引文格式：张巨林,陈德友,李自强. 一种面向多光谱多分辨率影像的超分辨率重建网络[J]. 地理空间信息, 2026, 24(7):86 –91. doi:10. 3969/j. issn. 1672–4623.2026.07.016

一种面向多光谱多分辨率影像的超分辨率重建网络

张巨林[1]，陈德友[2]，李自强[3]
（1. 广东南方数码科技股份有限公司，广东 广州 510000；2. 长安大学 地质工程与测绘学院，陕西 西安 710054；
3. 华南农业大学 工程学院，广东 广州 510000）

摘　要：在遥感科学中多光谱多分辨率影像因其全面覆盖性得到广泛关注，通过该影像合成高分辨率影像可以更好地描述地物信息。目前多数方法未通过统一的网络来增强所有波段，因此提出了一种面向多光谱多分辨率影像的轻量级超分辨率重建网络。通过生成潜在库构建多分辨率编码器、特征融合模块、特征增强模块和解码器架构，将10 m和20 m地面采样距离波段统一增强至5 m，输出高质量图像。定量对比分析显示，该方法在10 m、20 m波段上的评价指标均为最优，验证了其有效性。该方法为Sentinel–2的10 m、20 m波段增强至5 m分辨率提供了一种可行方案，可为图像分析和地球科学应用提供精确可靠的数据支持。

关键词：生成对抗网络；多光谱；多分辨率；Sentinel–2；超分辨率重建网络
中图分类号：P231　　**文献标志码：**B　　**文章编号：**1672–4623（2026）07–0086–06

A Super–resolution Reconstruction Network for Multi–spectral and Multi–resolution Images

ZHANG Julin[1], CHEN Deyou[2], LI Ziqiang[3]
(1. Guangdong Southern Digital Technology Co., Ltd., Guangzhou 510000, China;
2. School of Geological Engineering and Surveying, Chang'an University, Xi'an 710054, China;
3. College of Engineering, South China Agricultural University, Guangzhou 510000, China)

Abstract: In remote sensing science, multi-spectral and multi-resolution images have garnered widespread attention due to their comprehensive coverage. Synthesizing high-resolution images from such images allow for better description of ground object information. At present, most methods do not enhance all bands through a unified network. Therefore, we proposed a lightweight super-resolution reconstruction network for multi-spectral and multi-resolution images. We used generative latent banks to construct feature fusion module, feature enhancement module, and decoder architecture to uniformly enhance 10 m and 20 m ground sampling distance to 5 m, thereby outputting high-quality images. Quantitative comparative analysis shows that the method proposed in this paper achieves optimal performance compared to similar methods in terms of indices for both 10 m and 20 m bands, validating its effectiveness. In summary, this method provides a feasible solution for enhancing 10 m and 20 m bands of Sentinel-2 to 5 m resolution, offering precise and reliable data support for image analysis and earth science applications.

Key words: generative adversarial network, multi-spectral, multi-resolution, Sentinel-2, super-resolution reconstruction network

通过卫星影像可对陆地地表变化进行持续且全面的监测，常应用于军事、环境等领域[1–2]。欧洲航天局开发的Sentinel–2卫星搭载了一套多光谱仪器，能捕捉13个光谱波段的影像数据，覆盖可见光、近红外和短波红外波段，每个波段均有特定用途，并可提供地球表面的独特信息。为适应成像信噪比和数据存储的限制[3]，13个波段信息在不同空间分辨率下采集完成。在遥感背景下，图像超分辨率技术旨在从低分辨率观测中重建高分辨率图像，现有方法可分为基于插值的方法、基于重建的方法和基于学习的方法。基于插值和基于重建的方法是传统方法，基于插值的方法简单且计算效率高，但往往无法恢复高频信息，且易导致过度平滑；基于重建的方法则利用成像过程的先验知识以及正则化和优化等技术来恢复高分辨率图像，包括稀疏[4]、局部[5]和非局部[6]等方法，往往依赖于对图像先验的假设，且可能难以对不同图像进行泛化。基于学习的方法利用机器学习技术，尤其是深度学习来学习低分辨率和高分辨率图像之间的映射关系，并不依赖于对高分辨率与低分辨率图像间关系的明确建模，可直接从现有数据中学习这种关系。

项目来源：广东省重点领域研发计划资助项目（2023B0202090201）。
第一作者简介：张巨林（1982—），硕士，工程师，研究方向为GIS、测绘工程等，E–mail：ckdfkc@163.com。

SRCNN[7]首次采用卷积神经网络（CNN）开展相关的研究工作，能较好地学习非线性变换和空间依赖关系；随后RCAN[8]、ESRGAN[9]等类似方法被提出，通过更复杂的网络来学习更精细的细节，从而生成高质量的高分辨率图像。

以Sentinel-2数据为基础，目前已有多项研究专注于利用10 m波段的空间信息将20 m、60 m波段锐化为10 m。该锐化任务与全色锐化过程非常相似，通过注入来自更精细的全色波段的空间信息来锐化粗的多光谱波段。全色锐化方法主要包括统计建模类方法[10-13]和深度学习类方法两类。全色锐化只利用了单个精细波段，而Sentinel-2数据拥有4个精细波段[14]，该挑战可通过波段选择或聚合等方法来解决。然而，这些策略往往无法充分捕捉4个精细波段中存在的复杂空间细节；因此一些方法利用深度学习模型进行全色锐化，通过深度学习模型学习多分辨率输入与输出之间的复杂关系。自2018年Lanaras等提出DSen2以来，利用基于CNN的方法对Sentinel-2数据进行锐化的研究不断增加。FUSE[15]、SPRNet[16]、HFN[17]专注于改进推理时间等要素，并设计各种方法融合更精细波段的空间信息，以提高较粗波段的质量。目前还没有一种方法能同时将Sentinel-2所有波段增强到更高的分辨率。超分辨率模型专注于提升某一特定波段的空间分辨率；而全色锐化模型常涉及多分辨率输入，包括一个高分辨率的全色波段图像和一个或多个低分辨率的多光谱波段图像，其目标是将全色波段的空间细节注入到多光谱波段中，从而生成具有高空间分辨率的多光谱图像。因此，全色锐化模型的输出是一个融合了空间细节和光谱信息的高分辨率多光谱图像。此外，超分辨率模型在处理过程中通常不考虑波段间的依赖关系，在采用分步处理策略时可能会存在以下问题：①在全色锐化过程中，空间信息从全色波段传递到多光谱波段时可能存在精度损失；②不同波段的光谱响应特性存在固有差异。为解决该问题，本文提出一种基于深度学习的模型，利用单个端到端深度学习模型对多分辨率多光谱图像进行超分辨率处理。该模型通过生成潜在库[18]（GLEAN）构建多分辨率编码器、特征融合模块、特征增强模块、解码器架构，能将不同分辨率的频段作为输入，并通过基于生成对抗网络（GAN）的字典学习机制动态调节各波段特征权重，在保持光谱完整性的同时实现空间特征的跨分辨率一致性增强。为验证本文模型在多光谱多分辨率图像超分辨率处理中的有效性，在两个遥感场景上进行实验，结果表明该模型能显著提升多光谱图像的空间—光谱联合质量，有效消除边缘冲突并保持光谱完整性，验证了多分辨率编码器和特征融合机制（DFM）设计的合理性和有效性。

1　研究方法

1.1　网络架构

根据波段地面采样距离（GSD），将影像划分为A、B两组，A组由B2~B4、B8四个波段构成，GSD均为10 m，标记为A = {B2, B3, B4, B8}（GSD = 10 m）；B组由B5~B7、B8a四个波段构成，GSD均为20 m，标记为B = {B5, B6, B7, B8a}（GSD = 20 m）。A组波段的空间维度为$W \times H$，为实现超分辨率重建，本文给出一种网络架构将A组和B组波段上采样至空间分辨率为$2H \times 2W$。虽然StyleGAN3等模型在艺术生成领域表现优异，但其机制与遥感场景的需求存在本质差异，因此本文采用GLEAN[18]的潜在库查询机制建立网络，采用两个独立的编码器分别为A、B组的波段提取潜在向量和多分辨率卷积特征。

为有效融合来自不同编码器的多分辨率特征，引入特征融合模块，利用两个独立的编码器模块对不同分辨率的频段进行独立编码，进而生成潜在向量和卷积特征，可有效缓解同时学习图像保真度与自然性特征时所面临的计算与表示负担。预训练的StyleGAN模型用于学习潜在编码器库块，这些库块能够高效捕捉并转换输入数据的潜在特征。引入编码器、特征增强模块、解码器等关键组件细化整个编码—解码流程。实验选取20兆频段（64像素×64像素）、10兆频段（128像素×128像素）作为输入，通过多频段输入策略综合不同分辨率信息，最终生成尺寸为256像素×256像素、分辨率为5 m的高质量图像。此外，采用全连接层融合两个编码器提取的潜在向量，从而确保网络能充分利用来自不同GSD波段的信息，以实现更准确的超分辨率重建。总体网络架构见图1。

1.2　编码器

编码器旨在生成潜在向量，并从低分辨率输入图像中提取全面的特征信息。为最大化低分辨率输入图像中的信息提取效率，本文采用残差密集块作为初始层，旨在深层次挖掘图像特征。随着分辨率的逐步降低，特征提取通过一系列编码器模块实现。每个编码器模块均由步长为2和1的卷积层交替堆叠构成，卷积层均采用3×3的卷积核，且在每次卷积操作后添加PReLU激活函数以增强网络的非线性表达能力。通过

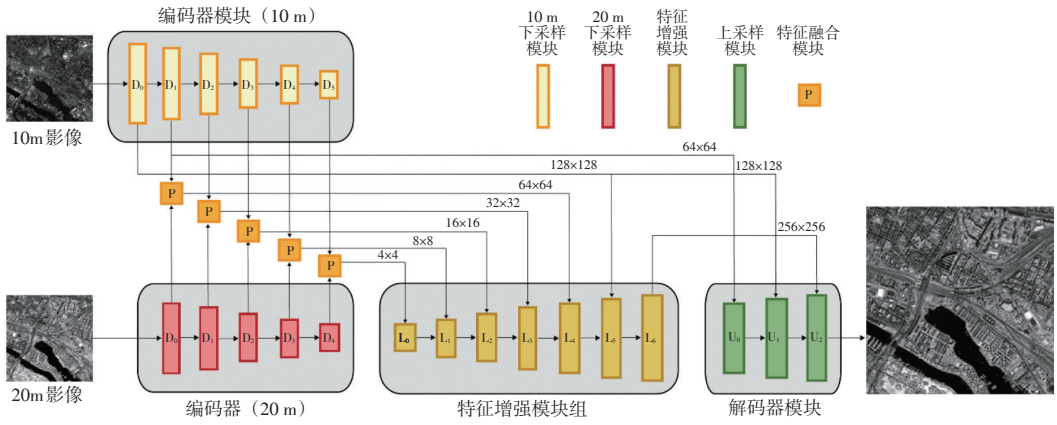


图1　总体网络架构

编码逐渐降低特征图的分辨率，直至尺寸为4像素×4像素，再通过全连接层生成潜在向量。值得注意的是，该方法可灵活采用多个潜在向量来捕捉图像的不同方面。编码器模块的核心功能是生成图像的压缩表示，即潜在向量，能传递关于图像的高级、抽象信息。此外，从编码器中提取的多分辨率特征图可捕捉图像局部细节，为GLEAN提供精确指导，在后续生成或恢复过程中重建这些局部结构。由于需处理两种图像波段（A和B），采用UA和UB两个编码器分别提取两个波段的特征，获得两个潜在向量；再采用全连接层将两个潜在向量合并为一个潜在向量。这种组合编码策略有效地将A和B波段图像的信息整合在一起，为后续的处理和分析提供了全面的图像表示。

1.3　特征融合与增强模块

特征融合模块采用双路径DFM[19]，包括求和与差分两个核心分支。求和分支用于强化图像的边缘信息，差分分支用于生成反映变化的特征，两个分支分别构建在两个密集连接的流上，且流内的权重是共享的。所有卷积操作均采用3×3的卷积核。DFM通过在每个流中整合多重特征，从而提升决策的准确性，不仅增强了模型的鲁棒性，还有效避免了因特征不对齐可能引发的伪变化问题。此外，由于密集连接中包含大量残差连接，每个流中的最后两个特征可被看作是前一个特征的残差或校正，这种机制有助于生成更加对齐的新特征图，并成功计算更精确的变化特征。为图像生成任务设计的预训练GAN通过提供先验知识和帮助生成精细细节来协助模型增强图像。由于两个编码器提供不同数量的卷积特征，为便于对不同数量的卷积特征进行条件处理，利用潜在向量进行输出。特征融合模块旨在捕捉特征图不同通道之间的相互依赖关系，使模型能根据各通道与当前任务的相关性为各通道分配各程度的重要性，进一步从组合信息中提取的最显著和最具判别性的特征。特征增强模块最后卷积层的步长为1，核大小为3×3，主要用于将特征的通道数转换为匹配量。GLEAN类似于一本字典，通过已知A集和B集的图像分布协助解码。本文方法针对不同风格层采用不同的潜在向量，可为最终输出提供更好的灵活性和控制性。

1.4　解码器

本文提出了一种新的解码器架构，旨在从给定的编码器特征中逐步恢复并细化图像分辨率，直至达到所需的精细度。解码过程不仅依赖于编码器的深度特征提取能力，还融合了来自潜在库的多分辨率特征，从而实现对图像信息的全面利用和精准重建。解码器由一系列解码器模块构成，这些模块按照特定顺序排列，执行渐进式的上采样操作。每个解码器模块中来自两个编码器（UA、UB）的特征和来自潜在库的多分辨率特征被连接在一起，形成一个综合的特征集合；再通过插值操作集合扩展到输入分辨率的两倍，为后续的卷积处理提供丰富的信息基础。将一个3×3的卷积层应用于扩展后的特征图上，进一步提炼和融合特征。引入像素注意力模块，根据特征图中的每个像素计算注意力权重。通过为像素分配不同的权重，该模块能捕捉像素之间的空间关系，使模型能够聚焦于图像中的关键区域，从而实现对细节的精准捕捉和恢复。值得注意的是，该模块的计算过程不仅依赖当前特征图，还隐形融入了上下文信息，使得模型能更全面地理解图像内容，并做出更加合理的像素级决策。因此，在解码器的每个模块中，像素注意力模块均显著提升了图像重建的质量和精度。综上所述，解码器通过巧妙融合来自编码器的深度特征、来自潜在库的多分辨率特征以及PA模块提供的空间注意力机制，实现了对图像信息的全面捕捉和精准重建。

2　实验结果与分析

2.1　实验数据

1）训练数据。本文采用SEN2VENμS[20]数据集进行训练。该数据集提供来自Sentinel-2的10 m和20 m分辨率无云地表影像，以及由VENμS卫星在同一天获取的5 m分辨率空间配准参考结果；涵盖了地球上的29个位置，包含132 955个256像素×256像素5 m分辨率的VENμS卫星影像及其相应Sentinel-2的10 m波段（B2、B3、B4、B8）和20 m波段（B5、B6、B7、B8a）影像。

2）测试数据。本文采用覆盖两个站点的Sentinel-2A影像。站点1涵盖加拿大弗雷德里克顿的市中心区域，范围为13 km×13 km，于2019年8月30日获取；站点2主要包含美国卡里古市城市化区域，大部分为农业农田，范围为15 km×15 km，于2021年6月18日获取。

2.2　实验设置

本文采用Adam优化器对StyleGAN进行训练，设定初始学习率为0.002 5；一阶和二阶矩衰减率分别为0和0.99；训练的小批量大小和轮次为32、1 000，且在每50个周期减半；批量大小和训练的周期数分别为4、200。

2.3　评估指标

本文的主要目的是给出一种针对多光谱多分辨率影像的轻量级超分辨率重建网络，并验证其在特定任务上的有效性，因此在实验中选择更相关的多光谱类处理方法进行比对，以突出本文方法的创新性和优势。本文采用均方根误差（RMSE）、峰值信噪比（PSNR）、结构相似性指数（SSIM）和通用图像质量指数（UIQI）[21]4个指标对图像质量进行评估。RMSE表示生成图像与参考图像之间的损失度；PSNR以分贝（dB）为单位，通过提供一个数值来量化噪声或失真的程度，反映处理后图像与原始图像的一致性，实验中直接计算PSNR的归一化状态；SSIM和UIQI是感知性度量指标，用于测量生成图像与真实图像之间的结构相似性，考虑了亮度、对比度和结构信息。本文采用自然图像质量指数[22]（NIQE）作为非参考图像质量评估指标。NIQE通过特征空间定义，关注图像中的边缘信息。

2.4　结果分析

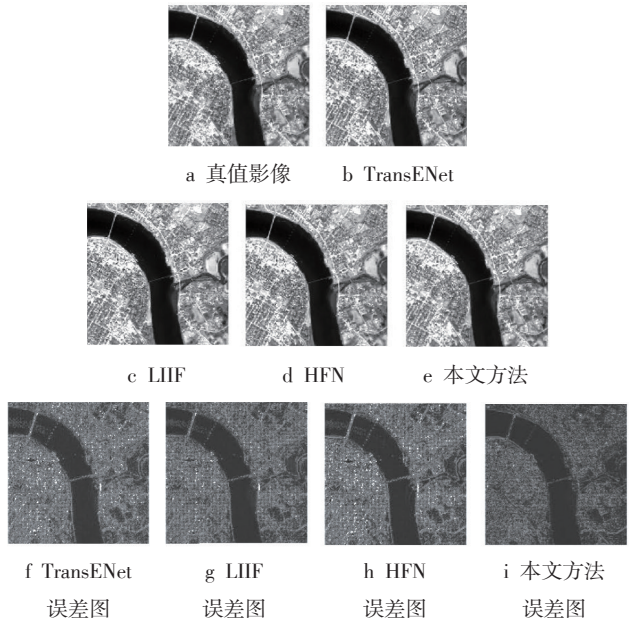
实验结果见表1、2，视觉效果和误差见图2、3。总体来说，本文方法在所有方法中表现最佳，与双三次插值法（Bicubic）、超分辨率深度卷积神经网络（EDSR）、跨通道网络（TransENet）、轻量级图像融合（LIIF）和ESRGAN相比，RMSE分别降低了27.6%、10%、11.66%、2%和1.38%。尽管ESRGAN等基于GAN的超分辨率方法能够生成高感知质量图像，但其在多光谱遥感场景中存在局限性（特征融合能力不足、光谱一致性缺失、计算效率差）；而GLEAN通过潜在库约束生成特征空间，可获得更高的处理性能。此外，本文方法的平均PSNR为27.12，平均SSIM和UIQI分别为0.90和0.91，验证了本文方法在实现更高感知质量和结构相似性方面的有效性和准确性。站点2的实验结果与站点1相似，本文方法的RMSE为

表1　站点1不同方法的定量评估结果

方法	RMSE	PSNR	UIQI	SSIM	NIQE
Bicubic	126.00	27.37	0.84	0.81	8.04
EDSR	101.26	29.00	0.87	0.89	8.62
TransENet	103.13	28.93	0.86	0.86	8.67
ESRGAN	93.00	29.33	0.88	0.87	8.00
LIIF	92.56	29.78	0.89	0.88	7.61
HFN	92.38	29.25	0.87	0.87	7.54
本文方法	91.10	27.12	0.91	0.90	7.10

表2　站点2不同方法的定量评估结果

方法	RMSE	PSNR	UIQI	SSIM	NIQE
Bicubic	335.74	21.28	0.62	0.43	13.57
EDSR	310.53	22.13	0.67	0.48	12.49
TransENet	298.49	22.26	0.72	0.59	12.29
ESRGAN	297.14	22.19	0.71	0.59	10.62
LIIF	299.75	22.25	0.72	0.60	10.64
HFN	180.09	26.77	0.87	0.83	9.21
本文方法	126.54	29.60	0.92	0.93	8.37



a 真值影像　b TransENet　c LIIF　d HFN　e 本文方法

f TransENet误差图　g LIIF误差图　h HFN误差图　i 本文方法误差图

图2　站点1实验比较结果与误差图

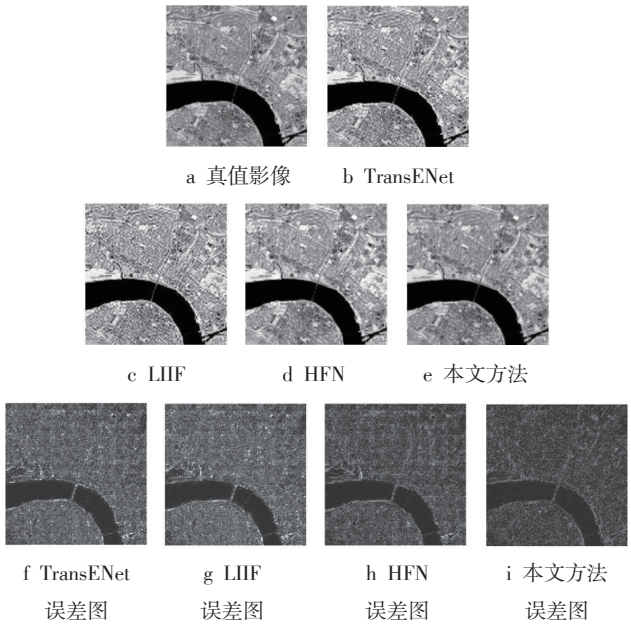


图3 站点2实验比较结果与误差图

126.54，低于其他对比方法；平均PSNR为29.60，优于其他比较方法；平均SSIM和UIQI也比次优模型提高了0.1和0.04。定量指标评估结果表明，本文方法在结构和频域的超分辨率重建方面有效。由图4可知，多次实验指标说明本文方法可以获得稳定的输出结果，验证了其有效性。

本文方法在定量指标上的优势主要源于以下设计：①通过GLEAN与GAN字典学习机制动态调节多波段特征权重，能有效缓解传统全色锐化中因光谱响应差异导致的边缘信息偏移问题；②多分辨率编码器

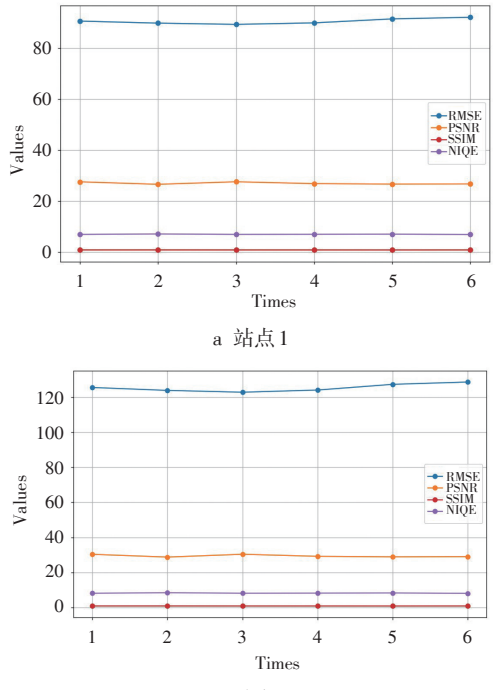


图4 本文方法6次实验指标值对比图

与特征增强模块的级联结构实现了跨分辨率空间特征一致性建模，在复杂地形场景中本文方法的RMSE较ESRGAN大幅降低，验证了其在保留高频细节的同时抑制伪影的能力；③基于GAN的对抗训练机制强化了高频纹理的真实性，使得SSIM与UIQI指标较TransENet进一步提高，尤其在建筑边缘等高频区域，结构相似性显著提升。

2.5 消融实验

为说明多分辨率编码器（包含特征融合模块）、特征增强模块、解码器模块的作用，本文针对站点2开展了消融实验，结果见表3、4。为分析多分辨率编码特征的作用，在模型中移除编码器层与整体的所有跨连接，此时模型类似于典型的GAN反演方法，即仅向GAN提供潜在向量。结果表明，相较于10 m波段，移除多分辨率编码器特征对20 m波段的性能影响更显著，可归因于在增强20 m波段时，网络会接收来自10 m分辨率编码器的编码信息，从而能利用10 m波段中的更高分辨率信息来辅助增强20 m波段。因此，多分辨率编码器特征有助于模型利用10 m和20 m分辨率波段之间的依赖关系，生成更好的细节。通过移除特征增强模块，将编码器特征直接连接到解码器模块形成编码器—解码器架构，来说明特征增强模块在增强超分辨率中的作用。结果表明，相较于移除其他模块，移除该模块的性能影响最显著，缺乏合适的先验信息将降低网络性能，即该模块在生成逼真细节的同时，能够保持与真实数据的一致性。通过移除解码器模块，直接将GLEAN的输出作为模型的最终输出，来评估解码器的影响。结果表明，移除解码器在一定程度上降低了网络的整体性能，编码器与解码器之间的跳跃连接有助于捕获整体结构，使生成的超分辨率影像细节更佳。

表3 10 m波段上的消融实验结果

模型	RMSE	PSNR	SSIM	UIQI
全网络	118.76	32.11	0.904	0.912
移除多分辨率编码器	167.16	28.54	0.887	0.898
移除特征融合与增强模块	184.15	27.99	0.878	0.884
移除解码器	188.98	27.37	0.853	0.867

表4 20 m波段上的消融实验结果

模型	RMSE	PSNR	SSIM	UIQI
全网络	118.98	32.18	0.921	0.915
移除多分辨率编码器	168.43	28.55	0.889	0.901
移除特征融合与增强模块	184.35	27.79	0.854	0.887
移除解码器	188.88	27.43	0.842	0.862

3 结 论

本文提出了一种将Sentinel-2数据的10 m和20 m波段同时超分辨率到5 m的方法。本文方法包括编码器、特征融合模块、特征增强模块、解码器等部分，其中编码器用于查找低分辨率输入图像的高分辨率对应图像，解码器则根据编码器的多分辨率编码对潜在存储库的输出进行进一步微调。将本文方法与Bicubic、TransENet、LIIF、ESRGAN、HFN等方法进行比较。视觉和定量比较结果表明，本文方法在多个指标上表现优于其他方法。尽管本文方法提高了高光谱影像超分辨率重建性能，但仍存在局限性：高分辨率目标设定受限于数据特性，盲目提升分辨率可能导致光谱失真；波段覆盖范围需进行针对性调整，跨传感器迁移需优化模型结构。未来将聚焦轻量化模型设计与跨传感器泛化能力研究，通过模型剪枝、结合去噪预处理等方式降低资源消耗并提升鲁棒性，以拓展方法适用边界，增强学术与实用价值。

参考文献

[1] 闾枫,刘红敏. 基于纹理分解和联合回归分析的SAR图像超分辨率[J]. 现代雷达,2022,44(1):49-55

[2] 张志德,葛贵银,刘祥梅,等. 基于雷达光学影像融合的养殖池塘提取方法[J]. 现代雷达,2022,44(12):93-100

[3] Malczewska A,Wielgosz M. How Does Super-resolution for Satellite Imagery Affect Different Types of Land Cover? Sentinel-2 Case[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2024,17:340-363

[4] Lu X, Yuan Y, Yan P. Image Super-resolution Via Double Sparsity Regularized Manifold Learning[J]. IEEE Transactions on Circuits and Systems for Video Technology,2013,23(12):2022-2033

[5] Sun J, Xu Z, Shum H Y. Image Super-resolution Using Gradient Profile Prior[C]. IEEE Conference on Computer Vision and Pattern Recognition,2008

[6] Yang C Y,Huang J B,Yang M H. Exploiting Self-similarities for Single Frame Super-resolution[C]. Computer Vision-ACCV,Germany: Springer,2011:497-510

[7] 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, 2016, 38(2):295-307

[8] Zhang Y,Li K,Li K,et al. Image Super Resolution Using very Deep Residual Channel Attention Networks[C]. European Conference on Computer Vision (ECCV),2018:286-301

[9] Wang X. ESRGAN: Enhanced Super-resolution Generative Adversarial Networks[C]. European Conference on Computer Vision (ECCV) Workshops,2018

[10] Kaplan G. Sentinel-2 Pan Sharpening-comparative Analysis[C]//Proceedings of the Second International Electronic Conference on Remote Sensing,2018:345

[11] Zhao X, Liu H, Zhang J, et al. A Spectral Mapping Based Intensity Modulation for Pan-sharpening[C]//Proceeding of the IEEE International Geoscience and Remote Sensing Symposium,2019:843-846

[12] Vivone G. A Critical Comparison of Pan-sharpening Algorithms[C]//Proceedings of the IEEE International Geoscience and Remote Sensing Symposium,2014:191-194

[13] Wang P, Yao H, Huang B, et al. Multi-resolution Analysis Pan-sharpening Based on Variation Factor for Multispectral and Panchromatic Images from Different Times[J]. IEEE Transactions on Geoscience and Remote Sensing,2023,61:1-17

[14] Wang Q,Shi W,Li Z,et al. Fusion of Sentinel-2 Images[J]. Remote Sensing of Environment,2016,187:241-252

[15] Gargiulo M,Mazza A,Gaetano R,et al. Fast Super-resolution of 20 m Sentinel-2 Bands Using Convolutional Neural Networks[J]. Remote Sensing,2019,11(22):2635-2652

[16] Wu J,He Z,Hu J. Sentinel-2 Sharpening Via Parallel Residual Network[J]. Remote Sensing,2020,12(2):279-298

[17] Wu J,Lin L,Zhang C,et al. Generating Sentinel-2 All-band 10-m Data by Sharpening 20/60-m Bands: A Hierarchical Fusion Network[J]. ISPRS Journal of Photogrammetry and Remote Sensing,2023,196:16-31

[18] Chan K C,Wang X,Xu X,et al. GLEAN: Generative Latent Bank for Large-factor Image Super-resolution[C]// Proc. IEEE Conf. Comput. Vis. Pattern Recognit. ,2021:14245-14254

[19] Chen P,Hong D. FCCDN: Feature Constraint Network for VHR Image Change Detection[J]. Journal of Photogrammetry and Remote Sensing,2022,187:101-119

[20] Michel J,Vinasco-Salinas J,Inglada J,et al. SEN2VENμS,a Dataset for the Training of Sentinel-2 Super-resolution Algorithms[J]. Data,2022,7(7):96-112

[21] Wang Z, Bovik A. A Universal Image Quality Index[J]. IEEE Signal Processing Letters,2022,9(3):81-84

[22] Mittal A,Soundararajan R,Bovik A C. Making a ‘Completely Blind’ Image Quality Analyzer[J]. IEEE Signal Processing Letters,2013,20(3):209-212