝图可分离卷积（BSConv, blueprint separable convolution）更是进一步减少了参数、优化了卷积操作，同时引入空间和通道注意力块来增强特征，在保证重建质量的基础上，减小了网络模型及计算复杂度^[12]。

为了进一步提高其性能并且减少模型参数、提高重建速度，本文设计了一种基于蓝图可分离卷积的轻量级超分辨率网络，利用蓝图可分离卷积代替普通卷积进行运算，减少特征冗余；同时使用增强空间注意（ESA）和对比度感知注意（CCA）^[9]来增强模型能力；相比BSRN，去除ESDB模块中的特征蒸馏连接，简化了网络模型，同时更好地利用了剩余的局部特征进行特征浓缩细化。

1 基于蓝图可分离卷积的超分辨率重建方法

1.1 网络概述

本文算法整体网络结构如图1所示，通过优化卷积运算、引入有效的注意模块、仅使用级联的蓝图卷积+RELU

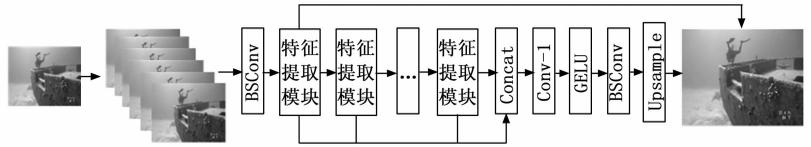


图1 整体网络结构

层^[13]进行局部特征提取3个方面来提高网络的效率，减少网络的冗余计算，从而实现轻量化操作。

该算法结构整体分为4个阶段：浅层特征提取、深层特征提取、多层特征融合以及图像重建阶段。在特征提取阶段，输入的低分辨率图像先经过蓝图可分离卷积BSConv得到浅层特征 F_0 ，然后将浅层特征 F_0 输入到多个基于蓝图卷积的特征提取块中提取出每层特征 $[F_0, F_1, \dots, F_n]$ ，再经过 1×1 卷积和GELU激活函数将特征进行融合与映射，最后通过蓝图卷积BSConv提取深层特征 F_j 。在图像重建阶段，将浅层特征 F_0 和深层特征 F_j 相加后输入到上采样模块，完成重建过程。

1.2 浅层特征提取阶段

在浅层特征提取阶段，首先将输入图像 I_{LR} 复制 n 次并沿通道维度连接至一起得到 I_{LR}^n ，再经过BSConv提取到浅层特征 F_0 ，该过程可表示为：

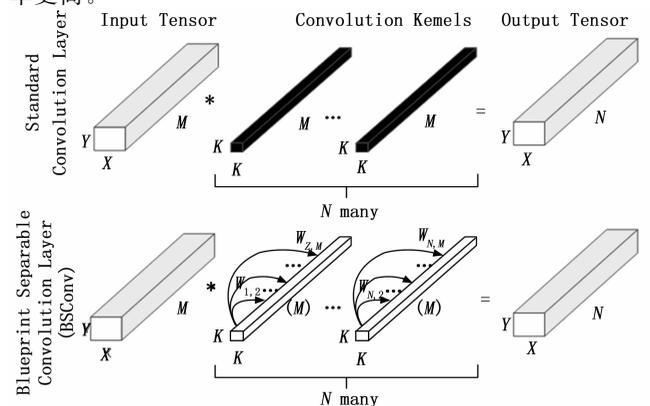
$$I_{LR}^n = Concat_n(I_{LR}) \quad (1)$$

$$F_0 = H_{SF}(I_{LR}^n) \quad (2)$$

其中： $Concat(\cdot)$ 表示沿通道维度的连接操作， n 是需要连接的 I_{LR} 图像的数目； $H_{SF}(\cdot)$ 表示浅层特征提取块。

1.2.1 蓝图可分离卷积

蓝图可分离卷积^[13]BSConv是Daniel受启发于预训练模型所提出，能够更好地利用核内相关性允许更有效的分离规则卷积。BSConv的卷积原理如图2所示，标准卷积^[14]每个卷积核尺寸是 $M \times K \times K$ ，可训练参数为 $M \cdot N \cdot K^2$ ，蓝图可分离卷积的卷积核将 $M \times K \times K$ 分离成 M 个 $K \times K$ 尺寸的卷积核，可训练参数仅需 $N \cdot K^2 + M \cdot N$ ，在轻量级网络中，使用蓝图可分离卷积相比标准卷积更具优势，效率更高。



□ Data ■ Learnable Kernel Weights ◻ Implicit Kernel Weights

图2 BSNConv卷积原理

本文中 BSConv 的作用是扩展通道至更高维度并进行浅层特征提取, 其结构如图 3 所示。

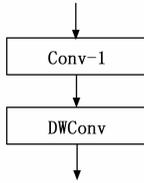


图 3 蓝图可分离卷积 BSConv 模块

1.3 深层特征提取阶段

该阶段是由多个基于蓝图卷积特征提取模块组成, 采用残差连接进行局部特征学习, 将浅层特征 F_0 输入到深层特征模块逐步细化提取每层的特征。该过程可表示为:

$$F_n = H_n(H_{n-1}(H_{n-2}(\dots H_0(F_0)\dots))) \quad (3)$$

其中: $H_n(\cdot)$ 表示第 n 个特征提取模块函数, $F_n(\cdot)$ 表示第 n 个输出特征映射。

1.3.1 基于蓝图可分离卷积的特征提取模块

该模块是整个算法的核心部分, 相比 NTIRE2022 挑战赛中获得冠军方案的 BSRN 算法, 新提出的模块中去掉了特征蒸馏分支、采用增加通道数进行补偿, 每个特征细化模块包含蓝图卷积 BSConv 层、GeLU 激活函数、 1×1 卷积层、增强空间注意层 (ESA)^[15]、对比感知通道注意力 (CCA)^[9], 本文所提模块如图 4 所示。给定输入特征 F_{in} , 整个结构的描述如下:

$$F_{refined_1} = RM_1(F_{in}) \quad (4)$$

$$F_{refined_2} = RM_2(F_{refined_1}) \quad (5)$$

$$F_{refined_3} = RM_3(F_{refined_2}) \quad (6)$$

其中: RM_j 表示第 j 个细化模块, $F_{refined_j}$ 表示第 j 个细化特征。经过多个局部特征细化步骤后, 将最后的细化特征 $F_{refined_3}$ 和输入特征 F_{in} 相加, 得到最终优化的输出特征 $F_{refined}$ 。

$$F_{refined} = F_{in} + F_{refined_3} \quad (7)$$

接下来将输出特征 $F_{refined}$ 输入到 1×1 卷积层以增强模型的代表能力, 同时为了保持重建效率, 引入一个轻量级

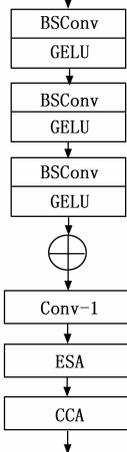


图 4 基于蓝图可分离卷积的特征提取模块

增强空间注意力模块 (ESA) 和一个对比度感知通道注意力模块 (CCA), ESA 模块和 CCA 模块分别从空间和通道角度增强模型的表达能力。

$$F_{enhanced} = H_{CCA}(H_{ESA}(F_{refined})) \quad (8)$$

其中: $F_{enhanced}$ 为增强功能, $H_{CCA}(\cdot)$ 和 $H_{ESA}(\cdot)$ 分别表示 CCA 和 ESA 模块, 使用注意力模型旨在聚合上下文信息。

1.3.2 增强的空间注意力模块

增强的空间注意力 ESA 模块^[15]的具体架构如图 5 (a) 所示。它首先使用一个 1×1 卷积层以减少输入特征的通道尺寸, 从而达到减少特征冗余的目的, 接着为了降低空间尺寸使用步长为 2 的卷积和 2×2 的最大池化层, 再使用一组由 7×7 最大池化层和步长为 3 的卷积组成的卷积组提取特征, 最后对上采样操作得到的特征进行 1×1 卷积操作恢复信道大小并通过 Sigmoid 函数^[16]生成注意矩阵后与输入进行点乘, 得到最终的输出特征。此模块应用了两个跳跃连接, 具有调节激活值的作用, 比普通的注意力模块更加轻巧并且具有更好的性能。

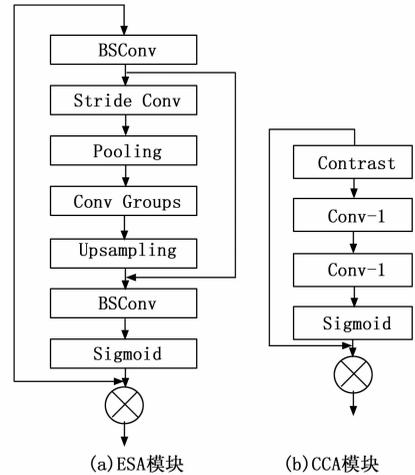


图 5 具体架构

1.3.3 对比度感知通道注意力模块

通道注意力机制^[17]最初是通过特征的不同通道重新分配权重, 更利于分类或检测, 但是对于超分辨率重建网络缺少如纹理、边缘等增强图像细节的信息。因此, 在 ESA 空间注意力模块后添加 CCA 对比度感知通道注意力模块, 该模块是利用对比度信息, 包括均值和标准差的总和来计算通道注意权重以增强图像细节信息。对比度感知通道注意力模块 CCA 具体架构如图 5 (b) 所示, 对比度信息值可通过以下公式进行计算:

$$z_c = H_{GC}(x_c) = \sqrt{\frac{1}{HW} \sum_{(i,j) \in x_c} \left(x_c^{i,j} - \frac{1}{HW} \sum_{(i,j) \in x_c} x_c^{i,j} \right)^2} + \frac{1}{HW} \sum_{(i,j) \in x_c} x_c^{i,j} \quad (9)$$

其中: z_c 是输出的第 c 个元素, $H_{GC}(\cdot)$ 表示全局对比度 (GC) 信息评估函数。

1.4 图像融合与重建阶段

进行深层特征提取后，将每一特征模块的生成特征输出相加通过 1×1 卷积和 GELU 激活函数来平滑逐渐细化的深层特征以进行融合和映射，再使用 BConv 进行特征优化，最后使用长跳跃连接通过上采样模块进行图像重建，多层特征融合公式和重建阶段的分别如式 (10) 和 (11) 表示：

$$F_{\text{fused}} = H_{\text{fusion}}(F_0 + F_1 + \dots + F_n) \quad (10)$$

$$I_{\text{SR}} = H_{\text{rec}}(F_{\text{fusion}} + F_0) \quad (11)$$

其中： $F_0 \sim F_n$ 为逐步细化提取的每层特征， $H_{\text{fusion}}(\cdot)$ 表示融合模块， F_{fused} 表示融合特征， $H_{\text{rec}}(\cdot)$ 表示重建模块，该模块由一个 3×3 标准卷积层和一个亚像素卷积组成，其结构如图 6 表示。

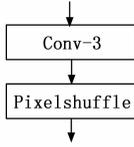


图 6 上采样操作

亚像素卷积^[17]就是通过卷积和多通道间的重组得到高分辨率图像，具体过程如图 7 所示，先对图像进行特征提取生成 $r \times r$ 个特征通道图 (r 即上采样倍数)，再按照一定的规则将这 $r \times r$ 个通道的特征图组合为 $w \times r$ 、 $h \times r$ 的上采样结果即完成亚像素卷积操作。

整个网络模型利用 L_1 损失函数进行优化，其公式如下：

$$L_1 = \|I_{\text{SR}} - I_{\text{HR}}\|_1 \quad (12)$$

2 实验结果与分析

2.1 实验设置

本文在由 Minnesota University 交互式机器人与视觉实验室最新公开的水下图像数据集 USR-248 上进行了 2 倍和 4 倍的超分辨率重建实验^[18]。该数据集包含了大量的水下实体，包括水母、章鱼、鲸类、虾类、蟹类、贝类等多种生物以及水下航行器残骸、潜水员等图片。训练集包含 1 060 张分辨率为 480×640 的真实高清水下图像及其对应的使用 Bicubic 下采样获得的低分辨率图像；测试集包含 248 张高分辨率图像与其对应的低分辨率图像。从 USR-248 训练集中选取编号 1~1 040 作为本文的训练集，从编号 1 041~1 060 中选取 5 张内容丰富，纹理清晰的图像作为本文的

验证集，使用 USR-248 全部的测试集在 Y 通道上对本文提出的模型进行测量评估^[19]。

本实验的训练平台为：操作系统为 64 位的 Windows10，采用单块 GPU 训练网络，显卡为 NVIDIA Quadro RTX5000，处理器为 Intel (R) Xeon (R) Silver 4210 CPU @2.20 GHz。训练测试平台为 CUDA10.2，cuDNN8.0.4，pytorch1.8.1，python3.8。在主要参数学习率的设置上，为了避免出现过拟合、欠拟合，训练时间过长，本文采用的是学习率衰减的办法。设定初始学习率为 1×10^{-3} ，每迭代 100 000 次学习率降为原来的 1/10，同时采用随机梯度下降法 (SGD) 以及 Adam 优化器对网络进行更新迭代训练。参数 $\beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-7}$ ，输入 patch 大小设置为 64×64 ，batchsize 设为 16，一共训练 1 000 000 次。

2.2 评价指标

本文使用峰值信噪比 (PSNR, peak signal-to-noise ratio)、结构相似比 (SSIM, structure similarity)、UIQM 作为评价指标。

2.2.1 PSNR

PSNR^[20]是一种评价图像的客观标准，用于衡量两张图像之间的差异，定义式如下：

$$PSNR = 10 \times \lg \left(\frac{Max_i^2}{MSE} \right) \quad (13)$$

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (14)$$

PSNR 值越大代表失真越小，表示图像质量越好。式中 y_i 表示高分辨率图像中第 i 个位置上的像素值， \hat{y}_i 表示重建后图像中第 i 个位置上的像素值， m 表示图像的总像素， Max_i^2 为图像像素可取到的最大值，例如 8 位像素为 $2^8 - 1 = 255$ ；MSE 为两张图的均方误差值，表达的是两幅图在每一个位置上的像素值的差异的平均，数值越大，表示两张图片在相似度上越低。

2.2.2 SSIM

SSIM^[20]比传统方式更符合人眼视觉感知，其定义式如下：

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (15)$$

其中： μ, σ 分别为图像像素的均值和标准差， σ^2, σ_{xy} 分别表示方差和协方差， $C_1 = (k_1L)^2, C_2 = (k_2L)^2$ 是维持稳定的常数。SSIM ≤ 1 ，SSIM 值越大表示重建图像质量越好。

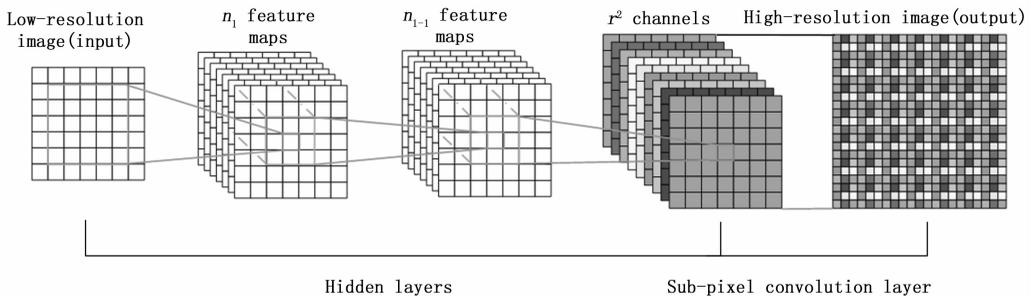


图 7 亚像素卷积操作

2.2.3 UIQM^[21]

UIQM 是一种基于人类视觉系统 (HVS) 的无参考水下图像评价指标, 由 3 个测量指标线性结合而成, 分别是色彩 (UICM)、清晰度 (UISM) 和对比度 (UIConM), UIQM 的值越大, 表示图像质量越佳, UIQM 如式 (16) 所示:

$$UIQM = c_1 \cdot UICM + c_2 \cdot UISM + c_3 \cdot UIConM \quad (16)$$

式中, c_1, c_2, c_3 为固定常数, 分别设为 0.028 2、0.295 3、3.575 3。

2.3 实验结果与分析

为了验证本文所提算法性能, 本文算法与近年来所提出的 EDSR、RCAN、BSRN、RFDN、IMDN、SwinIR^[22] 主流轻量级图像超分辨率重建算法在相同的数据集上进行性能及模型复杂度的比较。在数据集 USR-248 上, 不同轻量级图像超分辨率网络中放大倍数分别为 2 倍和 4 倍的 PSNR、SSIM、UIQM 对比如表 1 所示, 模型参数大小、网络重建时间、浮点运算量 (FLOPs) 对比如表 2 所示。其中表中加粗字体为最优数据。

2.3.1 网络重建性能对比

从表 1 看出, 在不考虑模型、参数的条件下, 当放大倍数为 2 时, RCAN 网络的 PSNR 和 SSIM 结果最优, EDSR 网络的 PSNR 和 SwinIR 的 SSIM 次之, 除此之外, 本文与 IMDN、RFDN、BSRN 三种轻量级超分辨率重建网络相比, 整体性能较优, 其中 UIQM 值优于所有网络; 当放大倍数为 4 倍时, 本文方法的 PSNR 值优于其他所有网络, 与 SwinIR、IMDN、RFDN、BSRN 四种轻量级网络相比, SSIM 和 UIQM 值均取得了较好的结果, 其中与取得 2022NTIRE 挑战赛冠军方法的 BSRN 网络相比, PSNR 值提高了 0.022 dB。实验结果表明, 本文算法在提高图像对比度、饱和度方面能达到较好的重建效果。

2.3.2 网络参数量、重建时间、浮点运算量 (FLOPs) 分析

从表 2 可以看出, 本文网络的参数量、运行时间、浮

点运算量均为最小, 进一步从轻量化方面表现出所提方法的优越性。从模型参数量方面, 在不同放大倍数下本文模型参数量仅 230 K、250.77 K, 远小于所对比的其他网络模型参数量, 相比 BSRN 模型减少了将近 31%, 相较于 RFDN 参数量减少约 45%, 相较于 IMDN 网络参数量减少约 67%, 相较于 SwinIR 网络参数量减少约 74%, 相较于 EDSR 网络参数量减少约 83%, 相较于 RCAN 网络参数量的减少更是达到了 98% 以上。

从重建时间方面, 本文网络在不同放大倍数情况下重建时间均最短, BSRN 和 RFDN 次之。放大倍数为 2 时每迭代一次仅需 144 ms, 放大倍数为 4 时每迭代一次仅需 277 ms, 所用时间不及 EDSR 网络的 1/3, 相比 SwinIR 缩短了 63%, 相比 IMDN 缩短了 20%, 相比 RCAN 缩短了将近 7 倍。所有方法重建时间均是在 GPU 显存有部分占用的情况下测出, 不同设备所测结果不同。

从浮点运算量方面, 在放大倍数为 2 倍和 4 倍时本文方法每帧的浮点运算量仅为 92.2 G、99.29 G, 相比 EDSR、SwinIR 网络减少了约 4/5, 相比 IMDN 网络减少了约 3/5, 相比 AIM2020 冠军方法 RFDN 和 NTIRE2022 冠军方法 BSRN 减少了约 1/3, 相比 RCAN 网络, 本文的浮点运算量的减少达到了 97%。

2.3.3 不同通道注意力机制对网络模型的影响

通道注意力机制的作用是给每个通道分配不同的权重以充分提取图片中有用的特征信息, 本文除了与现有方法进行对比, 还对比了 CCA、SE^[23]、ECA^[24] 3 种通道注意力机制对网络模型的影响, 结果如表 3 所示, 表中加粗字体为最优数据。实验结果表明, 3 种通道注意力模块的浮点运算量相同, 在模型参数方面, 本文使用的 CCA 模块参数量最大, 与 ECA 模块相差约 5 K, 与 SE 模块相差不到 0.5 K, 在模型参数大小、浮点运算量相差甚小的情况下本文所提

表 1 不同网络重建性能对比

	Scale	EDSR	RCAN	SwinIR	IMDN	RFDN	BSRN	本文方法
PSNR/dB	×2	31.610 1	31.644 1	31.552 6	31.478 9	31.525 2	31.548 4	31.556 0
SSIM	×2	0.831 9	0.865 5	0.863 5	0.860 1	0.861 5	0.861 7	0.862 0
UIQM	×2	2.838 5	2.824 9	2.853 5	2.851 3	2.856 3	2.856 4	2.858 0
PSNR/dB	×4	27.690 2	27.686 4	27.683 2	27.683 4	27.604 4	27.686 8	27.708 8
SSIM	×4	0.723 8	0.721 5	0.721 0	0.719 6	0.715 3	0.722 7	0.721 3
UIQM	×4	2.823 3	2.814 2	2.813 1	2.814 3	2.817 7	2.811 4	2.816 3

表 2 不同网络模型大小、重建时间、浮点运算量对比

	Scale	EDSR	RCAN	SwinIR	IMDN	RFDN	BSRN	本文方法
Params/K	×2	1 369.86	12 467.20	877.75	694.40	417.21	331.63	230.00
Run-times/ms	×2	476	981	386	178	155	167	144
FLOPs/G	×2	468.91	4 224.59	479.64	248.89	149.27	148.35	92.20
Params/K	×4	1 517.57	12 614.92	897.23	715.18	433.45	352.40	250.77
Run-times/ms	×4	591	652	395	355	304	327	277
FLOPs/G	×4	677.63	4 433.31	486.29	255.98	154.81	155.44	99.29

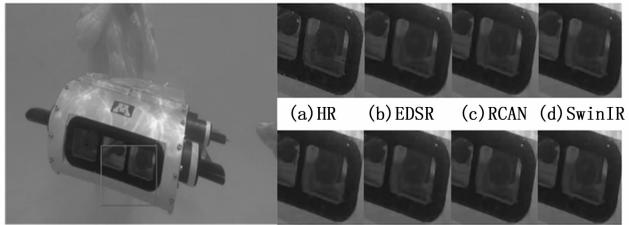
方法 PSNR、SSIM、UIQM 值都达到了最优，其中在放大倍数为 2 时，PSNR 值比使用 ECA 注意力模块提高了达 0.9 dB，因此本文模型在重建质量和模型复杂度之间取得了更好的平衡。

表 3 不同注意力机制对网络模型的影响

	Scale	Params/K	FLOPs/G	PSNR/dB	SSIM	UIQM
CCA	×2	230.00	92.20	31.556 0	0.862 0	2.858 0
	×4	250.77	99.29	27.708 8	0.721 3	2.816 3
SEN _{et}	×2	229.45	92.20	31.502 7	0.861 0	2.852 4
	×4	250.22	99.29	27.688 1	0.720 5	2.812 9
ECA	×2	225.38	92.20	30.645 9	0.840 3	2.830 2
	×4	246.15	99.29	27.130 2	0.695 1	2.802 9

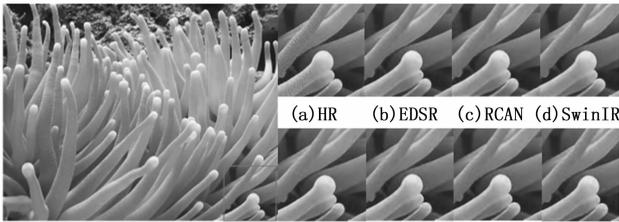
2.3.4 网络重建结果分析

在对比实验中，图像实际的重建效果除了通过评价指标进行对比，还从视觉效果上与其他算法进行比较。本文从 USR-248 测试集中选取四张高分辨率图像，当放大倍数为 2 时重建结果如图 8~9 所示，当放大倍数为 4 时重建结果如图 10~11 所示，本文网络重建效果与 RFDN、BSRN 网络重建效果视觉上无明显差异，效果良好，但是图片整体存在过度平滑的情况，细节纹理不够清晰。



USR-248: im_xb_22(x2) (e)IMDN (f)RFDN (g)BSRN (h)本文算法

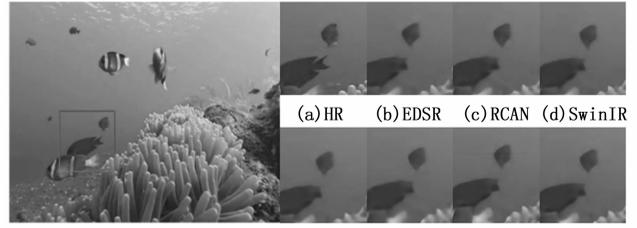
图 8 不同算法对 USR-248 数据集中 im_xb_22_进行 2 倍处理的效果



USR-248: im_xb_304(x2) (e)IMDN (f)RFDN (g)BSRN (h)本文算法

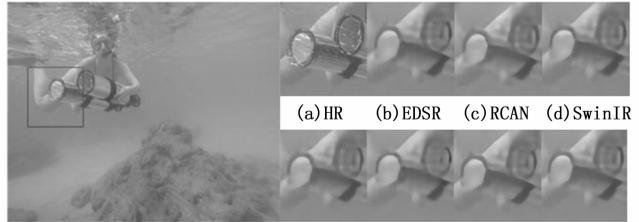
图 9 不同算法对 USR-248 数据集中 im_xb_304_进行 2 倍处理的效果

综上所述通过重建性能、模型参数量对比、重建时间对比、浮点运算量对比以及网络重建结果对比可以得知，在重建性能及视觉效果方面，所提方法落后于 RCAN、EDSR，但是两者之间差距并不大，PSNR 均值的整体差值不到 0.1 dB，在实现高质量重建性能的同时相比其他主流轻量级图像超分辨率重建网络，本文的参数量、重建时间、浮点运算量成倍减少，大大减少了网络规模、计算量及对硬件设



USR-248: im_xb_1115(x4) (e)IMDN (f)RFDN (g)BSRN (h)本文算法

图 10 不同算法对 USR-248 数据集中 im_xb_1115_进行 4 倍处理的效果



USR-248: im_xb_7396(x4) (e)IMDN (f)RFDN (g)BSRN (h)本文算法

图 11 不同算法对 USR-248 数据集中 im_xb_7396_进行 4 倍处理的效果

备的要求，提升了运算效率，综合对比可知，本文方法在算法性能和网络模型方面实现了更好的平衡，在实际应用中更加具有竞争力。本文网络与 EDSR、RCAN、SwinIR、IMDN、RFDN、BSRN 网络的参数量、重建时间及浮点运算量对比如图 12 所示。

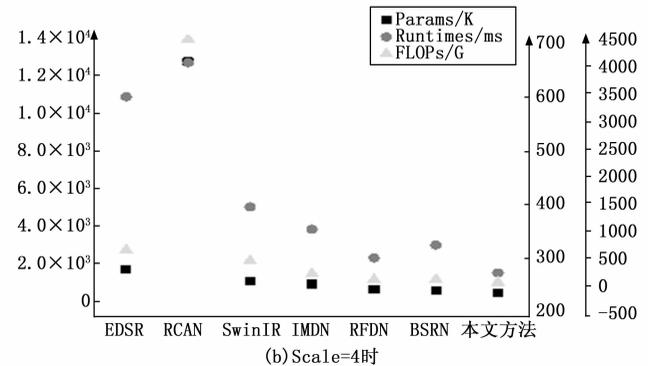
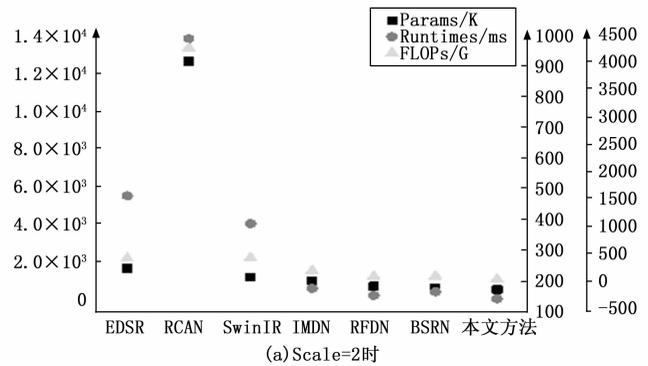


图 12 不同方法的参数量、重建时间及浮点运算量对比

3 结束语

本文提出了一种基于蓝图可分离卷积的轻量级水下图像超分辨率重建算法,首先使用蓝图卷积对图像提取浅层特征,再通过级联的特征提取模块进行深层特征提取,该模块中去除了特征蒸馏分支、采用增加通道数进行补偿,同时利用3个蓝图卷积来进行残差局部特征学习以简化特征聚合,通过减少网络层的数量和简化层之间的连接实现轻量化操作,最后进行图像的融合与重建,模型参数量、运行时间浮点运算量方面均优于对比算法,实现轻量化的同时重建质量也取得了较好的效果。本文方法应用于水下领域,所使用的训练集是基于水下图像,是否能在自然图像集上取得好的效果即本文算法的泛化性还有待研究。

参考文献:

- [1] GOLTS A, FREEDMAN D, ELAD M. Unsupervised single image dehazing using dark channel prior loss [J]. *IEEE Transactions on Image Processing*, 2019, 29: 2692–2701.
- [2] ZHUANG P, LI C, WU J. Bayesian retinex underwater image enhancement [J]. *Engineering Applications of Artificial Intelligence*, 2021, 101: 104171.
- [3] 陈龙彪, 谌雨章, 王晓晨, 等. 基于深度学习的水下图像超分辨率重建方法 [J]. *计算机应用*, 2019, 39 (9): 2738–2743.
- [4] 宋娅菲, 谌雨章, 沈君凤, 等. 基于改进残差网络的水下图像重建方法 [J]. *计算机科学*, 2020, 47 (S1): 500–504, 529.
- [5] 袁红春, 孔令栋, 张闪闪, 等. 基于信息蒸馏机制的水下图像超分辨率重建算法 [J/OL]. *激光与光电子学进展*: 1–13 [2022-08-20]. <http://kns.cnki.net/kcms/detail/31.1690.TN.20220709.1728.006.html>.
- [6] 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.
- [7] ZHANG Y, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks [C] // *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018: 286–301.
- [8] HUI Z, WANG X, GAO X. Fast and accurate single image super-resolution via information distillation network [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 723–731.
- [9] HUI Z, GAO X, YANG Y, et al. Lightweight image super-resolution with information multi-distillation network [C] // *Proceedings of the 27th ACM International Conference on Multimedia*, 2019: 2024–2032.
- [10] LIU J, TANG J, WU G. Residual feature distillation network for lightweight image super-resolution [C] // *European Conference on Computer Vision*, Springer, Cham, 2020: 41–55.
- [11] LI Z, LIU Y, CHEN X, et al. Blueprint separable residual network for efficient image super-resolution [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022: 833–843.
- [12] HAASE D, AMTHOR M. Rethinking depthwise separable convolutions: How intra-kernel correlations lead to improved mobilenets [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 14600–14609.
- [13] ZOU D, CAO Y, ZHOU D, et al. Gradient descent optimizes over-parameterized deep ReLU networks [J]. *Machine Learning*, 2020, 109 (3): 467–492.
- [14] THOMAS H, QI C R, DESCHAUD J E, et al. Kpconv: Flexible and deformable convolution for point clouds [C] // *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019: 6411–6420.
- [15] LIU J, ZHANG W, TANG Y, et al. Residual feature aggregation network for image super-resolution [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 2359–2368.
- [16] HAN J, MORAGA C. The influence of the sigmoid function parameters on the speed of backpropagation learning [C] // *International Workshop on Artificial Neural Networks*, Springer, Heidelberg, 1995: 195–201.
- [17] 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.
- [18] SHI W, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 1874–1883.
- [19] ISLAM M J, ENAN S S, LUO P, et al. Underwater image super-resolution using deep residual multipliers [C] // *2020 IEEE International Conference on Robotics and Automation (ICRA)*, IEEE, 2020: 900–906.
- [20] SARA U, AKTER M, UDDIN M S. Image quality assessment through FSIM, SSIM, MSE and PSNR—a comparative study [J]. *Journal of Computer and Communications*, 2019, 7 (3): 8–18.
- [21] LI C Y, MAZZON R, CAVALLARO A. An online platform for underwater image quality evaluation [C] // *International Conference on Pattern Recognition*. Springer, Cham, 2018: 37–44.
- [22] LIANG J, CAO J, SUN G, et al. Swinir: image restoration using swin transformer [C] // *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2021: 1833–1844.
- [23] 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.
- [24] WANG Q, WU B, ZHU P, et al. Supplementary material for ‘ECA-Net: Efficient channel attention for deep convolutional neural networks [C] // *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, IEEE, Seattle, WA, USA, 2020: 13–19.