

doi: 10.6046/zrzyg.2021208

引用格式: 尚晓梅, 李佳田, 吕少云, 等. 用于遥感图像超分辨率重建的残差对偶回归网络[J]. 自然资源遥感, 2022, 34(2): 112 – 120. (Shang X M, Li J T, Lyu S Y, et al. Residual dual regression network for super – resolution reconstruction of remote sensing images [J]. Remote Sensing for Natural Resources, 2022, 34(2): 112 – 120.)

# 用于遥感图像超分辨率重建的残差对偶回归网络

尚晓梅, 李佳田, 吕少云, 杨汝春, 杨超

(昆明理工大学国土资源工程学院, 昆明 650000)

**摘要:** 使用人工模拟的高 – 低分辨率图像对易导致在对真实遥感图像超分辨率重建时模型泛化能力差, 针对此问题, 结合残差通道注意力网络(residual channel attention network, RCAN)的二次残差(residual in residual, RIR)模块, 改进对偶回归网络(dual regression networks, DRN), 提出了残差对偶回归网络(residual dual regression network, RDRN)。选取 LandCover.ai 和 DIOR 航空图像数据集的 10 000 张 512 像素 × 512 像素图像构成样本数据集, 用于训练和测试网络, 并将重建结果与现有其他超分辨率网络模型的重建结果对比评价。实验结果表明, RDRN 在重建质量和模型参数量方面均表现优异, 能够在较低模型复杂度的情况下实现较好的超分重建效果, 且对不同低分辨率遥感图像具有较好的泛化能力。

**关键词:** 遥感图像; 超分辨率重建; 对偶回归; 残差通道注意力; 闭合网络

**中图法分类号:** TP 79 **文献标志码:** A **文章编号:** 2097 – 034X(2022)02 – 0112 – 09

## 0 引言

高分辨率遥感图像具有更高的像素密度, 包含更多细节信息, 对地物目标识别、分类和提取等应用的精度有重要影响<sup>[1]</sup>。超分辨率(super – resolution, SR)重建<sup>[2]</sup>能够由一幅低分辨率(low – resolution, LR)图像或 LR 图像序列恢复出包含更多细节信息的高分辨率(high – resolution, HR)图像, 是获取高分辨率遥感图像的重要方法, 其中基于深度学习的 SR 重建方法是当前主流研究方向, 根据所需数据集的不同, 可分为监督学习 SR 和非监督学习 SR<sup>[3]</sup>。

现有的 SR 方法主要集中于监督学习, 如 Dong 等<sup>[4]</sup>提出 SRCNN(super – resolution convolutional neural network)模型通过构建三层卷积神经网络结构, 直接学习 LR 图像与 HR 图像间的端到端映射关系, 运行效率和重建效果较好, 但所需训练时间较长且学习过程中可能出现过拟合问题; Kim 等<sup>[5]</sup>在 SRCNN 的基础上引入残差网络(residual network, ResNet)<sup>[6]</sup>, 提出 VDSR(very deep convolutional networks for super – resolution)模型, 同时通过增加卷积

层个数以提高模型准确率, 但学习信息有限且收敛慢; Kim 等<sup>[7]</sup>提出 DRCN(deeply – recursive convolutional network)模型将递归神经网络结构应用于 SR 重建中, 加深网络结构的同时使用跳跃连接增加网络感受野, 提升模型重建效果; Tai 等<sup>[8]</sup>通过对 DRCN 已有的 ResNet 等结构进行调整, 提出多路径模式的局部残差学习结合全局残差学习和多权重递归学习的 DRRN(deep recursive residual network)模型。这些监督学习 SR 方法均需要对原始 HR 图像采用某种特定的降采样方法如 Bicubic 插值函数等退化得到相应的 LR 图像, 作为一对 HR – LR 输入样本<sup>[9]</sup>。由于不同分辨率的遥感图像间潜在的退化方法通常是未知的, 通过已知方法人工获取的成对 LR – HR 遥感数据在实际 SR 应用中可信度不高<sup>[10]</sup>。

无监督学习 SR 则完全丢弃成对的合成数据, 仅利用未配对的 LR – HR 图像直接学习 LR 到 HR 的映射, 如 Shocher 等<sup>[11]</sup>认为单个图像内部的图像统计信息已经为 SR 提供了足够信息, 通过训练图像特定的 SR 网络而非在大型外部数据集上训练通用模型来应对无监督 SR, 提出零镜头超分辨率(zero – shot super – resolution, ZSSR); Bulat 等<sup>[12]</sup>提出将 SR 分为两个阶段, 首先使用未配对的 LR – HR

收稿日期: 2021 – 06 – 30; 修订日期: 2021 – 11 – 22

基金项目: 国家自然科学基金项目“城市居住区识别的 Voronoi 邻域方法与初步实践”(编号: 41561082)资助。

第一作者: 尚晓梅(1997 – ), 女, 硕士研究生, 主要研究方向为摄影测量与遥感。Email: sxm.320@qq.com。

通信作者: 李佳田(1975 – ), 男, 博士, 教授, 主要从事计算机视觉研究。Email: ljtwcx@163.com。

图像训练和学习 HR-to-LR GAN,在此基础上基于配对的 LR-HR 图像训练 LR-to-HR 生成对抗网络(generative adversarial network, GAN),以提高现实世界 LR 图像的 SR 重建质量,如 Yi 等<sup>[13]</sup>提出了 DualGAN 网络;Ledig 等<sup>[14]</sup>分别以 ResNet 和 VGG<sup>[15]</sup>作为生成器和判别器结构提出了 SRGAN (super-resolution using a generative adversarial network)模型;Yuan 等<sup>[16]</sup>基于 CycleGAN<sup>[17]</sup>提出由 4 个生成器和 2 个判别器组成的周期循环 SR 网络 CinCGAN (cycle-in-cycle generative adversarial networks)。这些无监督学习 SR 方法无需引入人工降采样先验,使得训练数据较容易获取<sup>[18]</sup>,但由于遥感图像具有自然且丰富的纹理特征及其内容的自相关性特点,直接将现有的无监督模型应用于遥感图像 SR 会使得模型不确定问题更加严重并产生较差的重建效果,因此非监督学习 SR 方法不能直接应用于标准遥感图像 SR 问题<sup>[19]</sup>。

为此,针对自然真实且不成对的遥感图像,本文利用弱监督模型对偶回归网络(dual regression network, DRN)<sup>[20]</sup>结合深度残差通道注意力网络(residual channel attention network, RCAN)<sup>[21]</sup>中的二次残差(residual in residual, RIR)模块,提出残差对偶回归网络(residual dual regression network, RDRN),同时使用真实的不成对 LR 遥感数据和成对的 LR-HR 合成数据,使得 SR 模型能在适应现实未配对数据的同时兼顾退化先验,增强网络的学习能力,进而

重建出更符合实际应用的高质量 HR 图像。

## 1 残差对偶回归网络 RDRN

### 1.1 对偶学习

针对涉及两个互为对偶的深度学习任务,例如图像理解中基于图像生成文本和基于文本生成图像,Fu 等<sup>[22]</sup>提出一种新的机器学习范式,称为对偶学习方法,利用未标注数据进行端到端学习,通过为强化学习获取奖励信息的方式,降低深度学习对大规模标注数据的依赖性,该方法包含原始和对偶两个非对称的相反任务,相互提供反馈,相互学习、相互提高。多任务学习<sup>[23]</sup>也可以同时学习多个共享相同的输入空间的任务,但对偶学习对输入空间没有要求,只要这些任务能形成一个反馈系统即可。如图 1 所示,该学习模型同时包括正向原始模型(primal model,  $M_p$ )和回归对偶模型(dual model,  $M_D$ ),使其形成一个闭环(closed-loop),采用周期一致性损失函数,同时学习原始任务  $M_p$  和对偶任务  $M_D$ ,利用对偶任务输出值  $X'$  与给定原始期望值  $X$  相间的偏差对网络参数进行调节和控制,对 LR 与 HR 间的映射函数空间形成约束,使输出值尽量接近于期望值,从而提高遥感图像重建质量和模型泛化能力。理想情况下,如果从 LR 到 HR 的映射是最优的,则可以对超分辨率图像进行降采样以获得相同的输入 LR 图像。




图1 对偶学习 SR 重建模型

Fig. 1 Dual learning SR reconstruction model

### 1.2 二次残差块

LR 遥感图像所包含的低频信息通过神经网络学习可以被恢复成高频信息,但卷积神经网络平等对待特征的每一个通道,缺少处理不同类型信息的灵活度和辨别学习能力<sup>[24]</sup>,虽然较深的卷积网络能够获得较好的 SR 性能,但更深的网络使得训练困难,易产生过拟合问题<sup>[25]</sup>。深度残差通道注意力网络 RCAN 通过 RIR 结构来构造深层网络,允许丰富的低频信息通过多个跳跃连接直接进行传播,使主

网络专注于学习高频信息,保证浅层网络同样拥有良好的泛化能力。

如图 2 所示,每个 RIR 块由数个残差组(residual group, RG)以及长跳跃连接(long skip connection, LSC)组成, RG 为其基本模块, LSC 则用来进行粗略的残差学习;每个 RG 内部则叠加数个残差注意力通道块(residual channel attention block, RCAB)和短跳跃连接(short skip connection, SSC), RCAB 将通道注意力机制(channel attention, CA)与残差思想融合

在一起,CA 通过考虑通道之间的相互依赖性来自适应地重新调整特征,SSC 则允许丰富的低频信息直接通过恒等映射向后传播,保证信息的流动,加速网络训练;在每个 CA 内部,首先进行一个空间的全局池化(global pooling)得到  $1 \times 1 \times C$  通道描述,再经过一个下采样层和一个上采样层得到每一个通道的权重系数,将权重系数和原来的特征按元素相乘(element-wise product)即可得到缩放后的新特征,该过程将不同通道的特征重新进行了加权分配。




图2 二次残差块的结构

Fig.2 Structure of RIR block

本文所采用的 RIR 块包含 10 个 RG、一个  $3 \times 3$  的卷积(convolution, Conv)和一个 LSC,每个 RG 由 20 个 RCAB、一个 Conv 和一个 SSC 组成,在 RCAB 中对每个输入首先进行一个 Conv-ReLU-Conv 操作得到特征  $f$ ,  $f$  再经过一个 CA 模块进行重新缩放得到  $x$ ,最后将  $x$  和输入按元素相加(element-wise

sum)得到输出特征。其中 CA 模块中的下采样和上采样层都利用的卷积层 Conv 来实现,下采样层的通道数减少  $r$  倍,上采样层的激活函数为线性整流函数(rectified linear unit, ReLU),下采样层的激活函数为 Sigmoid 函数。本文采用的通道数  $C$  为 64,  $r$  为 16。

### 1.3 RDRN 模型

RDRN 模型主要由原始学习任务 P 和对偶回归任务 D 组成。原始学习任务基于 U-Net 结构,由编码器和解码器组成,其中,编码器部分由简单的 Conv 层和带参数的 ReLU 激活函数(parametric rectified linear unit, PReLU)组成,经过逐级下采样(downsample, DS),分辨率也逐层降低;解码器部分由 Conv, RIR 块和像素重组(pixelshuffle)组成。对偶回归任务对超分后的图像进行卷积下采样(up-sample, US)得到 LR 图像。

如图 3 所示,原始主任务 P 由黑色流程线指示,对偶回归任务 D 由红线流程线指示,虚线表示直接将原始图像经过放大后与处理后的图像进行特征叠加,绿色块表示下采样模块的特征映射,黄色块表示上采样模块的特征映射。其中,原始任务 P 中的下采样和上采样模块都包含  $\log_2(s)$  基本块,  $s$  为比例因子,解码路径中的采样模块个数由超分辨重建的倍数决定,2 倍重建需要 1 个基础块,4 倍重建需要 2 个基础块,此外为其添加了前期额外的输出,如 4 倍重建时分别叠加了 1 倍重建和 2 倍重建后的图像以辅助生成相应比例的图像,并将其产生的损失同时应用于后续模型的训练。




图3 RDRN 的网络结构

Fig.3 Network structure of RDRN

对偶任务 D 的目的是学习一个下采样模型,对输入的未成对数据进行下采样估计,其网络复杂度

比需要学习尺度映射的原始任务简单,仅设计了只有 2 个卷积层和 1 个 PReLU 激活层的对偶模型,其

计算成本比原始模型低且应用效果良好。

## 2 实验与分析

### 2.1 数据集及预处理

为了使训练所得模型具有更好的泛化能力,本文实验所用数据集包含 512 像素 × 512 像素的遥感图像共 10 000 张,其中 10% 作为测试集,选取自大型航空图像数据集 LandCover.ai 和光学遥感图像数据集 DIOR。Boguszewski 等<sup>[26]</sup>提出的 LandCover.ai 数据集收集了波兰 216.27 km<sup>2</sup> 不同农村地区的 RGB 航空图像切片 10 674 张,涵盖不同光学条件和植被季节周期。DIOR 数据集由 Li 等<sup>[27]</sup>提出,共收集 23 463 张不同空间尺度分布的高质量遥感图像,包含大量地物类别,对于 SR 重建研究及其应用具有代表性。

为了能更好地处理图像的边界像素,使边界点能够保留到最后一层特征图,U-Net 使用镜像操作,为输入图像增加对称的镜像边,如图 4 所示,将 512 像素 × 512 像素的图像尺寸增加为 572 像素 × 572 像素,保证每次降采样操作的特征图尺寸均为偶数。增加的镜像尺寸即感受野的大小,即每条镜像边尺寸为感受野的一半,根据 RDRN 网络架构将降采样的感受野确定为 30。




图4 镜像加边操作  
Fig.4 Overlay-tile strategy

### 2.2 重建质量评估指标

图像质量评估(image quality assessment, IQA)方法<sup>[28]</sup>包括基于人类主观感知方法和客观计算方法,客观 IQA 方法按照原始参考图像提供信息的多少分为使用参考图像进行评估的全参考方法、基于提取特征比较的简化参考方法以及不使用参考图片的无参考方法(即盲 IQA)。本文采用 2 种常用的客观评价指标:峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似度(structural similarity, SSIM),结合主观到客观,对重建后的遥感图像质量

进行评价。

#### 2.2.1 PSNR

对于均为  $N \times N$  大小的原图像  $I$  和重建图像  $I'$ , PSNR 通过对比两者相应像素之间的差异来评估真实场景中的重建质量:

$$PSNR = 10 \cdot \lg\left(\frac{L_I^2}{MSE}\right), \quad (1)$$

式中:  $L_I$  为图像的最大像素值(如 8 位 RGB 图像中  $L$  值为 255),  $MSE$  为原图像  $I$  与重建图像  $I'$  的均方误差,公式为:

$$MSE = \frac{1}{N^2} \sum_{i=1}^N (I(i) - I'(i))^2, i = 1, \dots, N. \quad (2)$$

由式(1)和或(2)可知,  $L$  为固定值, PSNR 只与像素间的  $MSE$  有关,因此 PSNR 只关注原图像  $I$  与重建图像  $I'$  的像素值之间的差异。

#### 2.2.2 SSIM

SSIM 则基于图像间的亮度、对比度和结构从 HVS 的角度来评价重建质量:

$$SSIM(I, I') = \frac{(2\mu_I\mu_{I'} + C_1)(\sigma_{II'} + C_2)}{(\mu_I^2 + \mu_{I'}^2 + C_1)(\sigma_I^2 + \sigma_{I'}^2 + C_2)}, \quad (3)$$

式中:  $\mu_I$  为原图像  $I$  的像素均值;  $\sigma_I$  为原图像  $I$  的像素方差;  $\sigma_{II'}$  为 2 张图像间的协方差;  $C_1$  和  $C_2$  为避免计算不稳定而设置的常量。

### 2.3 模型的训练

实验环境为 Windows 10 系统,使用开源深度学习框架 Pytorch (1.1.4 版本),编程语言是 Python (3.7.0 版本)。使用 RMSprop 优化器,并在训练过程中不同网络设置相同的超参数:初始学习率设为 0.000 01,权值衰减值设为 0.9,学习率衰减指数设为 0.9,动量设为 0.9,训练过程中采用的批尺寸大小为 4,迭代轮数为 50 轮。

#### 2.3.1 成对数据的训练

DRN 网络由互逆的 P 网络和 D 网络构成,通过联合学习这 2 个网络,相互提供信息反馈来训练模型。设  $x \in X$  为 LR 图像,  $y \in Y$  为 HR 图像,对于原始回归任务,其目的是寻找一个函数  $P(x)$ ,使得预测  $P(x)$  与其对应的 HR 图像  $Y$  相似;对于对偶回归任务,其目的是寻求一个函数  $D(y)$ ,使得  $D(y)$  的预测与原始输入 LR 图像  $x$  相似。

因此,对于成对数据,给定一组有  $N$  对样本的样本集  $S_p = \{(x_i, y_i)\}, i = 1, 2, \dots, N$ ,其中  $x_i$  和  $y_i$

分别为成对数据集中的第  $i$  张 LR 和 HR 图像,其训练损失函数可以写为:

$$\sum_{i=1}^N M_p(P(x_i), y_i) + \lambda M_D(D(P(x_i)), x_i), \quad (4)$$

式中:  $M_p$  和  $M_D$  分别为原始和对偶回归任务的损失函数( $L_1$  范数);  $\lambda$  为控制对偶回归损失的权重。

### 2.3.2 非成对数据的训练

对于真实的没有对应的 HR 的 LR 图像,给定一组有  $M$  个样本的样本集  $S_U = \{(x_i)\}, i = 1, 2, \dots, M$ , 本文使用与成对数据训练方法不同的未配对数据的自适应算法,该过程不依赖于其损失函数为:

$$\sum_{i=1}^{M+N} L_{S_p}(x_i) M_p(P(x_i), y_i) + \lambda M_D(D(P(x_i)), x_i), \quad (5)$$

式中:  $L_{S_p}(x_i)$  是一个指标函数,当  $x_i \in S_p$  时,其值为 1,否则值为 0。

为了保证 SR 重建性能,首先结合从成对合成数据中提取的信息,加载预训练的模型  $P$  和  $D$ ,首先通过最小化目标函数(式(5))来更新原始模型  $P$ ,

然后通过最小化对偶回归损失(式(6))来更新对偶模型  $D$ ,直接从未配对的真实世界 LR 数据中来进行模型自适应,公式为:

$$\sum_{i=1}^{m+n} \lambda M_D(D(P(x_i)), x_i). \quad (6)$$

## 2.4 实验结果分析

为了验证 RDRN 模型的有效性,分别训练 SR-ResNet, DRCN, SRGAN, EDSR, DRN 对比模型并将训练结果在测试集上进行重建测试,对重建结果和模型复杂度分别进行对比分析。

### 2.4.1 重建结果定性分析

以 4 倍重建为例,在 4 倍放大的 SR 重建中, RDRN 会生成 1 倍重建 SR 图像、2 倍重建 SR 图像和 4 倍重建 SR 图像,由图 5 可以看出,随着重建的加深,图像被放大的同时像素量也在增加,因此图像并没有变得越来越模糊,其细节信息反而被逐步恢复,从而重建出最终清晰的图像,由此说明 SR 重建的目的是重建出图像中丢失的细节高频信息。




图 5 不同尺度 SR 重建的视觉比较

Fig. 5 Visual comparison of SR reconstruction at different scales

同时,通过对比分别从 1 倍重建图即原图、2 倍重建图和 4 倍重建图中截取的地物目标(如图 5 中 (b), (c), (d) 所示),重建倍数越高,重建效果越好,这也证明了 RDRN 方法的有效性。此外还可以看出, RDRN 方法在纹理规则且明显的地方超分表现良好,比如对道路、车辆等规则地物的重建,但是对于草地等地区的重建效果则并不显著。

为了对比 RDRN 模型和其他网络模型在不同尺度遥感图像 SR 的重建性能,针对放大 4 倍的 SR 模型重建结果进行直观的视觉比较,选取一组测试结果进行分析,结果如图 6 所示。由图 6 可知,

SRResNet, DRCN 和 EDSR 生成的图像包含较多的模糊,细节重建效果并不理想;而 SRGAN 虽然能够获得与原 HR 图像视觉上近似的效果,但由于其对未配对的 LR 和 HR 图像之间的数据差异敏感, SR 结果容易失真并包含噪声; DRN 的重建效果较好但同样无法产生较为清晰的纹理细节;相比之下, RDRN 模型始终产生更清晰的边缘和形状,而其他模型可能会给出更模糊的边缘和形状。实验结果证明所提出的 RDRN 能够生成更准确的 SR 重建图片。




图 6 不同 SR 方法的视觉比较

Fig. 6 Visual comparison of different SR methods

2.4.2 重建效果定量分析

为了定量比较 RDRN 模型和其他 SR 模型对遥感图像的重建质量,利用 4 倍重建图像的 PSRN 和 SSIM 得分,对不同 SR 模型的重建结果进行定量对比评价,结果如表 1 所示。

表 1 不同 SR 算法的性能比较<sup>①</sup>

Tab. 1 Performance comparison of different SR algorithm

| 模型         | PSRN/dB      | SSIM         |
|------------|--------------|--------------|
| SRResNet   | 25.96        | 0.657        |
| DRCN       | 29.34        | 0.787        |
| SRGAN      | <u>32.46</u> | 0.872        |
| EDSR       | 30.72        | 0.831        |
| DRN        | 32.28        | <u>0.893</u> |
| RDRN(本文方法) | <b>32.74</b> | <b>0.905</b> |

①粗体数字表示最佳结果,加下划线数字表示次佳结果。

由表 1 可知,RDRN 的重建质量最好。总体而言,无监督 SR 方法 SRGAN 的重建效果果优于 ED-SR 等监督 SR 方法的重建效果,弱监督闭环模型 DRN 的重建效果优于无监督 SR 方法,PSRN 和 SSIM 得分均远高于其他 SR 方法。加入了 RIR 结构的 RDRN 模型 PSRN 值较 DRN 模型高出 0.46 dB, SSIM 值高出 0.012。

2.4.3 模型复杂度对比

模型复杂度在很大程度上会影响模型的应用。在深度学习中,模型复杂度可以通过参数量的大小来衡量,表 2 总结了  $\times 4$  参数和  $\times 8$  参数的 RDRN 模型及其他对比模型的参数量。由表 2 可以看出,使用了 RIR 块的 RDRN 模型的参数量相比于只用 RCAB 模块的 DRN 缩小了约一半。除了 SRResNet 模型,RDRN 模型相对于 DRCN,SRGAN 和 EDSR 模型,模型参数量大幅减小。这表明,在不完全依赖成对数据集的情况下,利用较少的参数,RDRN 仍能获得较好的重建效果,其模型复杂度大幅降低的同时使重建质量得到提升。

表 2 模型参数量对比

Tab. 2 Comparison of model parameters

| 模型         | $\times 4$ 参数/MB | $\times 8$ 参数/MB |
|------------|------------------|------------------|
| SRResNet   | 1.6              | 1.7              |
| DRCN       | 33.3             | 34.8             |
| DRRN       | 33.6             | 34.2             |
| SRGAN      | 11.6             | 10.7             |
| EDSR       | 43.1             | 45.5             |
| DRN        | 18.4             | 20.7             |
| RDRN(本文方法) | 9.8              | 10.0             |

2.5 RDRN 模型分析

2.5.1 消融研究

为了验证对偶方法和二次残差块对遥感图像 SR 性能的影响,根据 4 倍重建 SR 测试图像的 PSNR 得分,针对 RDRN 模型的对偶回归方法和残差网络进行消融研究。如表 3 所示,与原始的监督学习 + RCAB 模型相比,采用对偶回归方法和残差网络的模型在测试集取得更好的重建效果。

表 3 对偶残差方法对 SR 质量的影响

Tab. 3 Influence of double regression scheme on SR performance (dB)

| 模型    | RCAB  | 二次残差块 |
|-------|-------|-------|
| P     | 29.34 | 29.46 |
| P + D | 31.86 | 32.67 |

相对于仅将 RCAB 应用于原始学习网络的 SR 结果,使用二次残差块的原始学习网络的 SR 结果的 PNSR 得分提高了 0.12 dB; 同样仅使用 RCAB,增加了对偶学习网络的结果比只有原始学习网络的重建效果有大幅提高; 在对偶回归的基础上修改 RCAB 为二次残差块后,SR 结果的 PNSR 得分提高了 0.81 dB。这表明,二次残差块比 RCAB 更适应遥感图像 SR,对遥感图像的高频细节有更好的恢复能力; 对偶回归方法能够对原网络形成约束,减少映射函数的空间,从而提高 HR 图像的重建效果。

2.5.2  $\lambda$  对 RDRN 的影响

为了研究对偶回归损失的权重  $\lambda$  对遥感图像

SR 重建性能的影响,根据 4 倍重建 SR 测试图像的 PSNR 得分,针对 RDRN 模型的损失函数式(1)中超参数  $\lambda$  的变化进行实验,实验结果如表 4 所示。由表 4 可以看出,当  $\lambda$  从 0.001 依次增加到 0.1 时,对偶回归的损失逐渐变得重要,为模型提供强大的监督反馈作用;继续将  $\lambda$  进一步增大到 1 甚至 10,对偶回归的损失项对网络整体的损失反而产生负面影响,从而影响模型最终性能。为了平衡原始学习和对偶回归以获得最好的重建效果,本文实验中将  $\lambda$  设为 0.1。

表 4 对偶损失权重  $\lambda$  对 SR 性能的影响

Tab. 4 Influence of super parameter  $\lambda$  in equation (1) (dB)

| $\lambda$ | 0.001 | 0.01  | 0.1   | 1.0   | 10    |
|-----------|-------|-------|-------|-------|-------|
| PSNR      | 32.57 | 32.61 | 32.67 | 32.51 | 32.37 |

### 2.5.3 $p$ 对自适应算法的影响

训练过程中不成对图像在训练数据集中所占的比例  $p$  对训练所得的模型重建效果也有较大影响。根据 4 倍重建 SR 测试图像的 PSNR 得分,针对 RDRN 模型训练过程中设置不同的  $p$  值,研究  $p$  对遥感图像 SR 重建性能的影响,分别设置  $p$  的值为 0,0.2,0.3,0.4,0.6,0.8 和 1 在相同的训练条件下训练 50 轮,获得相应的训练曲线。如图 8 所示。




图 8 不成对数据占比  $p$  对 4 倍重建 SR 性能的影响

Fig. 8 Influence of the proportion of unpaired data on reconstructed SR of 4 times

相比于仅能学习 LR - HR 图像间潜在非线性映射的原始正向模型(即  $p = 0$  时),增加能够利用非成对遥感图像的低频信息生成 HR 非监督学习的模型( $p \neq 0$ )能够获得更好的性能,其中  $p = 0.3$  时模型的重建性能最佳。因此,本文实验中设置  $p = 0.3$  以获得最佳性能。

## 3 结论

为了提高利用神经网络对遥感图像的 SR 重建质量和模型的泛化能力,在研究 SR 重建常用模型的基础上,提出了一种基于 DRN 网络和 RCAN 网络

的残差对偶回归网络 RDRN。该网络结构结合对偶学习思想,设置两个互逆的学习网络形成一个闭环,对 LR - HR 间的映射空间形成约束,以减少可能函数的空间。其中:

1) 正向学习网络基于 U - Net 网络结构,结合 RIR 模块,允许丰富的低频信息通过多个跳跃连接直接进行传播,保证浅层网络同样拥有良好的学习能力和泛化能力。

2) 对偶回归网络则将由正向网络学习得到的 HR 图像进行下采样,通过将下采样得到的 LR 图像与正向网络输出的多尺度 SR 图像进行对比,与正向学习网络相互提供反馈,相互提高。

3) 采用周期一致性损失函数,同时使用真实的不成对 LR 遥感数据和成对的 LR - HR 合成数据,使 SR 模型能在适应现实未配对数据的同时兼顾退化先验,重建出更符合实际应用的高质量 HR 图像。

实验结果表明,RDRN 在对遥感图像的 SR 重建中表现良好,能够为遥感图像重建出较清晰的细节纹理信息,且相对于 DRN 等其他 SR 网络,模型参数量较少,在遥感图像 SR 领域的具有巨大潜力。此外,未来 RDRN 网络还可拓展到更多尺度的 SR 重建,如 8 倍放大效果下的重建等,但由此引发重建图像的真实性仍待讨论。

## 参考文献 (References):

- [1] 张 艳,卢宜铭,刘国瑞,等. 多路径特征融合的遥感图像超分辨率重建算法[J]. 遥感信息,2021,36(2):46-53.  
Zhang Y, Lu X M, Liu G R, et al. Super resolution reconstruction algorithm of remote sensing image based on multi-path feature fusion[J]. Remote Sensing Information, 2021, 36(2):46-53.
- [2] Harris J L. Diffraction and resolving power[J]. Journal of the Optical Society of America, 1964, 54(7):931-936.
- [3] 苏 衡,周 杰,张志浩. 超分辨率图像重建方法综述[J]. 自动化学报,2013,39(8):1202-1213.  
Su H, Zhou J, Zhang Z H. Review of super resolution image reconstruction methods[J]. Acta Automatica Sinica, 2013, 39(8):1202-1213.
- [4] Dong C, Loy C C, He K M, et al. Learning a deep convolutional network for image super-resolution[C]//David Fleet. Proceedings of European Conference on Computer Vision. Zurich: Computer Vision - ECCV, 2014, 184-199.
- [5] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks[C]//IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2016, 1646-1654.
- [6] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//IEEE. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016, 770-778.
- [7] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution[C]//IEEE. Proceedings of the IEEE

- Conference on Computer Vision and Pattern Recognition. Las Vegas; IEEE, 2016; 1637 – 1645.
- [8] Tai Y, Yang J, Liu X. Image super – resolution via deep recursive residual network [C]//IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu; IEEE, 2017; 3147 – 3155.
- [9] 刘 帅, 朱亚杰, 薛 磊. 一种结合稀疏表示和纹理分块的遥感影像超分辨率方法[J]. 武汉大学学报(信息科学版), 2015, 40(5): 578 – 582.
- Liu S, Zhu Y J, Xue L. A super resolution method for remote sensing image based on sparse representation and texture segmentation [J]. Geomatics and Information Science of Wuhan University, 2015, 40(5): 578 – 582.
- [10] 吴 琼, 田 越, 周春平, 等. 遥感图像超分辨率研究的现状和发展[J]. 测绘科学, 2008, 33(6): 66 – 69, 15.
- Wu Q, Tian Y, Zhou C P, et al. Current situation and development of research on super resolution of remote sensing image [J]. Surveying and Mapping Science, 2008, 33(6): 66 – 69, 15.
- [11] Shocher A, Cohen N, Irani M. “Zero – shot” super – resolution using deep internal learning [C]//IEEE. Proceedings of the 2018 IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City; IEEE, 2018; 3118 – 3126.
- [12] Bulat A, Yang J, Tzimiropoulos G. To learn image super – resolution, use a GAN to learn how to do image degradation first [C]//Vittorio Ferrari. Proceedings of the European Conference on Computer Vision). Munich; ECCV, 2018; 185 – 200.
- [13] Yi Z L, Zhang H, Tan P, et al. DualGAN: unsupervised dual learning for image – to – image translation [C]//IEEE. Proceedings of the IEEE International Conference on Computer Vision. Venice; ICCV, 2017; 2868 – 2876.
- [14] Ledig C, Theis L, Huszár F, et al. Photo – realistic single image super – resolution using a generative adversarial network [C]//IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu; IEEE, 2017; 4681 – 4690.
- [15] Simonyan K, Zisserman A. Very deep convolutional networks for large – scale image recognition [J/OL]. <https://arxiv.org/abs/1409.1556v3>.
- [16] Yuan Y, Liu S, Zhang J, et al. Unsupervised image super – resolution using cycle – in – cycle generative adversarial networks [C]//IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops; IEEE, 2018; 701 – 710.
- [17] Zhu J Y, Park T, Isola P, et al. Unpaired image – to – image translation using cycle – consistent adversarial networks [C]//IEEE. Proceedings of the IEEE International Conference on Computer Vision. Venice; IEEE, 2017; 2223 – 2232.
- [18] 陈赛健, 朱远平. 基于生成对抗网络的文本图像联合超分辨率与去模糊方法[J]. 计算机应用, 2020, 40(3): 859 – 864.
- Chen S J, Zhu Y P. Text image joint super resolution and deblurring method based on generative countermeasure network [J]. Computer Applications, 2020, 40(3): 859 – 864.
- [19] 李 欣, 韦宏卫, 张洪群. 结合深度学习的单幅遥感图像超分辨率重建[J]. 中国图象图形学报, 2018, 23(2): 209 – 218.
- Li X, Wei H W, Zhang H Q. Super resolution reconstruction of single remote sensing image combined with deep learning [J]. Chinese Journal of Image Graphics, 2018, 23(2): 209 – 218.
- [20] Guo Y, Chen J, Wang J, et al. Closed – loop matters: Dual regression networks for single image super – resolution [C]//IEEE. IEEE Conference on Computer Vision and Pattern Recognition. Seattle; CVPR, 2020; 5407 – 5416.
- [21] Zhang Y, Li K, Li K, et al. Image super – resolution using very deep residual channel attention networks [C]//Vittorio Ferrari. Proceedings of the European Conference on Computer Vision. Munich; ECCV, 2018; 286 – 301.
- [22] Fu J, Liu J, Tian H, et al. Dual attention network for scene segmentation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Long Beach; IEEE, 2019; 3141 – 3149.
- [23] Yu Z, Qiang Y. An overview of multi – task learning [J]. National Science Review, 2018, 5(1): 30 – 43.
- [24] 周飞燕, 金林鹏, 董 军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229 – 1251.
- Zhou F Y, Jin L P, Dong J. Review of convolutional neural networks [J]. Chinese Journal of Computers, 2017, 40(6): 1229 – 1251.
- [25] 张 顺, 龚怡宏, 王进军. 深度卷积神经网络的发展及其在计算机视觉领域的应用[J]. 计算机学报, 2019, 42(3): 453 – 482.
- Zhang S, Gong Y H, Wang J J. Development of deep convolutional neural network and its application in computer vision [J]. Chinese Journal of Computers, 2019, 42(3): 453 – 482.
- [26] Boguszewski A, Batorski D, Ziemba – Jankowska N, et al. LandCover.ai: Dataset for automatic mapping of buildings, woodlands, water and roads from aerial imagery [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville; IEEE, 2021; 1102 – 1110.
- [27] Li K, Wan G, Cheng G, et al. Object detection in optical remote sensing images: A survey and a new benchmark [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 159: 296 – 307.
- [28] Wan M, Yazid, et al. A review of image quality assessment (IQA): SNR, GCF, AD, NAE, PSNR, ME [J]. Journal of Advanced Research in Computing and Applications. 2017, 7(1): 1 – 7.

## Residual dual regression network for super – resolution reconstruction of remote sensing images

SHANG Xiaomei, LI Jiatian, LYU Shaoyun, YANG Ruchun, YANG Chao

(Faculty of Land Resources Engineering, Kunming University of Science and Technology, Kunming 650000, China)

**Abstract:** In order to solve the problem of poor model generalizing ability in real super – resolution reconstruction of remote sensing images, which is easily caused by the use of artificial high – low resolution image pairs, combined

with the residual in residual (RIR) module of residual channel attention network (RCAN), dual regression network (DRN) is improved, and residual dual regression network (RDRN) is proposed. Ten thousand  $512 \times 512$  pixel images from LandCover.ai and DIOR aerial image data sets were selected to form the sample data set for training and testing the network, and the reconstruction results were compared with those of other super-resolution network models. The experimental results show that RDRN has an excellent performance in both reconstruction quality and model parameters. It can achieve a better super segmentation reconstruction effect with lower model complexity and has good generalization ability for different low-resolution remote sensing images.

**Keywords:** remote sensing image; super-resolution reconstruction; dual regression; residual channel attention; closed network

(责任编辑: 张 仙)