

DOI:10.16356/j.1005-2615.2023.06.002

结合局部高清图像的遥感集群目标区域超分辨率重建

阎菩提¹, 邱实¹, 岳程斐²

(1. 哈尔滨工业大学航天学院, 哈尔滨 150001; 2. 哈尔滨工业大学(深圳)空间科学与应用研究院, 深圳 518055)

摘要: 近年来, 卫星遥感图像的应用场景越来越广泛。但是由于采集设备有限及其成本限制, 卫星传感器获取到的图像通常不具备足够的分辨率且分布不够均匀, 同时部分目标聚集成群难以分辨, 导致低分辨率遥感图像在目标检测与识别等空间语义理解任务上难以满足准确定位和分类所有目标的要求。相比于一次性采集完整高分辨率遥感图像, 已有遥感图像通常在局部区域具有相对清晰的高分辨率, 且具备足够的细节信息用于分辨目标群, 而传统的遥感图像超分辨率重建方法主要关注遥感图像自身的全局特征, 通过图像的全局特征进行分辨率和像素扩充, 而忽视了遥感图像的细节信息。为了解决这些挑战, 提出了一种将遥感图像局部聚集群目标区域的细节特征信息引入到完整遥感图像的采样重建中的方法, 通过多层级的神经网络来提取不同尺度的图像特征, 并通过残差学习的方式将这些特征进行融合并重建。在实验中, 该方法相比主流现有的遥感图像超分辨率重建方法, 在视觉效果和测试实验上都取得了更好的结果, 证明该方法可以有效借助局部图像的像素信息, 显著地提高全局遥感图像的细节效果和优化集群目标区域的分辨能力, 提升了遥感图像的质量和可用性。

关键词: 遥感图像超分辨率; 局部遥感图像; 辅助超分辨率; 多层级融合

中图分类号: TP701

文献标志码: A

文章编号: 1005-2615(2023)06-0956-10

Remote Sensing Image Super-Resolution Reconstruction with Local High-Resolution Clustered Object Images

YAN Puti¹, QIU Shi¹, YUE Chengfei²

(1. School of Astronautics, Harbin Institute of Technology, Harbin 150001, China; 2. Institute of Space Technology and Applied Technology, Harbin Institute of Technology (Shenzhen), Shenzhen 518055, China)

Abstract: In recent years, the application scenarios of satellite remote sensing images have become increasingly diverse. However, due to limited collection equipment and cost constraints, the images obtained by satellite sensors usually do not have sufficient resolution and are not uniformly distributed, which is difficult to distinguish some clustered objects. Low-resolution remote sensing images are not suitable for semantic understanding tasks such as object detection and recognition to accurately locate and classify all objects. Compared to obtaining complete high-resolution remote sensing images at once, existing remote sensing images usually have relatively clear high resolution in local areas and sufficient detailed information for distinguishing object groups. Traditional remote sensing image super-resolution reconstruction methods mainly focus on the global features of remote sensing images, expanding resolution and pixels based on global features of images, while ignoring the details of remote sensing images. To address this problem, this paper proposes a method that introduces detailed information about local clustered object areas in local images in the reconstruction of complete remote sensing images. Specifically, the proposed method uses a multi-level neural network to extract image features of different scales and then uses residual learning to merge and

收稿日期: 2023-10-25; 修订日期: 2023-11-30

通信作者: 岳程斐, 男, 博士, 副教授, 博士生导师, E-mail: yuechengfei@hit.edu.cn。

引用格式: 阎菩提, 邱实, 岳程斐. 结合局部高清图像的遥感集群目标区域超分辨率重建[J]. 南京航空航天大学学报, 2023, 55(6): 956-965. YAN Puti, QIU Shi, YUE Chengfei. Remote sensing image super-resolution reconstruction with local high-resolution clustered object images[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2023, 55(6): 956-965.

reconstruct these features. In the experiments of this paper, the proposed method achieved better visual effects and numerical results compared to several existing remote sensing image super-resolution reconstruction methods. This indicates that the proposed method can effectively utilize the pixel information of local images, significantly improve the details of global remote sensing images and optimize the recognition capability of the group objects area, and enhance the quality and availability of remote sensing images in a low-cost way.

Key words: remote sensing image super-resolution; local satellite image; assisted super-resolution; multi-layer fusion

近年来,遥感卫星图像在环境监测、资源勘探、灾害警报和军事应用等领域得到广泛应用。然而,由于航天成像设备和通信带宽的限制,卫星图像的分辨率通常受到一定的限制。此外,大气变化、传输噪声、运动模糊和欠采样光学传感器的影响,使得卫星图像的质量和分辨率无法满足实际卫星图像分析的需求。为克服成像硬件限制并提高图像的空间分辨率,研究者开始研究遥感图像的超分辨率重建技术(Super-resolution reconstruction, SR)^[1]。目前,超分辨率技术已被广泛应用于遥感卫星图像的采集和增强,例如法国 SPOT-5 卫星通过对 2 个 5 m 分辨率的遥感图像进行超分辨率,使得最终遥感图像达到了 2.5 m 分辨率。

现有的图像超分辨率重建算法主要分为 2 类:基于几何和基于学习的算法。基于几何的算法通过融合多帧低分辨率图像信息,并从像素点的几何特征组合恢复出潜在高分辨率图像。具体而言,基于几何的超分辨率重建方法需要按照降采样、光学模糊、噪声恢复、配准误差度量、几何变形和运动补偿等步骤来恢复图像的更密集分辨率的像素。尽管基于几何的超分辨率重建方法具有更直观的可解释性,但它们依赖于准确的像素精度估计,即受到低分辨率数据的精度的直接影响,给真实场景下的超分辨率使用带来较大的困难。

随着机器学习技术在基于语义的图像处理领域的目标识别和图像分割等方面的不断进展,基于机器学习的超分辨率方法也逐渐成为研究的主流方向。这些方法旨在通过训练数据集提供的先验信息来学习低分辨率和高分辨率图像/块之间的映射函数。相比于基于几何的方法,基于机器学习的方法由于提供了足够数量的先验信息,因此可以获得更好的重建性能。目前,基于机器学习的超分辨率方法可以分为 3 类:基于回归的方法、基于特征表示的方法和基于深度学习的方法。虽然一些基于回归和特征表示的方法已经取得了较为满意的性能,但是它们对目标图像自身特征的要求较高,

难以在多种变化的真实场景下得到扩展应用。

基于深度学习的方法利用卷积神经网络(Convolutional neural network, CNN)在数据集中逐渐迭代学习复杂的映射函数。这种技术提供了端到端的解决方案,已广泛应用于多种图像生成和分析任务。Shi 等^[2]提出了一种基于子像素的卷积神经网络,该方法为从低分辨率到高分辨率的图像提供了一种直接且有效的学习映射函数的新方法。Kim 等^[3]通过实验提出,深度残差学习可以有效地缓解构建深度网络的训练难度。Lai 等^[4]在特征域中构建金字塔网络,融合多尺度的特征残差,并将其用于构建生成对抗网络以生成虚假细节,模拟更具细节的图像输出。Luo 等^[5]将自相似性代替零填充以避免添加占位信息并获得良好的结果。Wang 等^[6]提出了一种用于视频超分辨率重建的卷积神经网络,以保留帧间的时间相关性。此外,针对卫星遥感图像,Wang 等^[7]采用了多尺度残差网络来提取多尺度特征并学习超分辨率重建的映射关系。

然而,上述提到的超分辨率重建方法主要集中在常规图像上,很少有方法聚焦于卫星遥感图像的超分辨率。卫星遥感图像在分割、特征提取和目标跟踪等下游遥感视觉任务中扮演着重要角色,它的特点是图片尺度相对较大,且图片细节分布不均,部分聚集成群的目标区域需要更细致地增强用以区分单个目标,而分布分散地区域则要求较低。设计用于普通图像的深度学习方法不能有效处理卫星图像,因为它们没有考虑卫星图像自身所具备的大尺度和非均匀性质。此外,对于卫星图像检测(Redmon 等^[8])和目标识别(Lu 等^[9])来说,充足的高频信息(如边缘和纹理)至关重要。使用单一结构网络预测和重建对象,在没有考虑不同尺度的情况下会导致较差的重建性能。一个实用的解决方案是划分多尺度进行补充。Zhang 等^[10]使用多尺度空间结构的自相似性来构成特征字典。Fu 等^[11]利用图像的多尺度区域训练循环注意力网络进行

高分辨率的细粒度识别。Liu等^[12]采用多尺度和多层级网络,将全局特征和局部特征融合起来以获取分层边缘信息,Du等^[13]融合了来自3个不同滤波器的不同尺度特征。Luo等^[14]设计了一个关注视频领域的超分辨率算法,能够活得更精确的重建结果。Wang等^[15]提出了一种用于图像超分辨率重建的超密集GAN,将残差块的内部布局改造成二维矩阵拓扑,用更少的层完成足够的连接路径,从而灵活适应图像内容的多样性、提高超分辨率重建性能。Fang等^[16]提出了一种用于卫星图像重建的任意尺度的超分辨率网络,用于应对不同数据、硬件的不同需求。

现有的基于卷积神经网络的超分辨率重建模型为了获取精细的局部细节信息,通常使用小的图像块进行训练,如SRCNN(Dong等^[17])使用 33×33 的图像块,VDSR(Kim等^[3])使用 41×41 的图像块,LapSRN(Lai等^[4])使用 32×32 的图像块,SRResnet/SRGAN(Ledig等^[18])使用 24×24 的图像块。然而,小的感受野只考虑了有限范围内的信息,缺乏获取超分辨率图像的全局和上下文信息的能力。相反,Zeiler等^[19]通过可视化卷积网络表明,不同的网络层在表示模拟腹侧通路的特征方面发挥着不同的作用。因此,如何有效通过不同尺度的分层特征提高神经网络获取全局信息的能力成为遥感超分领域中一个值得深入研究的问题。

这些超分辨率重建方法通常需要多个相同场景的空间/光谱/时间低分辨率图像,这增加了方法设计和网络训练的成本。因此在现有的数据尺度要求较高的方法下,本文提出了一种新的卫星遥感图像超分辨率深度神经网络,以非均匀分布的遥感图像的局部集群目标区域高清区域作为辅助信息,独立对此部分进行分析与局部特征提取,作为全局遥感图像的辅助特征,高效地重建出带有高分辨率细节信息的卫星遥感图像。由于遥感图像具有空间相似性,局部的纹理特征在一定条件下,是可以映射到其他区域的,尤其是那些相似的区域,这是本文通过耦合局部特征知识提升图像分辨率细节质量的物理基础。集群目标区域是指存在大量同类目标聚集的区域,这些目标通常距离很小且区别较小,会给超分辨率重建带来较大的挑战,因此为这些这些区域的重建提供额外的高分辨率引导具备较大的潜在价值。

具体而言,该方法首先使用卷积神经网络从局部集群目标区域(如停车场、街道等)图像中提取多层次特征,然后将这些特征通过残差学习的方式融

合到全局遥感图像的超分辨率网络中,从而在高目标密度局部图片的辅助下对不均匀全局图片进行超分辨率,减少了对高分辨率图像自身数据数量及清晰度分布的需求。同时,本文还引入了一种新的层级式监督机制来增强网络的训练过程,提高模型的性能和稳定性。实验结果表明,相比几种现有的遥感图像超分辨率重建方法,本文的方法在提高卫星图像分辨率方面具有显著的优势,在不同场景下的视觉效果和数值结果上都取得了更好的结果。这表明本文提出的方法可以有效借助局部集群目标区域图像的边缘等信息,显著地提高非均匀全局遥感图像的细节效果,以低成本的方式提升了遥感图像的质量和可用性。这种以非均匀分布的遥感图像为辅助的超分辨率深度神经网络方法有望为遥感卫星图像的高精度分析和应用提供新的低成本、高效的解决方案。

1 研究方法

在本节中,本文介绍了本文所提出的基于局部集群目标区域引导辅助的遥感图像超分辨率重建算法框架。给定一个地区的非均匀精度的低分辨率遥感图像,以及其对应的部分集群目标区域的高分辨率遥感图像,本框架对此类图像进行输入和处理,可输出同一区域的高分辨率卫星遥感图像。一般而言,一张图像可以使用像素矩阵来表示,在本算法介绍中,记 X 为由非均匀精度的低分辨率遥感图像,记 Y 为同一目标、同一地区的高分辨率遥感图像, Z 为该地区对应的局部集群目标区域的高分辨率遥感图像。本文将基于局部集群目标区域辅助的遥感图像超分辨率重建算法定义为对于输入的 $X \in S_X$ 和辅助输入图像 $Z \in S_Z$,通过模型学习尽可能准确的映射关系,预测尽可能接近 $Y \in S_Y$ 的 $\tilde{X} \in S_X$ 。

对于遥感卫星拍摄到的原始图像数据 X ,在有限的传感器分辨率下,原始图像数据 X 可能具有较低且不够均匀的分辨率,在部分区域分辨率较高(稀疏目标区域)、在部分区域分辨率较低(集群目标区域),这种非均匀的模糊性会给图像的应用带来极大的困难,此外这种特性会使得遥感图像的特征在进行全局提取时具备多种不完整且随机的局部特征。在网络设计中,本文通过设计提取多尺度特征的多层级融合、重建与对抗生成框架来实现局部集群目标区域高清区域特征与非均匀的全局特征的高效推理,本框架通过端到端的有监督学习网

络来实现这一复杂的映射。具体而言,图1为本文所提出的基于局部集群目标区域辅助的遥感图像超分辨率重建算法流程框架图,由图1可知,本文的框架在大框架上由生成器和判别器组成,生成器

通过对输入进行特征提取与重建实现对高分辨率遥感图像的生成,判别器对生成器生成的高分辨率图像进行真伪判别,两种结构直接交替训练,通过相互对抗,以获得更为真实的网络生成效果。

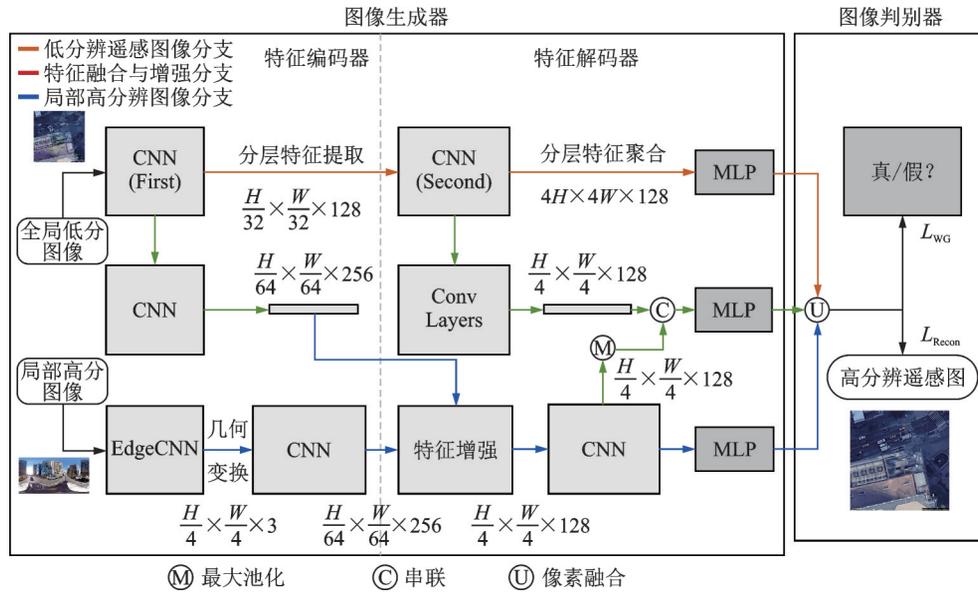


图1 基于局部群目标辅助的遥感图像超分辨率重建算法流程
Fig.1 Local image based satellite image super-resolution algorithm pipeline

在本文所提出的生成器中,网络由几个具有相同结构的级联特征提取单元组成的特征编码器和特征解码器组成。每个单元同时接受非均匀精度的低分辨率遥感图像和集群目标区域的高分辨率遥感图像作为输入,其中首个级联单元直接接受原始图像,第2个级联单元接受第1个单元所输出的对应特征,每个单元逐步增强遥感图像并同时输出新的辅助特征图,以供下一个超分辨率重建单元使用。特征编码器的每个单元接收不同级别的输入,完成输入数据的特征提取、融合和扩展,从而强化和补充两种输入模态之间的结果。此外,在生成器的不同级联单元中本方法将低阶特征与高阶特征进行串联融合,以共享语义和几何信息。特征解码器对特征编码器所输出特征图进行逐步反卷积恢复,最终获得与输入遥感图像尺寸。为了让输出的遥感图像符合真实场景下的语义,本文在生成器的基础上增加了判别器的设计,用于判断输出图像的真实性。为了兼顾输出图像的完整性和均匀分布性,在网络整体设计中,本文使用联合损失函数来训练生成器,然后使用对抗损失微调网络。实验结果表明,这种以目标聚集成群的局部高清图为辅助的超分辨率深度神经网络方法有望为遥感卫星图像的高精度分析和应用提供新的低成本、高效的解决方案。

级联图像生成器分为3个分支,1.1节对全局低分遥感图像分支和集群目标区域局部高分图像分支进行介绍,对于本文的核心设计特征融合与增强分支,本文在1.2节中进行单独介绍,此外本文在1.3节中对于网络中的判别器部分进行了介绍。

1.1 级联图像生成器

本文的深度增强网络是一种对抗式架构,包括生成器和判别器,如图1所示。生成器是两个具有相似结构的增强单元的级联结构,以低分辨率的遥感图像 X 和集群目标区域辅助图像 Z 作为输入。每个增强单元由3个并行的功能分支组成:全局低分遥感图像分支、集群目标区域高分图像分支及特征融合与增强分支,它们分别通过处理非均匀低分遥感图像(特征)、局部目标群高分图像(特征),以及对2个分支特征进行融合与增强来重建最终的高分辨率图像。第1个增强单元将该地区对应的部分集群目标区域的高分辨率遥感图像 Z 和非均匀精度的低分辨率遥感图像 X 作为输入,进行特征提取和聚合,然后将输出传递到下一个增强单元。第2个增强单元与第1个单元在功能上相似,但其输出为增强后的遥感图像 Y 。

(1) 低分辨率遥感图像分支

具体地说,在这个级联图像生成器中,低分辨率遥感图像分支接收原始的非均匀低分辨率遥感

图像作为输入,经过两个CNN进行分层特征提取。在第一个CNN中,特征被提取出来并用作下一个CNN和特征融合分支及增强分支的输入。特征融合分支将遥感图像的低级特征和地面图像的高级特征进行融合,以获得更加准确的预测。增强分支将遥感图像的低级特征转换为高级特征,从而深化遥感图像特征的语义。在第2个CNN,特征被进一步提取并用于分层特征聚合的特征解码。这种分层特征提取和聚合的方法,有助于获得更加准确的预测结果,从而提高图像生成器的性能和稳定性。

此外,对于此分支和其他分支使用的CNN,其基本组成结构是类似于ResNet的残差结构

$$f_{out} = f_{in} + \text{ConvBlock}_2(\text{ConvBlock}_1(f_{in})) \quad (1)$$

式中: f_{in} 、 f_{out} 分别为残差结构的输入特征和输出特征;ConvBlock是由Conv-BN-ReLU组成的基本卷积单元,其中ConvBlock₁将特征维度压缩2倍用于降维和保留关键特征信息,ConvBlock₂将特征维度恢复回原本的维度,这种瓶颈结构有利于减少参数和提取更好的特征。

(2) 局部集群目标区域高分辨率图像分支

为了处理局部集群目标区域高分辨率图像,本文使用了一个独立的分支。这个分支的输入是原始集群目标区域高分辨率图像,其大小为低分辨率遥感图像的1/4。本文使用了DGCNN(Wang等^[20])中的EdgeConv模块来学习局部高清图特征。此外,本文还使用了空间变换层,通过 3×3 矩阵将局部高清图特征集对齐到全局图像几何空间。为了估计这个矩阵,本文使用了一个张量作为中间变量,将每个点的坐标和其 k 个相邻点的坐标差连接在一起。EdgeConv模块的输出送入后续的CNN,进一步加深特征的语义并进行上采样以便恢复原图的分辨率。此外,这些特征还通过特征融合分支与其他分支的特征进行融合,然后输出到后续单元进行处理。

为了更好地共享语义和几何信息,本文对不同层级的特征进行跨级连接,通过层间连接的构建,编码器和解码器之间的高层特征与低层特征相互融合,从而增加几何和语义信息之间的流动。

1.2 特征融合与增强分支

本文提出的特征融合与增强分支如图2所示。局部集群目标区域高清分支将局部高清图特征集区分为若干个图像切块并从中提取特征,之后使用全局分支中的图像特征生成的注意

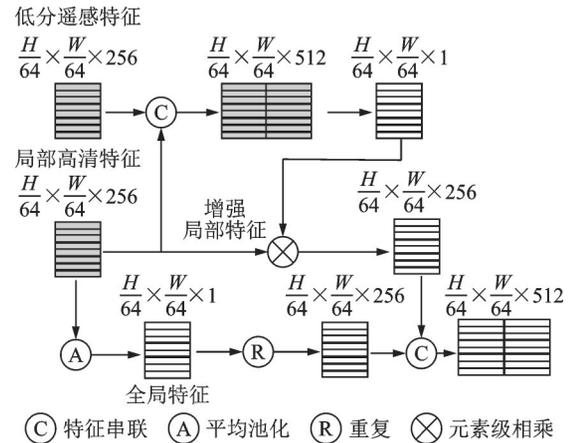


图2 特征融合与增强分支结构图

Fig.2 Feature fusion branch pipeline

掩码来增强局部高清图特征。随后,增强的局部高清图特征被上采样,随后转发到全连接层,帮助预测全局遥感超分辨率图像。具体而言,本文将原始的 N 个图像切块的特征以原始向量($N \times H/4 \times W/4 \times 3$)表示,然后将它们转换为特征空间($N \times H/64 \times W/64 \times C$)中的维度 C 。

受到近期新方法中注意力机制的启发,特征增强模块融合了全局图像特征和局部集群目标区域高清图特征。具体来说,第1个增强单元的全局图像分支提取256维特征向量(如图2顶行所示),并与局部集群目标区域高清图特征连接,再通过多层感知机(Multilayer perceptron, MLP)压缩为一维向量,最后通过Sigmoid函数将此向量归一化到 $[0, 1]$ 的范围内,得到一个注意掩码。然后通过与点特征的逐元素相乘来实现增强的局部点特征。通过这种方式,可以获得了由局部集群目标区域特征增强的全局图像特征

$$X' = \mathcal{E}_M(F_{low}, F_{local}) \cdot F_{local} \quad (2)$$

式中: X' 表示增强后的高分辨率遥感图像特征, \mathcal{E}_M 表示经过特征融合获得的注意力掩膜, F_{low} 、 F_{local} 分别表示全局低分遥感特征和局部集群目标区域高清图特征。本文采用的注意力机制能够进一步提高生成器的性能和稳定性。这种方式可以有效地处理局部高分辨率图像,并将其与其他分支的特征融合,从而生成高质量的遥感图像。

1.3 判别器及训练损失

对抗训练是一种近年来在深度学习领域中受到广泛关注的技术,其在图像生成方面已经取得了显著的成功。为此,本文引入了一个判别器来进行对抗训练,以帮助识别超分辨率遥感图片的真实性。本文框架使用联合损失函数进行训练,该函数

同时考虑了完整性和分布均匀性的因素,以获得“粗糙”的超分辨率遥感图片。然后,本文通过对抗性损失微调网络,获得“精细”的超分辨率遥感图片。本文使用 ResNet(He 等^[21])作为判别器的二进制分类网络,以区分预测结果来自生成集 S_{IX} 还是真实集 S_{IY} 。最后,本文通过改进的 Wasserstein GAN 损失(Adler 等^[22])进行对抗性损失的训练,以提高网络性能。此外,网络的生成器部分使用 Smooth-L1 损失(Liu 等^[23])来进行图像拟合。网络的损失函数为

$$L = \alpha L_{WG} + L_{Recon} \quad (3)$$

式中

$$\alpha = 0.3$$

$$L_{WG} = D(X) - D(Y) + \lambda(\|\partial D(X)\|_2 - 1)^2 \quad (4)$$

为对抗训练的损失, D 代表判别器, ∂D 为判别器的梯度,权重 $\lambda = 3$

$$L_{Recon} = \begin{cases} 0.5d^2 & d < 1 \\ |d - 0.5| & d \geq 1 \end{cases} \quad (5)$$

为用来重建的 Smooth-L1 损失,其中 $d = |X - Y|$ 。

2 数据处理与结果分析

2.1 实验数据集

本文实验使用了目前两个大规模的、公开的跨视角数据集,分别是 Dayton 数据集(Vo 和 Hayes^[24])和 SVA 数据集(Palazzi 等^[25])。本文在现有遥感图像数据集的基础上,对高分辨率遥感图像进行非均匀的降采样处理,并对原始高分辨率图像中的局部集群目标区域进行提取作为输入的数据对。在实验中,本文将两个数据集的数据集中处理进行训练与测试。

Dayton 数据集由 Vo 和 Hayes 提供。它包括从 11 个不同美国城市收集的超过 1M 对街景和俯视图。本文从全部卫星遥感图像中选择了 76 048 对图像,并创建 55 000/21 048 对图像的训练/测试拆分。由于这部分图像数据是从完整数据集的 Dayton 城市中挑选,因此在本文中,本文将这个数据集中的 Dayton 部分称为 Dayton 数据集,如图 3 将这个数据集的部分数据进行了展示。

Surround vehicle awareness(SVA)数据集是从“侠盗猎车手 V”(GTA V)视频游戏中收集的合成数据集。本文在图 4 中对该数据集进行了展示,本文直接使用数据集中提供的训练/测试拆分,对于原始数据,本文使用每 10 个帧选取 1 帧的策略来消

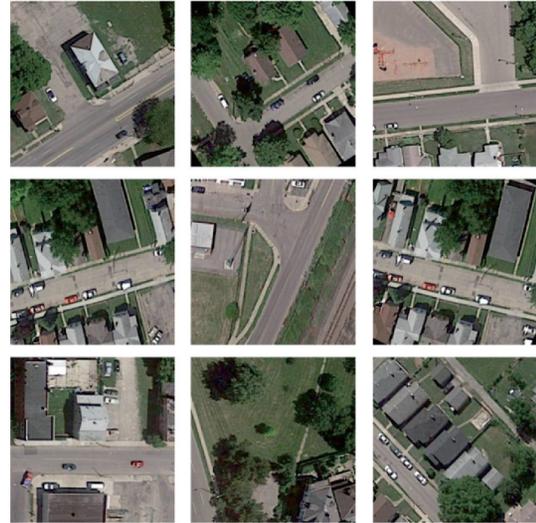


图3 Dayton数据集示意图

Fig.3 Example of Dayton dataset

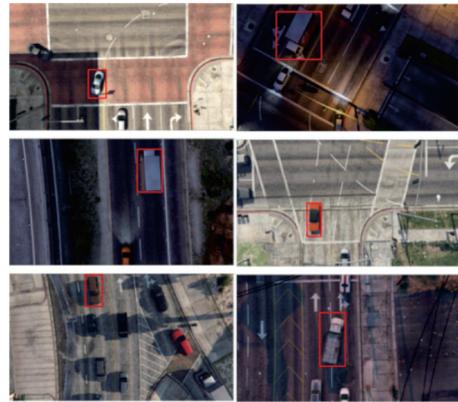


图4 SVA数据集示意图

Fig.4 Examples of SVA dataset

除数据集中的冗余。经过最终处理,最终获得了一个包含 46 030 对图像的训练集,以及一个 254 对图像的测试集。低分辨率图片直接输入网络,局部高分辨率图片由全局低分辨率图片裁剪而来,并在输入网络之前应用了随机旋转、随机颜色变换等数据增强。

两个数据集的低分辨率图像和高分辨率图像如图 5 所示。

2.2 对比实验

本文对重建图像进行了主观和客观的定性和定量分析,本文使用了峰值信噪比(Peak signal-to-noise ratio, PSNR)、结构相似性(Structural similarity, SSIM)、特征相似性(Feature similarity, FSIM)、视觉信息保真度(Visual information fidelity, VIF)、矩形归一化超像素熵指数(Rectangular-normalized superpixel entropy index, RSEI)和互信息增益(Gain of mutual information, GMI)等指标(Lu 等^[26]),这些指标越大表明效果越好。

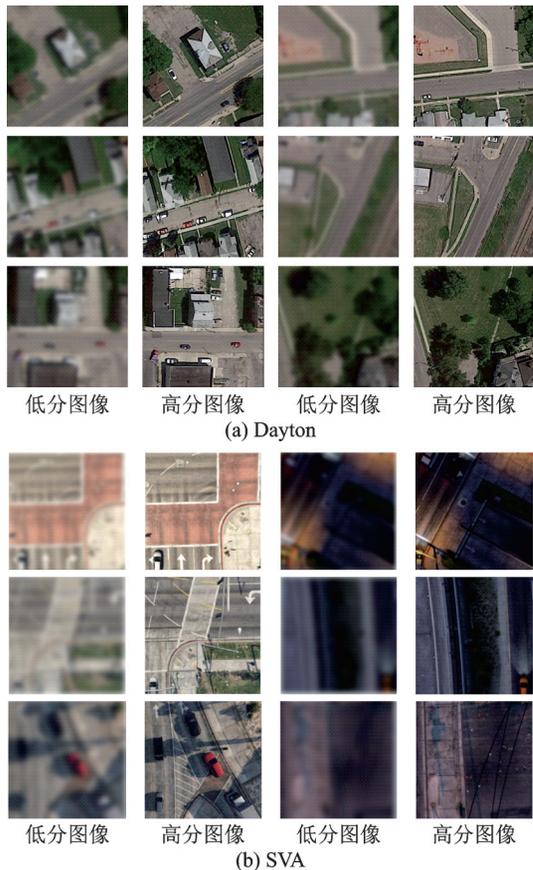


图5 Dayton和SVA数据集低分图像和高分图像示意图
Fig.5 Examples of high-resolution and low-resolution images of datasets Dayton and SVA

为了验证本文算法的有效性,本文将提出的方法与目前较为通用的超分辨率重建算法进行了比较:

(1) SRCNN(Dong等^[17])是第1个使用深度学习卷积神经网络进行超分辨率重建的算法。

(2) LapSRN(Lai等^[4])是首个基于多尺度特征进行学习的深度学习超分辨率算法,有效提高了当时算法的性能。

(3) SelfExSR(Huang等^[27])基于自相似性完成超分辨率,在不使用外部数据集的情况下在城市场景上实现了优于其他方法的效果。

(4) VISR(Kim等^[3])是当前针对卫星遥感图

像进行重建的CNN网络中表现最好的算法。

(5) SRResnet(Ledig等^[18])则是目前计算效率最高且效果最好的深度超分辨率重建算法。

这些算法的复现和对比过程中,使用了公开的源代码和作者提供的可用参数进行实现。所有图像均采用Python PIL库进行相同模式的采样。为了公平比较,本文使用相同的数据集配置对所有这些算法进行训练,并使用所提出的网络对相同的卫星图像进行了评估。

表1中列出了两个数据集的混合测试结果,包括测试集图像的PSNR、SSIM、FSIM、VIF、RSEI、GMI和运行时间等指标。通过分析表格结果可以发现,本文方法在多项指标上都优于现有其他方法。所有实验重复了10次测试并取平均值,本文方法的优势具有统计学意义。此外,在衡量时间复杂度的运行时间上,本文方法虽然不是速度最快的,但是考虑到本文方法额外设计了2个分支并且实现了显著好于对比方法的结果,时间上仅增加了一些是可以接受的,对比之下,SlefExSR在时间上的复杂度高达Bicubic插值的100倍。

在超分生成中,由于图像自身空间相似性,往往自然景物区域的生成效果相对于人造物区域质量更好。因此本文设计了2类场景分别进行测试,在图6中,本文给出了对比实验的可视化结果,包含城市和野外两个场景。从可视化结果中可以发现本文的方法可视化效果显著优于其他现有方法,而且城市和野外场景都能达到较好的效果。这一结果表明,本文引入的局部集群目标区域辅助信息具有一定效果,尤其是在有大量房屋、车辆聚集的场景下产生了更优的预测。与仅使用遥感图像本身进行超分辨率重建的方法相比,本文方法使用了集群目标区域的高清影像作为辅助,在对遥感图像信息的补充方面具有更优秀的效果。这种辅助信息的引入可以有效缓解图像目标信息的缺失与不

表1 超分辨率重建对比结果

Table 1 Comparison results of super-resolution

评价指标	Bicubic	SelfExSR	SRCNN	LapSRN	VISR	SRResnet	本文方法
PSNR	15.67	15.91	16.54	16.98	17.03	17.28	18.65
SSIM	0.728 9	0.735 8	0.740 2	0.742 6	0.756 5	0.756 8	0.802 9
FSIM	0.852 5	0.867 2	0.889 8	0.891 2	0.902 4	0.905 5	0.957 8
VIF	0.297 2	0.298 7	0.315 8	0.325 8	0.335 7	0.336 4	0.409 3
RSEI	0.322 5	0.325 5	0.342 5	0.354 1	0.364 4	0.367 1	0.402 3
MI	3.942 5	4.025 4	4.122 5	4.134 5	4.167 8	4.169 9	4.587 8
GMI	1.000 0	1.011 4	1.004 7	1.024 5	1.015 8	1.025 7	1.102 5
Inference time/s	0.03	3	0.3	0.05	0.21	0.45	0.27

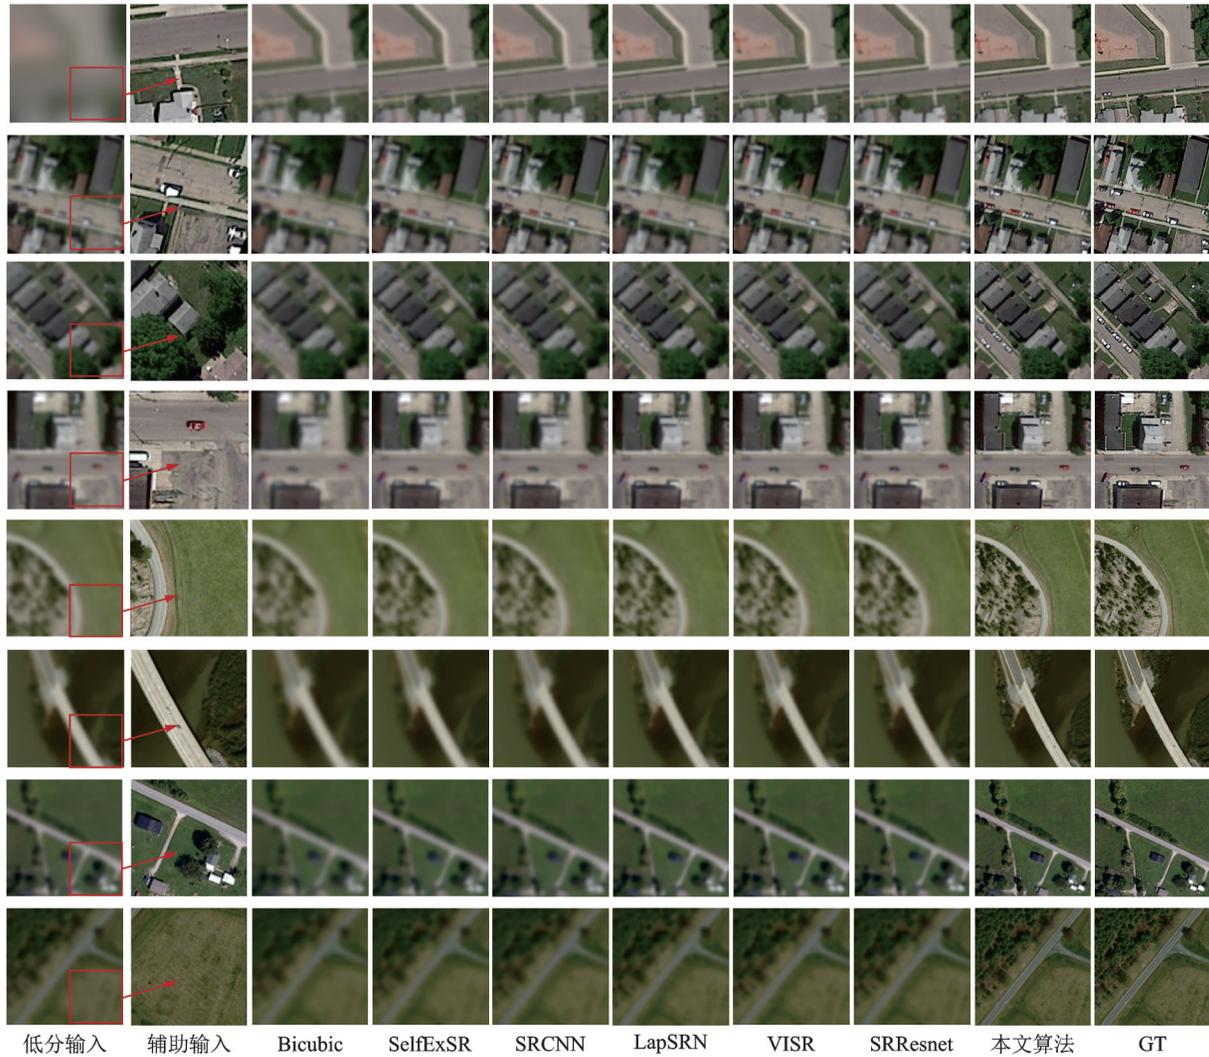


图 6 本文算法与基线方法的可视化对比

Fig.6 Comparison of visualization results between our method and baseline methods

足,将聚集的目标在超分过程中进行分辨和分离,增强聚集目标区域在重建过程的细节,在基于语义的应用中具有较大参考价值。

2.3 消融实验

为了验证本文方法中的不同模块的有效性,本文对方法中的不同模块进行了消融实验。具体而言,本文分别测试了无局部集群目标区域高分辨率图像分支、无特征融合、无判别器 3 种结构,并于完整结构的效果做对比,实验结果如表 2 所示。在不同模块的去除实验中,完整结构具备最佳效果,因此足以证明本文方法在设计时不同模块均具备一定有效性。此外,本文在图 7 中额外可视化了不同消融实验的效果,以定性说明所提出模块的有效性。

需要注意的是,本文在图 7 中展示了 2 个场景的实验结果。对于第 1 个场景,无融合的结果不如无判别器的结果;而对于第 2 个场景,无融合的结果却显著优于无判别器的结果。这种现象出现的可能原因

表 2 本文算法的消融实验结果

Table 2 Ablation study of our method

评价指标	无局部高分辨率图	无特征融合	无判别器	完整结构
PSNR	17.28	17.55	17.98	18.65
SSIM	0.756 8	0.762 5	0.777 8	0.802 9
FSIM	0.905 5	0.912 5	0.926 5	0.957 8
VIF	0.336 4	0.354 8	0.387 8	0.409 3
RSEI	0.367 1	0.378 5	0.381 5	0.402 3
MI	4.169 9	4.205 7	4.315 8	4.587 8
GMI	1.000 0	1.024 3	1.053 8	1.102 5

是第 1 个场景中多个同类大目标密集排列在一起,同还存在多个小目标,这种情况下通过融合可以很好地解决局部和整体的问题,从而提升视觉效果。然而,对于下面一行,目标之间相对分散,这种融合能够起到的作用有限。这进一步说明了本文方法需要局部目标聚群区域作为辅助才能有效地拓展到全局的其他区域,实现更好的超分辨率重建。

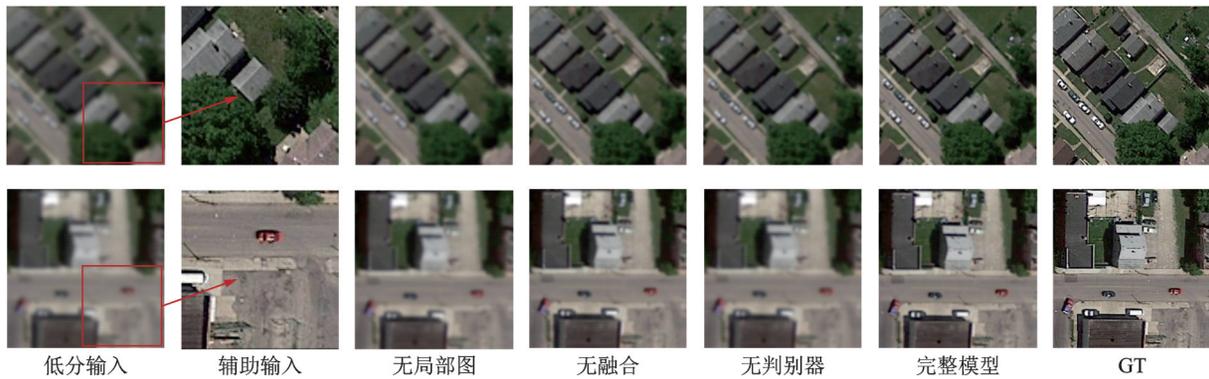


图7 本文方法消融实验结果

Fig.7 Ablation results of our method

3 结 论

本文基于已有遥感图像局部区域具有相对清晰的高分辨率及足够的场景信息的属性,提出了一种基于局部集群目标区域辅助的遥感图像超分辨率重建方法。与传统的遥感图像超分辨率重建方法不同的是,本文方法引入了遥感图像局部集群目标区域的细节特征信息到完整遥感图像的采样重建中。实验结果表明,本文方法可以有效地提高全局遥感图像的细节效果,尤其有利于分离聚集目标区域的边缘和丰富聚集目标区域的细节,显著地提升遥感图像的质量和可用性,特别是在低成本采集条件下。同时,本文提出的方法在视觉效果和数值结果上都优于几种现有的遥感图像超分辨率重建方法,验证了本文方法的有效性和优越性。未来研究可以进一步探索如何结合多源数据和多任务学习等方法,进一步提高遥感图像的分辨率和可用性,更好地辅助遥感图像的下游任务如目标检测等。

参考文献:

- [1] TSAI R Y, HUANG T S. Multiframe image restoration and registration[J]. *Multiframe Image Restoration and Registration*, 1984(1): 317-339.
- [2] 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*. [S.l.]: IEEE, 2016: 1874-1883.
- [3] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Vegas, USA: IEEE, 2016: 1646-1654.
- [4] LAI W S, HUANG J B, AHUJA N, et al. Deep laplacian pyramid networks for fast and accurate super-resolution[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE, 2017: 624-632.
- [5] LUO Y, ZHOU L, WANG S, et al. Video satellite imagery super resolution via convolutional neural networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(12): 2398-2402.
- [6] WANG Z, YI P, JIANG K, et al. Multi-memory convolutional neural network for video super-resolution [J]. *IEEE Transactions on Image Processing*, 2018, 28(5): 2530-2544.
- [7] WANG S, YUE B, LIANG X, et al. How does the low-rank matrix decomposition help internal and external learnings for super-resolution[J]. *IEEE Transactions on Image Processing*, 2017, 27(3): 1086-1099.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2016: 779-788.
- [9] LU T, MING D, LIN X, et al. Detecting building edges from high spatial resolution remote sensing imagery using richer convolution features network[J]. *Remote Sensing*, 2018, 10(9): 1496.
- [10] ZHANG Y, LIU J, BAI W, et al. Exploiting multi-scale spatial structures for sparsity based single image super-resolution[C]// *Proceedings of 2014 IEEE International Conference on Image Processing (ICIP)*. Paris, France: IEEE, 2014: 3877-3881.
- [11] FU J, ZHENG H, MEI T. Look closer to see better: Recurrent attention convolutional neural network for fine-grained image recognition[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE, 2017: 4438-4446.

- [12] LIU Y, CHENG M M, HU X, et al. Richer convolutional features for edge detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2017: 3000-3009.
- [13] DU X, QU X, HE Y, et al. Single image super-resolution based on multi-scale competitive convolutional neural network[J]. *Sensors*, 2018, 18(3): 1-17.
- [14] LUO Y, ZHOU L, WANG S, et al. Video satellite imagery super resolution via convolutional neural networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(12): 2398-2402.
- [15] WANG Z, JIANG K, YI P, et al. Ultra-dense GAN for satellite imagery super-resolution[J]. *Neurocomputing*, 2020, 398: 328-337.
- [16] FANG J, XIAO J, WANG X, et al. Arbitrary scale super resolution network for satellite imagery[J]. *China Communications*, 2022, 19(8): 234-246.
- [17] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 38(2): 295-307.
- [18] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA:IEEE, 2017: 4681-4690.
- [19] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[C]//Proceedings of Computer Vision—ECCV 2014: 13th European Conference. Zurich, Switzerland; Springer, 2014: 818-833.
- [20] WANG Y, SUN Y, LIU Z, et al. Dynamic graph cnn for learning on point clouds[J]. *ACM Transactions on Graphics*, 2019, 38(5): 1-12.
- [21] 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. Vegas, USA: IEEE, 2016: 770-778.
- [22] ADLER J, LUNZ S. Banach wasserstein gan[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal Canada: ACM, 2018: 6755-6764.
- [23] LIU Y, JIN L. Deep matching prior network: Toward tighter multi-oriented text detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 1962-1969.
- [24] VO N N, HAYS J. Localizing and orienting street views using overhead imagery[C]//Proceedings of Computer Vision—ECCV 2016: 14th European Conference. Amsterdam, The Netherlands; Springer, 2016: 494-509.
- [25] PALAZZI A, BORGHI G, ABATI D, et al. Learning to map vehicles into bird's eye view[C]//Proceedings of Image Analysis and Processing—ICIAP 2017: 19th International Conference. Catania, Italy: Springer, 2017: 233-243.
- [26] LU T, WANG J, ZHANG Y, et al. Satellite image super-resolution via multi-scale residual deep neural network[J]. *Remote Sensing*, 2019, 11(13): 1588.
- [27] HUANG J B, SINGH A, AHUJA N. Single image super-resolution from transformed self-exemplars [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2015: 5197-5206.

(编辑:张蓓)