

基于感受野扩大与解码特征增强的 U 型去云网络

梁 星¹
LIANG Xing

摘 要

U 型架构的网络在遥感影像去云中应用广泛, 并取得了显著效果。然而, 大多数 U 型架构去云算法编解码之间传输的仅是单一感受野特征, 导致对应层级解码层接收到的信息受限, 去云影像存在空间细节信息的损失。此外, 大多数 U 型网络的输出仅以解码层中尺寸最大的特征为出口, 忽略了对其他各层级解码特征的有效利用, 导致纹理结构信息重构不理想。为了解决这些问题, 提出了一个基于感受野扩大与解码特征增强的 U 型去云网络。具体来说, 在各级编解码层之间依次加入不同数量感受野自适应扩大模块, 实现编解码之间传输信息的感受野自适应扩大; 在解码层不同层级之间逐级加入层级交互模块并上采样至输出尺寸大小再进行通道串联, 实现解码特征的增强。此外, 现有公开去云数据集未能考虑不同云层厚度对去云的影响, 对此, 提出了 1 个含有薄云、中云、厚云 3 个子集的合成数据集, 每个子集包含 5 种地物类型。在所提出的合成数据集和 1 个公开的真实数据集上, 与近年来提出的 5 种优秀算法相比, 所提出的方法取得了最好的客观评价指标和视觉效果。

关键词

感受野扩大; 解码特征增强; U 型架构; 合成数据集

doi: 10.3969/j.issn.1672-9528.2024.06.021

0 引言

遥感作为获取地球表面几何和物理信息最重要的手段之一^[1], 在气象、测绘、水文、军事、农业、林业等各个领域获得了广泛的应用。然而, 地球表面 50% 以上的区域被云层遮盖, 严重影响了遥感影像在目标定位、图像解译、数据融合、目标检测等领域的应用^[2]。因此, 遥感影像去云这一任务具有非常重要的意义。

传统的遥感去云方法大致可以分为四种: 基于空间的、基于光谱的、基于多时相的、基于多源的。基于空间的方法^[3-4]利用单幅影像中无云区域和有云区域像素的相似性去恢复有云区域。基于光谱的方法^[5-6]利用不同光谱波段之间的相关性以及部分多光谱波段, 能够穿透薄云的假设去云。基于多时相的方法^[7-8]利用同一区域的参考图像(无云)和目标图像(有云)相关性, 去重建目标图像有云区域。基于多源的方法^[9-10]利用其他类型传感器数据作为辅助数据, 去恢复有云区域。然而, 上述传统遥感去云方法分别会受到无云区域和有云区域相似程度不高、云层较厚波段穿透能力

有限、图像间几何配准存在误差、辅助数据存在噪声等因素的影响, 去云效果不理想。

近年来, 为了解决遥感去云这一具有挑战性的任务, 提出了几种基于 U 型架构的卷积神经网络去云方法。U 型架构网络由编码器和解码器组成, 编码器逐级下采样提取影像深层特征, 解码器将深层特征逐级上采样并接收对应层级编码器传递过来的特征, 最终得到去云后的影像。这些网络在合成或真实数据集上进行训练并取得了一定的效果, 但是它们也存在以下问题。

(1) 大多数基于 U 型架构的方法^[11-12]编解码层之间的传输仅是单一感受野特征, 导致对应层级解码层接收信息受限, 使得重构影像存在空间细节的损失。

(2) 大多数基于 U 型架构的方法^[13-14]仅以解码层中尺寸最大的特征为出口, 忽略了对其他各层级解码特征的有效利用, 使得网络整体重构能力不足, 无法更好地恢复影像的纹理结构信息。

(3) 大多数已有去云数据集^[15-16]未能考虑不同云层厚度对去云的影响, 未能更好地模拟不同云层厚度的有云影像。

为了解决上述问题, 本文提出了一个基于感受野扩大与解码特征增强的 U 型去云网络。具体来说, 在各层级编解码层之间分别加入不同数量的感受野自适应扩大模块, 实现编解码之间传输特征感受野自适应扩大, 从而减少编解码之间信息传输时空间细节的损失; 在解码层不同层级之间逐级加

1. 三峡大学计算机与信息学院 湖北宜昌 443000
2. 水电工程智能视觉监测湖北省重点实验室 湖北宜昌 443000
[基金项目] 水电工程智能视觉监测湖北省重点实验室建设 (2019ZYYD007)

入层级交互模块并上采样至输出尺寸大小，然后进行通道串联，充分利用尺寸最大以及其他各层级解码特征，减少解码特征上采样过程中的信息丢失，实现解码特征的增强。此外，手工选取包含 4 种季节类型以及 5 种地物类型的遥感影像，通过设置不同云层厚度，构建一个含有薄云、中云、厚云 3 个子集的合成云数据集，更好地表征真实世界中不同云层厚度的有云影像。

1 本文方法

1.1 网络框架

本文提出的基于感受野扩大与解码特征增强的 U 型去云网络整体框架如图 1 所示。网络由预处理模块、编码器、感受野自适应扩大模块 (receptive field adaptive expansion module, RFAM)、解码器、解码特征增强模块 (decoding feature enhancement module, DFEM) 以及后处理模块组成。编码器提取到的特征经过感受野自适应扩大模块 (RFAM) 后再传递给解码器；解码器解码得到的各级特征经过解码特征增强模块以及后处理模块后得到去云后的影像。

预处理模块采用常见的旋转、翻转操作以丰富输入网络样本多样性，使用 1 个步长为 1 的 3×3 卷积将输入影像的通道数由 3 维调整至 32 维。编码器每个层级由 3 个步长为 1 和 1 个步长为 2 的 3×3 卷积串联组成。使用步长为 2 的卷积是为了进行下采样操作，使用 3 个步长为 1 的卷积串联是为了提取更充分特征。解码器每个层级由 3 个步长为 1 的 3×3 卷积以及 1 个步长为 2 的转置卷积串联组成。使用步长为 2 的转置卷积是为了进行上采样操作，使用 3 个步长为 1 的卷积进行串联是为了增强解码能力。后处理模块使用 1 个步长为 1 的 3×3 卷积将特征通道数由 32 维调整至 3 维，得到去云后的影像。




图 1 网络总体结构

1.2 感受野自适应扩大模块 (RFAM)

为了扩大编解码之间传输特征的感受野，减少编解码之间信息传输的损失，以及考虑到 U 型架构的网络由浅至深各级特征的尺寸逐渐减小，在编解码之间依次添加 4 个、3 个、2 个、1 个感受野自适应扩大模块 (RFAM)。单个感受野自适应扩大模块 (RFAM) 由空洞卷积模块和自适应特征融合模块 (adaptive feature fusion module, AFFM) 组成。

空洞卷积模块由 3 个并行能获得大小为 5×5 、 7×7 、 13×13 感受野的空洞卷积组成。d(1) 表示空洞率为 1 的 3×3 卷积，能够获得大小为 5×5 的感受野；d(2) 表示空洞率为 2 的 3×3 卷积，d(1) 和 d(2) 串联能够获得大小为 7×7 的感受野；d(3) 表示空洞率为 3 的 3×3 卷积，d(1)、d(2)、d(3) 串联，能够获得大小为 13×13 的感受野。上述感受野下的区域为连续区域，没有缝隙。

自适应特征融合模块 (AFFM) 的主要作用是给 3 种不同大小的感受野特征分配不同权重。分配过程如公式 (1) ~ (3) 所示，首先对每种特征在通道方向进行全局平均池化，然后使用两次全连接将通道压缩成 1 维。

$$F_{1out} = W_2(ReLU(W_1(Gap(f_{in}^{(1)})) + b_1)) + b_2 \quad (1)$$

$$F_{2out} = W_4(ReLU(W_3(Gap(f_{in}^{(2)})) + b_3)) + b_4 \quad (2)$$

$$F_{3out} = W_6(ReLU(W_5(Gap(f_{in}^{(3)})) + b_5)) + b_6 \quad (3)$$

式中： $f_{in}^{(1)}$ 表示 d(1) 提取到的特征， $f_{in}^{(2)}$ 表示 d(1) 和 d(2) 串联提取到的特征， $f_{in}^{(3)}$ 表示 d(1)、d(2) 和 d(3) 串联提取到的特征。Gap 表示通道方向全局平均池化，ReLU 表示 ReLU 激活函数， W_1 、 W_2 、 W_3 、 W_4 、 W_5 、 W_6 、 b_1 、 b_2 、 b_3 、 b_4 、 b_5 、 b_6 表示可学习参数。利用第一个全连接将特征降维至之

前的四分之一，利用第二个全连接将特征降维至 1 维。然后利用 Softmax 函数计算三种感受野特征的权重，其公式为：

$$\text{weight}_1, \text{weight}_2, \text{weight}_3 = \text{Softmax}(F_{1out}, F_{2out}, F_{3out}) \quad (4)$$

式中： $\text{weight}_1 + \text{weight}_2 + \text{weight}_3 = 1$ 。

然后，将三种感受野特征的权重与每种特征相乘再相加，再加上最开始的输入特征 F_{in} ，得到感受野自适应扩大后的输出 F_{out} ，其公式为：

$$F_{out} = \text{weight}_1 \cdot f_{in}^{(1)} + \text{weight}_2 \cdot f_{in}^{(2)} + \text{weight}_3 \cdot f_{in}^{(3)} + F_{in} \quad (5)$$

1.3 解码特征增强模块 (DFEM)

为了更好地利用解码层各级解码

特征,减少解码特征上采样过程中的信息丢失,增强网络整体重构能力,本文设计了解码特征增强模块(DFEM)。解码特征增强模块(DFEM)由层级交互模块(hierarchical interaction module, HIM)以及后续的上采样、通道串联组成。解码特征增强模块(DFEM)不是直接将解码层的每级特征上采样至最大尺寸大小,而是从尺寸最小的特征开始与相邻层特征通过层级交互模块(HIM)逐级进行交互,然后再上采样至最大尺寸大小。层级交互模块(HIM)的构成如图2所示。




图2 层级交互模块

设 $L=[L_1, L_2, \dots, L_N]$, $H=[H_1, H_2, \dots, H_M]$, 其中 L 表示浅层特征, H 表示深层特征, N 与 M 分别表示浅层特征和深层特征的通道数。将浅层特征和深层特征分别进行卷积和反卷积操作,特征图的大小统一调整为 $C \times H \times W$, L 卷积后的结果记为 L^* , H 反卷积后的结果记为 H^* , 其公式为:

$$L^* = \text{Conv}(L) \quad (6)$$

$$H^* = \text{DeConv}(H) \quad (7)$$

然后,对 L^* 与 H^* 通道维度和空间维度分别进行平均池化,通道维度池化结果记为 L_{gap}^* 、 H_{gap}^* ,空间维度池化结果记为 $L_{\text{gap-1}}^*$ 、 $H_{\text{gap-1}}^*$ 。对通道维度池化结果 L_{gap}^* 、 H_{gap}^* 分别输入 Sigmoid 激活函数,得到不同通道的权重。

$$\text{Sig_}L^* = \text{Sigmoid}(\text{Gap}(L^*)) \quad (8)$$

$$\text{Sig_}H^* = \text{Sigmoid}(\text{Gap}(H^*)) \quad (9)$$

将 L^* 与 H^* 空间维度池化结果 $L_{\text{gap-1}}^*$ 、 $H_{\text{gap-1}}^*$ 分别进行复制,使其通道大小由 1 维变成 C 维,得到 $L_{\text{gap-C}}^*$ 、 $H_{\text{gap-C}}^*$ 。然后进行交叉相乘,即将 L^* 的通道权重 $\text{Sig_}L^*$ 与 H^* 复制

后的空间特征 $H_{\text{gap-C}}^*$ 相乘,将 H^* 的通道权重 $\text{Sig_}H^*$ 与复制后的空间特征 $L_{\text{gap-C}}^*$ 相乘,并将两个乘积结果输入 Softmax 函数得到三维空间内浅层特征和深层特征对应位置的权重,其公式为:

$$\text{weight}_1, \text{weight}_2 = \text{Softmax}(\text{Mul}(\text{Sig_}L^*, H_{\text{gap-C}}^*), \text{Mul}(\text{Sig_}H^*, L_{\text{gap-C}}^*)) \quad (10)$$

然后将各自权重与自身特征进行相乘后相加,得到两个层级特征的交互结果,其公式为:

$$\text{Out_L_H} = \text{weight}_1 \cdot L^* + \text{weight}_2 \cdot H^* \quad (11)$$

通过在通道维度和空间维度的平均池化操作,得到全局

信息和空间细节信息。将浅层特征的激活全局信息与深层特征的空间细节信息进行相乘,以及将深层特征的激活全局信息与浅层特征的空间细节信息进行相乘,能够得到浅层向深层以及深层向浅层的全局局部信息融合,对它们进行 Softmax 操作,可以获得两组权重矩阵。两组权重矩阵与调整到相同大小的浅层和深层特征相乘,能够抑制不重要信息,增强有用信息。

1.4 损失函数

在网络的训练阶段,使用平滑 L1 损失^[17]、对抗损失^[18]、感知损失^[19]和多尺度结构相似性损失作为网络模型的优化目标。平滑 L1 损失与 L1 损失

相比,在零点附近更加平滑,与 L2 损失相比,对异常值敏感性较低,在图像重建任务中优于 L1、L2 损失;对抗损失,在恢复图像逼真细节方面有很大帮助;感知损失,即在训练好的 VGG16 模型上计算不同特征层的去云图像和无云图像的 L2 损失,可以实现从纹理到高阶语义的多层约束;多尺度结构相似性损失,能够使网络生成的去云影像具有更高的结构相似性。总损失函数 L 的组成公式为:

$$L = \gamma_1 \cdot L_{\text{SmoothL1}} + \gamma_2 \cdot L_{\text{adv}} + \gamma_3 \cdot L_{\text{perc}} + \gamma_4 \cdot L_{\text{MS-SSIM}} \quad (12)$$

式中: L_{SmoothL1} 表示平滑 L1 损失, L_{adv} 表示对抗损失, L_{perc} 表示感知损失, $L_{\text{MS-SSIM}}$ 表示多尺度结构相似性损失, γ_1 取值为 1, γ_2 取值为 0.000 5, γ_3 取值为 0.01, γ_4 取值为 0.5。

1.5 合成云数据集制作

由于现实中无法准确捕获同一场景的无云图像和多云图像^[20],目前制作配对数据集主要方式有两种:(1)利用大气散色模型制作合成配对数据集,通过大气散色模型将提取到的云层添加到清晰影像中^[21];(2)将时间间隔不超过

2 个重访周期的无云影像作为有云影像的参考^[22-23]。然而，现有的不管是合成配对数据集还是有时间间隔真实配对数据集，都没有考虑云层厚度对去云的影响，没有按照云层厚度划分数据集。

为了更好地表征真实世界中不同云层厚度的有云影像，本文使用 RSDehazeNet 所公开的方法，通过设置 0.4、0.7、1.0 的云层厚度，构建一个含有薄云、中云、厚云 3 个子集的合成数据集，每个子集包含森林、居民区、海洋、平原、河流 5 种地物类型遥感影像。无云影像和云层均是选自 Landsat8 卫星所拍摄影像。数据集总共有 3000 对无云和合成云影像，每个子集的数量为 1000 对，训练集、测试集、验证集按照 8:1:1 比例划分。选取 4、3、2 波段合成为 RGB 影像，无重叠裁切为 512×512 大小的瓦片。合成云数据集已开源。图 3 展示了部分合成云示例。图 3 第 1 行为地面真实的无云影像，从左往右依次是森林、居民区、海洋、平原、河流 5 种地物类型，第 2～4 行分别为薄云、中云、厚云。



图 3 合成云示例

2 实验结果与分析

2.1 数据准备

为了证明所提算法在合成数据集和真实数据集上都有较好的性能，本文在 1 个合成数据集和 1 个真实数据集上进行实验。合成数据集采用作者提出的含有薄、中、厚 3 个子集的合成云数据集，真实数据集使用公开的 Rice 数据集。Rice 数据集由 Rice1 和 Rice2 两个子集组成。Rice1 数据集由 Google Earth 采集，通过设置云层是否显示来获得有云或无云影像。Rice2 数据集取自 Landsat8 卫星，其构建方法是

人工选取间隔小于 15 天的同一位置无云影像和有云影像。由于 Rice 数据集没有划分训练集、测试集、验证集，本文按照 8:1:1 的比例随机进行划分。

本文所提出的合成数据集能够与 Rice 数据集进行很好的互补，Rice1 数据集中的云层为均匀的薄云，而本文提出合成数据集为非均匀云，且这两个数据集的地面真实影像均为已知；Rice2 数据集中云层大多数是厚云，其地面真值并不可知，而是以两个重访周期内的影像作为地面真值的近似。

2.2 实验设置

本文提出的基于感受野自适应扩大与解码特征增强的 U 型去云网络是基于 PyTorch 框架实现，在 Windows 环境下使用 1 块 NVIDIA-GeForce-RTX-3090 GPU 进行训练。采用 Adam 算法优化，初始学习率设置为 0.000 1，使用多步长衰减方式调整学习率，Gamma=0.5，在 800 轮、900 轮、950 轮的时候进行调整，训练总轮数为 1000 轮。

2.3 实验结果

2.3.1 定量评价

为了进行更加全面的定量评价，采用了 5 种广泛使用的定量评价指标：①峰值信噪比（peak signal to noise ratio, PSNR）；②结构相似性（structural similarity, SSIM）；③相关系数（correlation coefficient, CC）；④通用图像质量指数（universal image quality index, UIQI）；⑤均方根误差（root mean squared error, RMSE）。

表 1 和表 2 是本文提出去云方法与近 5 年 5 种基于深度学习方法的定量比较结果。

表 1 各种算法在合成数据集上的定量比较

Datasets	Indicators	GridDehaze (ICCV2019)	MSBDN (CVPR2020)	UHD (CVPR2021)	DCI (TGRS2022)	PSMB (TGRS2023)	Ours
薄云	PSNR ↑	28.433	27.941	25.607	28.172	27.940	30.249
	SSIM ↑	0.947 3	0.914 0	0.874 7	0.931 7	0.936 6	0.956 4
	CC ↑	0.941 4	0.932 8	0.902 9	0.942 9	0.956 3	0.963 8
	UIQI ↑	0.898 4	0.880 3	0.842 3	0.905 4	0.914 3	0.930 9
	RMSE ↓	7.057 3	7.215 7	8.118 4	7.251 0	7.787 2	6.474 9
中云	PSNR ↑	28.437	27.665	25.354	28.029	27.636	30.039
	SSIM ↑	0.941 3	0.898 2	0.852 0	0.925 2	0.928 5	0.950 2
	CC ↑	0.943 6	0.928 1	0.897 5	0.941 5	0.954 0	0.961 5
	UIQI ↑	0.902 3	0.878 1	0.832 2	0.903 8	0.916 5	0.925 0
	RMSE ↓	7.006 7	7.280 9	8.103 8	7.256 3	7.915 8	6.454 0
厚云	PSNR ↑	27.219	26.057	24.098	26.542	26.810	28.791
	SSIM ↑	0.911 8	0.840 4	0.792 8	0.887 3	0.899 6	0.927 0
	CC ↑	0.922 6	0.893 2	0.854 7	0.911 3	0.938 5	0.948 7
	UIQI ↑	0.874 4	0.817 2	0.783 5	0.852 4	0.890 0	0.909 1
	RMSE ↓	7.375 3	7.848 4	8.583 3	7.753 0	8.085 1	6.881 8

注：第一名为加粗字体，第二名为带下划线字体，第三名为斜体。

表 2 各种算法在真实数据集上的定量比较

Datasets	Indicators	GridDehaze (ICCV2019)	MSBDN (CVPR2020)	UHD (CVPR2021)	DCI (TGRS2022)	PSMB (TGRS2023)	Ours
Rice1	PSNR $\uparrow$	31.841	<u>32.250</u>	29.846	<u>32.037</u>	30.050	32.678
	SSIM $\uparrow$	<u>0.951 0</u>	0.943 5	0.928 9	<u>0.950 5</u>	0.931 9	0.957 2
	CC $\uparrow$	0.976 3	<u>0.976 3</u>	0.954 9	<u>0.977 7</u>	0.961 8	0.977 9
	UIQI $\uparrow$	0.916 5	<u>0.923 9</u>	0.880 1	<u>0.919 9</u>	0.866 3	0.930 8
	RMSE $\downarrow$	6.083 9	<u>5.911 0</u>	6.681 1	<u>5.994 5</u>	<u>5.994 5</u>	5.681 3
Rice2	PSNR $\uparrow$	32.957	<u>33.075</u>	30.936	32.900	32.029	34.406
	SSIM $\uparrow$	0.877 1	0.870 3	0.860 9	<u>0.899 9</u>	<u>0.880 7</u>	0.900 1
	CC $\uparrow$	0.895 3	0.901 5	0.890 3	<u>0.910 4</u>	<u>0.909 6</u>	0.921 5
	UIQI $\uparrow$	<u>0.382 4</u>	0.365 7	0.331 7	<u>0.367 6</u>	0.325 4	0.386 6
	RMSE $\downarrow$	<u>5.202 1</u>	<u>5.122 7</u>	5.708 0	5.308 3	5.676 7	4.686 4

注：第一名为加粗字体，第二名为带下划线字体，第三名为斜体。

其中第一名为加粗字体，第二名为带下划线字体，第三名为斜体。在合成的薄云、中云、厚云 3 个子集中，本文所提网络的 PSNR 值比第二名均高出 1.5 dB 以上，在真实的 Rice2 子集中，本文所提网络的 PSNR 值比第二名高出 1.3 dB。

2.3.2 定性评价

图 4 展示了各种算法在合成数据集上的可视化结果，图 5 展示了各种算法在真实数据集上的可视化结果。




图 4 各种算法在合成数据集上的可视化结果




图 5 各种算法在真实数据集上的可视化结果

为了使读者更加直观地感受不同去云的方法与地面真值之间的差异，以及对不同去云方法进行相互比较，本文采用矩形框标注和差距图对比相结合的方式去展示。有矩形框标注的重点关注标注范围内不同算法去云结果的差异，没有矩形框标注的需结合差距图进行对比。从图 4 和图 5 图例可知，差距图中颜色越靠近 0.00 这一端表示去云结果与地面真值的差距越小，颜色越靠近 0.15 这一端表示去云结果与地面真值差距越大。总体而言，我们提出的算法去云影像与地面真值最为接近。

具体而言，在薄云这个子集中 UHD[26] 算法差距图中差值大的面积最大，其生成的去云影像在矩形框标准的范围内出现了亮度升高的现象。此为云残留所导致，GridDehaze^[25]算法和 MSBDN^[26]算法也出现了类似情况。在中云这个子集中，UHD 算法、DCI^[27]算法的去云影像出现了大范围亮度升高的现象，PSMB 算法出现了大范围颜色加深的情况，其他算法也出现了不同程度的云残留。随着云层的厚度增加，所有算法去云能力均出现下降，但是本文提出的算法依然能保持较好的去云能力。在厚云数据子集中，矩形框范围内的小块居民地只有本文提出的算法保持了较好的效果，其他算法均恢复失败。在 Rice1 数据子集中，GridDehaze 算法、MSBDN 算法、PSMB 算法、UHD 算法和 DCI 算法去云结果均存在不同程度的色差。在 Rice2 数据子集中，UHD 算法出现了大量的云残留。针对矩形框标注范围内的地物形状，本文提出的算法与地面真值最为接近。

2.3.3 消融实验

为了验证提出的去云方法中各个模块的有效性，本文按照网络结构和模块创新的思路设计了消融实验，共包含 4 个实验：（1）ENDN（Encoder and Decoder）表示网络仅包含编码器和解码器；（2）ENDN_RFAM（Encoder and Decoder, Adaptive Feature Fusion Module），表示在编码器和解码器之间加入了感受野自适应扩大模块，也就是本文所提的第 1 个创新点；（3）ENDN_DFEM（Encoder and Decoder, Decoding Feature Enhancement Module），表示在（1）的基础上加入了解码特征增强模块，也就是本文所提的第 2 个创新点；（4）ENDN_RFAM_DFEM（Encoder and Decoder, Adaptive Feature Fusion Module, Decoding Feature Enhancement Module），在（1）的基础上同时加入本文提出的两个创新点，也就是本文的最终模型。消融实验在合成数据集的厚云子集与真实数据集的 Rice2 子集上进行，对比 PSNR 和 SSIM 两种指标，具体实验指标如表 3 所示。

表 3 在厚云子集与 Rice2 子集的 PSNR 和 SSIM 结果

模型	厚云		Rice2	
	PSNR	SSIM	PSNR	SSIM
ENDN	26.398	0.884 9	32.527	0.877 3
ENDN_RFAM	27.731	0.910 1	33.782	0.885 9
ENDN_DFEM	27.474	0.903 6	33.466	0.885 6
ENDN_RFAM_DFEM	28.791	0.927 0	34.406	0.900 1

在合成数据集中的厚云子集中，对照 ENDN 和 ENDN_RFAM 可以发现，增加感受野自适应扩大模块（RFAM）可以较大幅度地提高网络性能，PSNR 能够提高 1.333 dB；对照 ENDN 和 ENDN_DFEM 可以发现，增加解码特征增强模块（DFEM），PSNR 可以提高 1.076 dB。在真实数据集 Rice2 子集中，增加感受野自适应扩大模块（RFAM），PSNR 可以提高 1.255 dB；增加解码特征增强模块（DFEM），PSNR 可以提高 0.939 dB。

3 结论

本文针对大多数 U 型架构去云算法的编解码之间传输仅是单一感受野特征以及输出仅以解码层中尺寸最大特征为出口，忽略了其他各层级解码特征的有效利用这两个问题，提出了一种基于感受野自适应扩大与解码特征增强的 U 型去云网络。另外，针对现有公开去云数据集未能考虑不同云层厚度对去云的影响，制作了 1 个含有薄云、中云、厚云 3 种厚度的合成数据集。对比近年来提出的 5 种基于深度学习算法，本文的算法取得了最好的去云效果。但是，随着云层的厚度增加，算法的去云效果逐渐下降，需要进一步探索其他去云方式，比如借助辅助数据、采取无监督的方式等，使厚云重构的去云效果更加理想。

参考文献:

- [1]YUAN K, MENG G, CHENG D, et al.Efficientcloud detection in remote sensing images using edge-aware segmentationnetwork and easy-to-hard training strategy[C]//2017 IEEE International Conference on Image Processing(ICIP). Piscataway:IEEE,2017:61-65.
- [2]JI S, DAI P, LU M, et al.Simultaneous cloud detection and removal from bitemporal remote sensing images using cascade convolutional neural networks[J].IEEE transactions on geoscience and remote sensing,2021,59(1):732-748.
- [3]MAALOUF A, CARRE P, AUGEREAU B, et al.A bandelet-based inpainting technique for clouds removal from remotely sensed images[J].IEEE transactions on geoscience and remote sensing, 2009,47(7):2363-2371.
- [4]YU C, CHEN L, SU L, et al.Kriging interpolation method and its application in retrieval of MODIS aerosol optical depth[C]//2011 19th International Conference on Geoinformatics,[v.3].Piscataway:IEEE,2011:1-6.
- [5]XU M, JIA X, PICKERING M.Automatic cloud removal for Landsat 8 OLI images using cirrus band[C]//2014 IEEE Geoscience and Remote Sensing Symposium.Piscataway: IEEE, 2014:2511-2514.
- [6]LV H, WANG Y, SHEN Y.An empirical and radiative transfer model based algo rithm to remove thin clouds in visible bands[J].Remote sensing of environment,2016,179:183-195.
- [7]XU M, JIA X, PICKERING M, et al.Cloud removal based on sparse representation via multitemporal dictionary learning[J]. IEEE transactions on geoscience and remote sensing, 2016, 54(5): 2998-3006.
- [8]TSENG D C, TSENG H T, CHIEN C L.Automatic cloud removal from multi-temporal SPOT images[J].Applied mathematics and computation,2008,205(2):584-600.
- [9]HOAN N T, TATEISHI R.Cloud removal of optical image using SAR data for ALOS applications experimenting on simulated ALOS data[J].Journal of the remote sensing society of Japan, 2009,29(2):410-417.
- [10]ECKARDT R, BERGER C, THIEL C, et al.Removal of optically thick clouds from multi-spectral satellite images using multi-frequency SAR data[J].Remote sensing,2013,5(6):2973-3006.
- [11]ZI Y, XIE F, ZHANG N, et al.Thin cloud removal for multispectral remote sensing images using convolutional neural networks combined with an imaging model[J].IEEE journal of selected topics in applied earth observations and remote sensing, 2021,14:3811-3823.
- [12]TAO C, FU S, QI J, et al. Thick cloud removal in optical remote sensing images using a texture complexity guided self-paced learning method[J].IEEE transactions on geoscience and remote sensing,2022,60:1-12.
- [13]YU W, ZHANG X, PUN M.Cloud removal in optical remote sensing imagery using multiscale distortion-aware networks[J].IEEE geoscience and remote sensing letters, 2022, 19: 1-15.
- [14]ZHENG J, LIU X, WANG X, et al.Single image cloud removal using U-Net and generative adversarial networks[J]. IEEE transactions on geoscience and remote sensing, 2021, 59(8): 6371-6385.
- [15]XU Z, WU K, HUANG L, et al.Cloudy image arithmetic:a cloudy scene synthesis paradigm with an application to deep-learning-based thin cloud removal[J].IEEE transactions on geoscience and remote sensing,2022,60:1-16.
- [16]GUO J, YANG J, YUE H, et al.RSDehazeNet:dehazing net-

- work with channel refinement for multispectral remote sensing images[J].IEEE transactions on geoscience and remote sensing, 2021,59(3):2535-2549.
- [17]YU Y, LIU H, FU M, et al.A two-branch neural network for non-homogeneous dehazing via ensemble learning[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops,[v.1].Piscataway:IEEE,2021:193-202.
- [18]SUN H, LUO Z, DONG R, et al.Partial siamese with multiscale Bi-Codec networks for remote sensing image haze removal[J].IEEE transactions on geoscience and remote sensing, 2023, 61:1-16.
- [19] 孙航, 方帅领, 但志平, 等. 层级特征交互与增强感受野双分支遥感图像去雾网络 [J]. 遥感学报, 2023,27(12):2831-2846.
- [20]XU Z, WU K, HUANG L, et al.Cloudy image arithmetic:a cloudy scene synthesis paradigm with an application to deep-learning-based thin cloud removal[J].IEEE transactions on geoscience and remote sensing, 2022,60:1-16.
- [21]MA X, WANG Q, TONG X.A spectral grouping-based deep learning model for haze removal of hyperspectral images[J]. ISPRS journal of photogrammetry and remote sensing, 2022, 188: 177-189.
- [22]LI W, LI Y, CHEN D, et al.Thin cloud removal with residual symmetrical concatenation network[J].ISPRS journal of photogrammetry and remote sensing,2019,153(Jul.):137-150.
- [23]LIN D, XU G, WANG X, et al.A remote sensing image dataset for cloud removal[EB/OL].(2016-01-03)[2024-02-26]. <https://doi.org/10.48550/arXiv.1901.00600>.
- [24]ZHENG Z, REN W, CAO X, et al.Ultra-high-definition image dehazing via multi-guided bilateral learning[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, [v.1].Piscataway:IEEE,2021:16180-16189.
- [25]LIU X, MA Y, SHI Z,et al.GridDehazeNet:attention-based multi-scale network for image dehazing[C]//2019 IEEE/CVF International Conference on Computer Vision.Piscataway: IEEE, 2019: 7313-7322.
- [26]DONG H, PAN J, XIANG L, et al.Multi-scale boosted dehazing network with dense feature fusion[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, [v.1]. Piscataway:IEEE,2020:2154-2164.
- [27]ZHANG L, WANG S.Dense haze removal based on dynamic collaborative inference learning for remote sensing images[J]. IEEE transactions on geoscience and remote sensing, 2022, 60:1-16.

【作者简介】

梁星(1989—),男,湖北当阳人,硕士,讲师,研究方向:遥感图像处理、人工智能等。

(收稿日期: 2024-04-08)

(上接第 95 页)

- generation of machine learning training data sets[J]. Computers&geosciences, 2023,170(Jan.):105232.1-105232.15.
- [6]REN X, MALIK J.Learning a classification model for segmentation[C]//Computer Vision, 2003. Proceedings,vol.2. Piscataway:IEEE,2003:10-17.
- [7]ZHANG A, REN W, LIU Y, et al. Lightweight image super-resolution with superpixel token interaction[C]//2023 IEEE/CVF International Conference on Computer Vision(ICCV). Piscataway: IEEE, 2023:12682-12691.
- [8]ACHANTA R, SHA A K, SMITH A, et al.SLIC superpixels compared to state-of-the-art superpixel methods[J].IEEE transactions on pattern analysis and machine intelligence, 2012, 34(11): 2274-2282.
- [9] 侯志强, 赵梦琦, 余旺盛, 等. 基于 SLIC 与分水岭算法的彩色图像分割 [J]. 光电工程, 2019, 46(6):78-86.
- [10] 蒋丽维, 刘迪, 张洋, 等. 基于超像素图像分割算法的碳酸盐岩鲕粒特征提取方法 [J]. 石油地球物理勘探, 2023, 58(S1): 44-48.
- [11]TREMEAU A, COLANTONI P. Regions adjacency graph applied to color image segmentation[J].IEEE transactions on image processing, 2002,9(4):735-744.
- [12]ZHUANG L, KAIMING H. A decade's battle on dataset bias:are we there yet?[EB/OL].(2024-03-13)[2024-03-20]. <https://doi.org/10.48550/arXiv.2403.08632>.
- [13] 刘合. 油气勘探开发数字化转型人工智能应用大势所趋 [J]. 石油科技论坛, 2023,42(3):1-9.

【作者简介】

程国建(1964—),男,陕西西安人,博士,教授,研究方向:机器学习、机器视觉与模式识别、大语言模型、智能数字油田等。

邓文华(1999—),通信作者(email: dengwhwj@qq.com),男,陕西宝鸡人,硕士研究生,研究方向:人工智能、机器视觉与模式识别、智能数字油田等。

(收稿日期: 2024-03-25)