

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2024)08-2113-24

论文引用格式: Zhang T, Wang B F, Fu Y, Liu S R, Ye J C, Shan P H and Yan C G. 2024. Deep learning-based spectral image super-resolution: a survey. Journal of Image and Graphics, 29(08):2113-2136(张涛, 王彬泮, 付莹, 刘松荣, 叶吉超, 单培红, 颜成钢. 2024. 基于深度学习的光谱图像超分辨率综述. 中国图象图形学报, 29(08):2113-2136)[DOI:10.11834/jig.230747]

## 基于深度学习的光谱图像超分辨率综述

张涛<sup>1,2</sup>, 王彬泮<sup>3</sup>, 付莹<sup>3\*</sup>, 刘松荣<sup>4</sup>, 叶吉超<sup>5</sup>, 单培红<sup>6</sup>, 颜成钢<sup>1,2</sup>

1. 杭州电子科技大学通信工程学院, 杭州 310018; 2. 杭州电子科技大学丽水研究院, 丽水 323000;
3. 北京理工大学计算机学院, 北京 100081; 4. 浙江交投高速公路运营管理有限公司, 丽水 323000;
5. 国网浙江省电力有限公司, 丽水 323000; 6. 浙江省公众信息产业有限公司, 杭州 310000

**摘要:** 光谱图像超分辨率技术的目的是从低空间分辨率和光谱分辨率的图像中恢复高空间分辨率和光谱分辨率的图像, 在植被调查、地质勘探、环境保护、异常检测和目标追踪等遥感领域有着广泛应用。随着深度学习的兴起, 基于深度学习的光谱图像超分辨率算法如雨后天春笋般涌现, 特别是卷积神经网络、Transformer、生成对抗网络以及深度展开网络等技术的出现使图像融合性能产生了质的飞跃。本文全面探讨和分析了不同光谱图像超分辨率任务场景下的前沿深度学习算法。首先, 介绍了光谱图像超分辨率的基本概念, 以及不同超分辨率场景的定义。针对单图超分辨率和融合超分辨率两大场景, 从超分辨率维度、数据类型、基本框架和监督方式等多个角度详细阐述了各类方法的基本思想和特点。其次, 总结了各类算法存在的局限性, 并提出了进一步改进的方向。然后, 简要介绍了不同融合场景中常用的数据集, 并明确了各种评估指标的具体定义。对于每种超分辨率任务, 从定性评估、定量评估等多个角度全面比较了代表性算法的性能。最后, 总结了研究结果, 并探讨了光谱图像超分辨率领域所面临的一些严峻挑战, 同时对未来可能的研究方向进行了展望。所提及的算法和数据集已汇总至 <https://github.com/ColinTaoZhang/DL-based-spectral-super-resolution>。

**关键词:** 深度学习; 超分辨率; 光谱图像; 单图超分辨率; 融合超分辨率

## Deep learning-based spectral image super-resolution: a survey

Zhang Tao<sup>1,2</sup>, Wang Binpeng<sup>3</sup>, Fu Ying<sup>3\*</sup>, Liu Songrong<sup>4</sup>, Ye Jichao<sup>5</sup>, Shan Peihong<sup>6</sup>, Yan Chenggang<sup>1,2</sup>

1. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China;
2. Lishui Institute, Hangzhou Dianzi University, Lishui 323000, China; 3. School of Computer Science and Technology, Beijing Institute of Technology, Beijing 100081, China; 4. Zhejiang Communications Involvement Expressway Operation Management Co., Ltd., Lishui 323000, China; 5. State Grid Zhejiang Electric Power Co., Ltd., Lishui 323000, China;
6. Zhejiang Public Information Industry Co., Ltd., Hangzhou 310000, China

**Abstract:** The goal of spectral image super-resolution technology is to recover images with high spatial resolution and spectral resolution from images with low spatial resolution and spectral resolution. Images of high spatial and spectral resolution are widely used in remote sensing fields such as vegetation survey, geological exploration, environmental protection, anomaly detection, and target tracking. With the rise of deep learning, spectral image super-resolution algorithms based on deep learning have emerged. In particular, the emergence of technologies such as end-to-end neural networks, generative

收稿日期: 2023-10-17; 修回日期: 2024-03-05; 预印本日期: 2024-03-12

\* 通信作者: 付莹 fuying@bit.edu.cn

基金项目: 国家自然科学基金项目(62171038, 62331006)

Supported by: National Natural Science Foundation of China (62171038, 62331006)

adversarial networks, and deep unfolding networks has made a qualitative leap in spectral image super-resolution performance. This study comprehensively discusses and analyzes cutting-edge deep learning algorithms under different spectral image super-resolution task scenarios. First, we introduce the basic concepts of spectral image super-resolution and the definitions of different super-resolution scenarios. Focusing on the two major scenarios of single-image super-resolution and fusion super-resolution, the basic concepts of various methods are elaborated from multiple perspectives such as super-resolution dimensions, super-resolution data types, basic frameworks, and supervision methods, and their characteristics are discussed. Second, this study summarizes the limitations of various algorithms and proposes directions for further improvement. Furthermore, the commonly used datasets in different fusion scenarios are briefly introduced, and the specific definitions of various evaluation indicators are clarified. For each super-resolution task, this study comprehensively compares the performance of representative algorithms from multiple perspectives such as qualitative evaluation and quantitative evaluation. Finally, this study summarizes the research results and discusses some serious challenges faced in the field of spectral image super-resolution, while also looking forward to possible future research directions. First, from the perspective of super-resolution scenarios, the existing spectral image super-resolution algorithms can be divided into two categories, namely, single image super-resolution and fusion-based super-resolution. Specifically, single spectral image super-resolution is designed to generate high-resolution output images from a single low-resolution input image. According to the direction of super-resolution, single image super-resolution can be divided into spatial super-resolution, spectral super-resolution, and spatial-spectral super-resolution. Fusion-based spectral image super-resolution is designed to fuse images of different modes into a single image with high spatial and spectral resolution. According to the different modes of fusion images, fusion-based spectral image super-resolution can be divided into pansharpening and multispectral and hyperspectral images fusion. Moreover, deep learning-based spectral image super-resolution methods can be categorized into end-to-end neural network based (E2EN-based) spectral image super-resolution framework, generative adversarial network-based (GAN-based) spectral image super-resolution framework, and deep unfolding network-based (DUN-based) spectral image super-resolution framework according to the network architecture. The E2EN-based spectral image super-resolution framework designs various network structures to mine nonlinear mapping relationships between low-resolution and high-resolution images. According to the basic computing unit of network structure, it can be divided into convolutional neural network-based method and Transformer-based method. The GAN-based spectral image super-resolution framework realizes the spectral image super-resolution through the game between the generator and the discriminator. The DUN-based spectral image super-resolution framework combines traditional optimization algorithms and deep learning, and it unfolds iterative optimization steps to form deep neural networks. From the perspective of supervision paradigm, the deep learning algorithms can also be classified into unsupervised and supervised categories. The supervised approaches minimize the distance between super-resolved spectral image and ground truth, while unsupervised algorithms design loss function through the similarity between super-resolved and input images or through the game of the generator and the discriminator. Our critical review describes the main concepts and characteristics of each approach for different spectral image super-resolution tasks according to the network architecture and supervision paradigm. Second, we introduce the representative datasets and evaluation metrics. We divide the datasets into categories of single spectral image super-resolution datasets and fusion-based spectral image super-resolution datasets. Furthermore, the evaluation metrics can be grouped into full-reference metrics and no-reference metrics. Some full-reference metrics are widely used for the quantitative evaluation of spectral image super-resolution, including peak signal-to-noise, structural similarity, spectral angle mapper, and relative dimensionless global error in synthesis. Third, we provide the quantitative and qualitative experimental results of different spectral image super-resolution tasks. Finally, we summarize the challenges and problems in the study of deep learning-based spectral image super-resolution and conduct forecasting analysis, such as high-quality spectral image super-resolution dataset, model-driven and deep learning combined spectral image super-resolution method, real-time spectral image super-resolution, and comprehensive evaluation metrics. The methods and datasets mentioned are linked at <https://github.com/ColinTaoZhang/DL-based-spectral-super-resolution>.

**Key words:** deep learning; super-resolution; spectral image; single image super-resolution; fusion-based super-resolution

## 0 引言

光谱图像是一种包含多个连续光谱波段信息的图像。与传统的彩色图像不同,彩色图像通常只包含3个颜色通道(红、绿和蓝),光谱图像包含了更多的光谱信息,通常由数十甚至数百个连续光谱波段组成,每个波段捕获了特定波长范围内的光谱信息。光谱图像能够解决彩色图像无法解决的“同色异谱”问题,在植被调查、地质勘探、环境保护、异常检测和目标追踪等遥感领域有着广泛应用(Murguia等, 2010; Hohmann等, 2017; Li等, 2017a; McElfresh等, 2018)。

然而,由于信噪比和时间的限制,在遥感中需要权衡空间分辨率和光谱分辨率。高光谱图像的光谱分辨率很高,但空间分辨率很低。这意味着图像可能无法捕捉到细微的地表特征,如小型建筑物、道路上的细节以及植被的个体植株等。并且,较低的空间分辨率会导致空间混叠效应(Keshava和Mustard, 2002; Bioucas-Dias等, 2012; Heylen等, 2014; Shi和Wang, 2014),即不同地物或对象在同一像素内混合在一起,导致信息丢失和模糊。这对于图像中存在复杂的地物和地貌时尤为显著。相反,多光谱和全色图像产生较高的空间分辨率,但光谱分辨率很低。这意味着图像无法有效利用光谱信息而难以区分不同目标,如形状相似的植被。因此,利用信号处理技术提高遥感光谱图像的空间分辨率和光谱分辨率是非常有必要的。

为了解决这个问题,最直接的方法是提高光学器件的精度和传感器的分辨率,采集更高分辨率的图像,然而这种方法往往需要极其高昂的成本。为了降低成本,研究人员致力于使用计算的方法提升遥感光谱图像的分辨率(Fu等, 2021; 张良培等, 2022; 李欣等, 2018; 焦姣和吴玲达, 2019; 方帅和许漫, 2022; 唐霖峰等, 2023; 聂江涛等, 2023)。其只需要对采集到的光谱图像进行一些计算,就可以获得更高分辨率、更清晰的图像。根据输入数据的类型,可以把光谱图像超分辨率分为光谱单图超分辨率(single spectral image super-resolution, SSISR)和光谱融合超分辨率(fusion-based spectral image super-resolution, FSISR)。

光谱单图超分辨率旨在从单一低分辨率输入图

像生成高分辨率的输出图像。根据超分辨率方向的不同,光谱单图超分辨率可以分为空间超分辨率(spatial super-resolution, SpaSR)、光谱超分辨率(spectral super-resolution, SpeSR)和空间—光谱超分辨率(spatio-spectral super-resolution, SSSR)。

光谱融合超分辨率旨在将不同模式的图像融合到单一图像中,实现高空间—光谱分辨率图像的获取。根据融合图像模式的不同,光谱融合超分辨率可以分为全色光谱融合超分辨率(pansharpening, PS)和多光谱高光谱融合超分辨率(multispectral and hyperspectral image fusion, MHF)。各类光谱图像超分辨率示意图如图1所示。

光谱图像超分辨率和自然图像超分辨率存在一定相似之处。常见的自然图像超分辨率也可分为单图超分辨率和融合超分辨率,如图2所示。光谱图像超分辨率与自然图像超分辨率也存在大量不同之处,主要可总结为以下3点:

1)超分辨率数据不同。自然图像超分辨率一般针对彩色图像或者灰度图像,而光谱图像超分辨率则针对高光谱图像、多光谱图像、彩色图像和灰度图像等多种不同数据类型。换言之,光谱图像超分辨率使用数据类型更广。

2)超分辨率维度不同。自然图像超分辨率关注于空间超分辨率,而光谱图像超分辨率在关注空间超分辨率的同时也会关注光谱超分辨率和空间—光谱超分辨率。换言之,光谱图像超分辨率维度更多。

3)超分辨率模式不同。针对融合超分辨率,自然图像超分辨率利用多幅相同模式、相同分辨率的图像,而光谱图像融合超分辨率则利用多幅不同模式、不同模式的图像。换言之,光谱图像超分辨率输入数据模式差异更大。

在深度学习广泛应用于图像处理领域之前,光谱图像超分辨率问题已经得到了深入研究。最基础的方法是直接利用相邻像素的信息进行非线性插值(Li和Orchard, 2001),如双线性和双三次插值。然而,这些方法往往会导致边缘模糊和振铃效应。在过去的几十年中,有许多光谱图像超分辨率算法相继提出。传统方法一般通过挖掘高维数据相关性和冗余性等属性,引入各种手工先验构建优化模型,从低分辨率光谱图像恢复高分辨率光谱图像。常用的光谱图像手工先验主要包括稀疏性(Dian等, 2017; Li等, 2018; Han等, 2017; Tang等, 2019; Fu等,

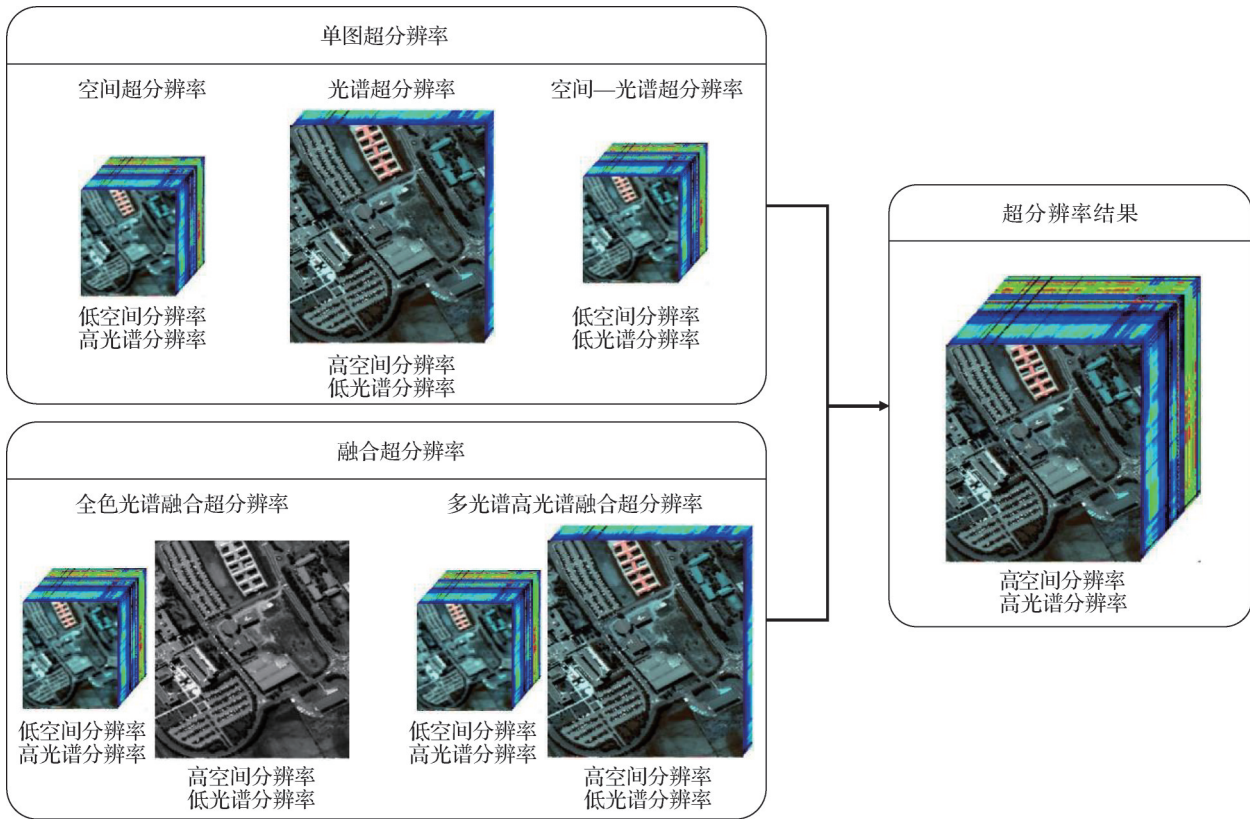


图1 各类光谱图像超分辨率示意图

Fig. 1 Schematic diagram for various categories of spectral image super-resolution

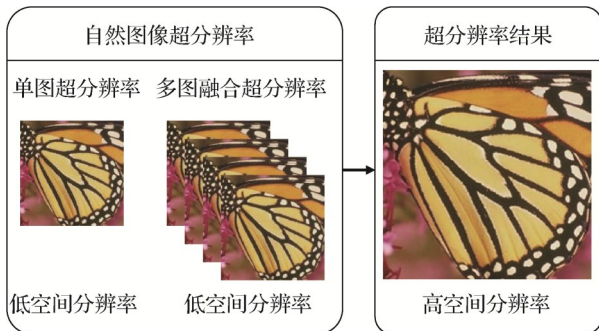


图2 自然图像超分辨率示意图

Fig. 2 Schematic diagram of natural image super-resolution

2018b, 2020; Lin 等, 2018; Zhang 等, 2018)、低秩性 (Wang 等, 2017; Fu 等, 2018a; Xu 等, 2020; Dian 和 Li, 2019)等。尽管现有的传统光谱超分辨率方法在多数情况下能够得到较为满意的结果,但依然存在一些阻碍其实际应用的问题。首先,现有方法通常要求解目标函数以恢复高分辨率光谱图像,恢复速度很慢;其次,所使用的数据稀疏性、低秩性等手工先验知识难以完整表达现实世界复杂的光谱数据。

深度学习以其强大的数据特征表达能力流行于图像处理领域,并在诸多图像处理任务上取得了显著的性能优势,如图像分类(He 等, 2016; Huang 等, 2017; Hu 等, 2018)、目标检测(Ren 等, 2017; Redmon 等, 2016; Liu 等, 2016)、语义分割(Shelhamer 等, 2017; Chen 等, 2018; Chen, 2022)和图像增强(Zhang 等, 2022a, 2023e, 2024)等。随着深度学习的发展,基于深度学习的遥感光谱图像超分辨率方法也如雨后春笋般出现。现有的基于深度学习的光谱图像超分辨率方法主要学习低分辨率图像与高分辨率图像之间的非线性映射关系,实现光谱图像超分辨率。根据采用的网络架构,基于深度学习的光谱图像超分辨率方法可以分为基于端到端网络(end-to-end network, E2EN)的光谱图像超分辨率框架、基于对抗生成网络(generative adversarial network, GAN)的光谱图像超分辨率框架和基于深度展开网络(deep unfolding network, DUN)的光谱图像超分辨率框架。图3展示了这三类光谱图像超分辨率框架的整体流程。

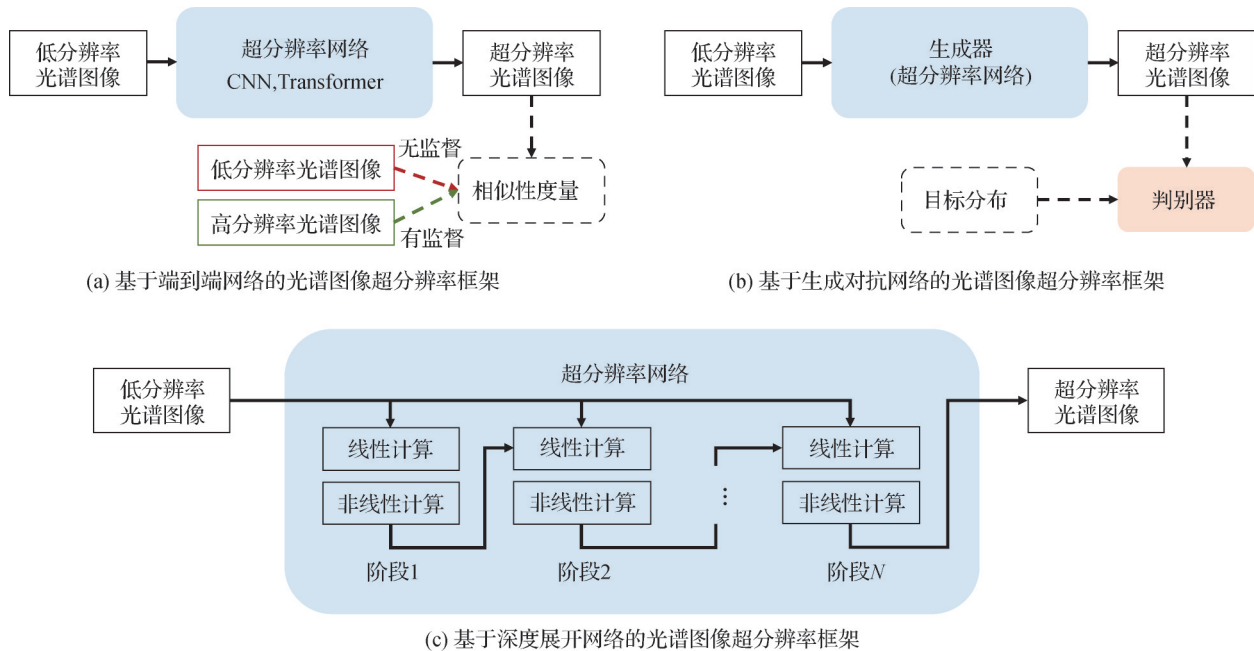
1) 基于端到端网络(E2EN)的光谱图像超分辨

率框架通过设计网络结构挖掘各式非线性映射关系,实现端到端光谱图像超分辨率。根据构建网络的基本计算单元,可以将其分为基于卷积神经网络(convolutional neural network, CNN)的方法和基于Transformer的方法,分别将卷积层和Transformer模块作为基本计算单元。图3(a)展示了基于E2EN的光谱图像超分辨率框架。当然,也有研究者将CNN和Transformer相结合用于光谱图像超分辨率(Du等,2023)。

2)基于生成对抗网络(GAN)的光谱图像超分辨率框架通过生成器与判别器之间的博弈,实现光谱图像超分辨率。图3(b)是一种主流的基于GAN的光谱图像超分辨率框架,通过判别器迫使生成器生

成的超分辨率结果与目标图像在概率分布上趋于一致。常见的目标图像一般为高分辨率光谱图像(Li等,2022b)。

3)基于深度展开网络(DUN)的光谱图像超分辨率框架将传统优化算法与深度学习相结合,并将迭代优化步骤展开构成深度神经网络,实现光谱图像超分辨率。如图3(c)所示,基于DUN的光谱图像超分辨率框架由线性计算单元和非线性计算单元构成,线性计算单元一般为优化算法中数据保真项相关的计算,非线性计算单元一般为先验项相关的计算,而非线性计算单元一般为CNN或者Transformer网络。此外,也有方法将预训练好的深度网络插入优化算法并进行迭代优化得到高分辨率光谱图像(Lai等,2022)。



(c) 基于深度展开网络的光谱图像超分辨率框架

图3 不同光谱图像超分辨率框架示意图

Fig. 3 Schematic diagram of different spectral image super-resolution frameworks  
(a) E2EN-based framework; (b) GAN-based framework; (c) DUN-based framework)

根据训练过程中使用的监督范式,基于深度学习的光谱图像超分辨率方法还可以分为有监督框架和无监督框架。本文根据网络结构和监督范式,详细地介绍基于深度学习的光谱图像单图超分辨率和融合超分辨率的研究进展,以便研究人员能够更好地更快地掌握光谱图像超分辨率领域的研究现状。本文的结构框架如图4所示。首先,根据网络结构和监督范式介绍有代表性的光谱图像单图超分辨率和融合超分辨率方法。其次,介绍常用的光谱图像超分辨率数据集和评价指标,并展示了各个有代表性

的方法的指标性能和复原结果。最后,对全文进行总结,并结合光谱图像超分辨率中存在的挑战提出展望。

## 1 方法

### 1.1 光谱单图超分辨率

光谱单图超分辨率旨在从单一低分辨率输入光谱图像生成高分辨率的输出光谱图像,根据超分方向的不同,单图超分辨率又可以分为空间超分辨率、

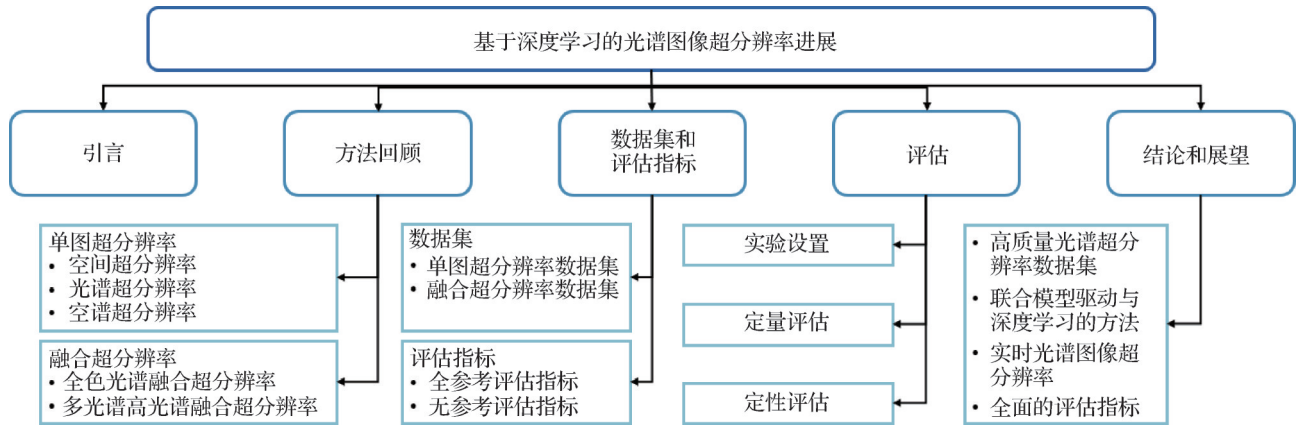


图4 本文结构框架

Fig. 4 Overall framework of this survey

光谱超分辨率和空间—光谱超分辨率。

### 1.1.1 空间超分辨率

由于成像传感器技术的权衡,光谱图像在保持高光谱分辨率时空间分辨率相对较低,导致其应用受到限制。光谱图像空间超分辨率旨在将低空间分辨率的输入图像转化为高空间分辨率的输出图像,空间超分辨率专注于提高图像的视觉清晰度和细节,而不涉及光谱信息的增加。

根据网络的主体架构,光谱图像单图空间超分辨率方法可以分为基于端到端网络的方法和基于生成对抗网络的方法两种类型。

基于端到端网络的自然图像超分辨率方法取得了很大的成功,但若直接将其迁移到光谱图像超分辨率,则会产生严重的光谱失真。光谱图像超分辨率与自然图像超分辨率最主要的区别就在于如何保留光谱特征。Li等人(2017b)提出了一种将空间约束策略与深度谱差卷积神经网络相结合的光谱图像空间超分辨率方法。Mei等人(2017)将3D卷积用于挖掘相邻像素的空间相关性和相邻波段的光谱相关性,从而减轻以逐通道方式将自然图像超分辨率算法直接应用于光谱图像时的光谱失真。Yang等人(2019)提出了一种用于光谱空间超分辨率的多尺度小波3D卷积神经网络,预测高分辨率光谱图像的小波系数,而不是直接重建高分辨率光谱图像。Xie等人(2019b)将深度神经网络提取的特征矩阵与超分辨率光谱图像的非负矩阵分解策略相结合,进而保留更多光谱信息。Hu等人(2020)从光谱图像是一个同时具有空间信息和光谱信息的三维数据立体的观点出发,提出光谱空间超分辨率的关键是

如何有效地利用连续低分辨率波段中的光谱信息,并构建了一个集成光谱差异、并行卷积和帧内融合等计算的神经网络。

然而,使用3D卷积神经网络会导致大量的计算代价。为降低计算开销,Li等人(2019)将光谱和空间信息分别进行考虑再使用融合模块融合特征。光谱方面主要由一维卷积组成,对光谱的微小变化进行特征提取;而空间通路中则采用二维卷积,配合注意力机制,对空间信息进行特征提取。Hu等人(2019)先使用深度信息蒸馏网络和光谱插值获取粗略的高分辨率光谱图像,再对其进行内部融合以进一步利用空谱信息,最终获取更精细的高分辨率光谱图像。Li等人(2020c)提出了混合卷积网络,通过2D/3D混合卷积替代基础卷积对光谱图像提取特征。在2D卷积单元中,设计了局部特征融合以自适应地分析2D卷积单元中的所有层次特征。在3D卷积单元中,采用空间和光谱可分离的3D卷积提取空间和光谱信息,进而减少内存使用和训练时间。Liang等人(2023)使用矩阵分解网络提升光谱图像盲超分辨率精度。

上述方法往往把光谱信息和空间信息分开进行处理,忽略了二者之间的联系。为综合挖掘空谱相关性,Zhang等人(2023b)引入了隐式神经表示(implicit neural representation, INR),通过连续函数将空间坐标映射到其相应的光谱值以实现光谱图像表示。Wang等人(2021a)设计了一个双通道网络,共同利用来自当前通道和相邻通道的信息,从而提高二维空间域的学习能力。Lu等人(2021)利用CNN挖掘图像的空谱协同信息,并采用双分支架构

和空间扩展变换函数表征高分辨率和低分辨率光谱图像之间的空间相关性。

此外,全局信息与局部信息的结合对光谱图像空间超分辨率也具有很重要的作用。Jiang等人(2020)率先引入了光谱注意力机制,并结合空间残差模块联合挖掘空谱信息。Magid等人(2021)提出了动态高通滤波模块和矩阵多通道注意力模块,以改进局部和全局高频特征学习。Liu等人(2021)设计了由特征协方差统计构造的光谱注意力机制自适应地校准特征以充分挖掘全局光谱先验。Fu等人(2021)和Wang等人(2022)从序列角度对全局光谱相关性进行建模,通过循环网络挖掘光谱数据通道之间的互补和连续信息,实现光谱图像空间超分辨率。Hu等人(2022b)提出了多级渐进光谱超分辨率网络,使用稠密非局部和局部模块结合局部和全局特征,并重建不同层级超分辨率光谱图像。Li等人(2022a)提出了两阶段光谱图像超分辨率方法,分为粗略阶段和精细阶段。为了从全局角度挖掘相关性,在精细阶段通过光谱角度约束的反投影方法学习空谱一致性。近年来,Transformer网络展现了强大的长距离建模能力。Long等人(2023)提出双注意力机制的Transformer光谱图像超分辨率网络,使用空间注意力和光谱注意力作为基本计算单元,分别挖掘长距离空间相关性和全局光谱相关性。Zhang等人(2023c)使用光谱相关系数构建更高效的Transformer网络用于光谱图像超分辨率。

随着生成对抗网络(GAN)在图像生成领域取得了巨大突破,有许多研究者在图像超分任务上也使用生成对抗网络取得了优越的效果。Dou等人(2020)创新性地生成对抗网络引入光谱空间超分辨率领域,结合3D卷积和注意力机制,不仅可以利用空间特征而且可以保留光谱特性。Li等人(2022b)提出了基于注意力机制的生成对抗网络,应用了局部和全局注意力机制。局部注意力关注需要更多关注的地球表面的结构组成部分,而全局注意力则用于捕获通道和空间维度的长距离相互依赖关系,以进一步优化超分辨光谱图像的细节。虽然生成对抗网络(GAN)已被证明是基于深度学习图像超分辨率的有效框架,但是基于GAN的模型的优化过程经常遇到模式崩溃的问题,很可能导致生成的光谱图像出现空谱失真。为了缓解模式崩溃问题,Shi等人(2022)将光谱图像视为嵌入潜在空间的高

维流形,将生成对抗网络模型的优化转化为学习高分辨率光谱图像在潜在空间中的分布的问题,使得生成的超分辨率光谱图像的分布更接近于原始高分辨率光谱图像对应的分布。基于此,Shi等人(2022)提出了与潜在编码器耦合的生成对抗网络模型,可以将生成的空谱特征从图像空间映射到潜在空间,并使用耦合分量对生成样本进行约束。

### 1.1.2 光谱超分辨率

由于当前成像技术的限制,获取高空谱分辨率光谱图像很困难。作为一种替代方法,光谱超分辨率旨在从相应的高分辨率RGB图像/多光谱图像(multispectral image)中重建高空谱分辨率图像。

深度学习光谱超分辨率方法大多是基于端到端卷积神经网络(CNN)的。Xiong等人(2017)首先提出了基于CNN的欠采样光谱图像重建框架,首先通过简单插值在光谱维度上进行上采样,然后使用CNN对光谱插值后的图像进行增强。Li等人(2020b)利用相机光谱响应先验构建自适应权重的注意力机制,实现光谱图像超分辨率。Zhang等人(2020a)提出了像素感知的深度函数混合网络,每个函数混合模块由一系列基础函数组成,不同基础函数具有不同的感受野大小,可满足不同像素不同感受野的需求。Zheng等人(2022b)和Li等人(2023c)使用了不同的注意力机制以挖掘空间和光谱相关性,实现高质量光谱超分辨率。Zhu等人(2021c)将图像语义信息作为先验信息构建CNN光谱超分辨率模型,使网络关注相同类别的不同空间位置信息,并使用无监督的方式训练该网络。进一步地,Wu等人(2023)在语义信息先验的基础上利用注意力机制挖掘空谱相关性,并利用二阶先验约束构建损失函数训练网络。Hang等人(2021)对光谱图像的光谱相关性和投影属性进行研究,利用光谱数据的光谱相关性设计分解子网络重构光谱图像,并利用投影属性,即多光谱图像可以看做是高光谱图像的三维投影,构造自监督子网络作为分解子网络的约束,依次进行端到端光谱超分辨率。Fu等人(2022b)研究了相机光谱响应对光谱超分辨率的影响,并提出了联合相机光谱响应选择和光谱超分辨率的框架。针对在现实世界中图像容易受到混合噪声、压缩和伪影等污染的问题,Li等人(2022a)提出了非局部净化的密集残差通道重校准网络,首先通过非局部净化模块消除各种干扰,再使用密集残差

通道重校准模块构建的网络实现光谱超分辨率。

基于Transformer的光谱超分辨率网络也得到了大量关注。Cai等人(2022)提出了多阶段的光谱维度Transformer用于光谱超分辨率,其由光谱维度多头自注意力作为基本单元构建单阶段光谱维度Transformer,并通过堆叠的方式构建多阶段光谱维度Transformer。进一步地,Li等人(2023b)提出了双光谱维度多头自注意力,在光谱维度自注意力的基础上增加了不同注意力头之间的自注意力,并通过掩膜引导的通道增强模块实现高质量的光谱超分辨率。CNN主要关注于局部信息的挖掘,而Transformer则关注于全局信息的挖掘。为充分发挥CNN和Transformer各自的优势,Du等人(2023)提出了CNN和Transformer联合网络。不同于CNN与注意力机制的结合,其采用级联的方式使用CNN挖掘浅层特征而使用Transformer挖掘深层特征。

此外,深度展开网络(DUN)相对于传统CNN或者Transformer具有更强的可解释性,也在光谱超分辨率任务上得到了发展。Zhu等人(2021b)受到经典梯度下降优化算法的启发,构建深度展开网络并由深度神经网络完成其中梯度估计的部分。该深度展开网络可经过单次训练后处理对应不同相机光谱响应的RGB图像,而不需要针对每一个相机光谱响应分别训练网络。He等人(2022)基于半二次分裂法(half-quadratic splitting method)构建深度展开网络,并使用跨维度通道注意力构建的深度神经网络替换近端算子部分。Zhang等人(2022c)将深度展开网络用于联合光谱超分辨率和空间去马赛克。

基于生成对抗网络(GAN)的方法主要对高空超分辨率光谱图像中重要信息的潜在分布进行约束。Lore等人(2019)探索使用条件生成对抗网络进行光谱超分辨率,将多光谱图像作为生成条件输入生成网络生成高光谱图像,并使用判别网络强化生成网络对结构信息的挖掘能力。Liu等人(2023)将空谱特征注意力模块注入到基于生成对抗网络的光谱超分辨率框架中,并对生成的高光谱图像使用光谱角映射损失函数进行约束。

### 1.1.3 空间—光谱超分辨率

如何获得同时具有高空间分辨率和高光谱分辨率的图像仍然是一个待解决的问题。光谱图像的空间—光谱超分辨率结合了空间超分辨率和光谱超分辨率的概念,旨在同时提高光谱图像的空间分辨率

和光谱分辨率。Mei等人(2020)首次提出使用卷积神经网络(CNN)联合改进空间和光谱分辨率,充分讨论了空间超分辨率和光谱超分辨率作用顺序的影响,包括在光谱和空间域中进行超分辨率的同时空间—光谱联合超分辨率和顺序考虑光谱和空间超分辨率的分离空间—光谱联合超分辨率。Ma等人(2022b)提出了深度空间—光谱特征交互网络,设计了空间超分辨率和光谱超分辨率作为两个辅助任务以使两者相互受益。Zhang等人(2023a)将隐式神经表示应用于空间光谱超分辨率。Ma等人(2022a)提出了深度展开空间—光谱超分辨率网络,同样将空间超分辨率和光谱超分辨率作为辅助任务,使用交替乘法(alternative direction multiplier method)封闭求解空间超分辨率子问题和光谱超分辨率子问题。

基于深度学习的光谱图像单图超分辨率算法归纳如表1所示。

## 1.2 融合超分辨率

光谱图像融合超分辨率结合了超分辨率和多幅图像融合的概念,旨在从多个低分辨率光谱图像中生成高分辨率光谱图像,并在这个过程中融合不同图像的信息,以提高光谱图像的质量和清晰度。根据融合数据的类型,可分为全色光谱融合和多光谱高光谱图像融合。根据训练方式的不同,光谱图像融合超分辨率也可分为有监督训练和无监督训练。

### 1.2.1 全色光谱融合超分辨率

全色光谱融合超分辨率旨在将全色图像(具有高空间分辨率和低光谱分辨率)与多光谱图像(具有低空间分辨率和高光谱分辨率)融合在一起,以获得具有高空间分辨率和高光谱分辨率的图像。

深度学习首次引入到全色光谱融合超分辨率是Masi等人(2016)使用3层连续的卷积将插值后的多光谱图像和全色图像融合生成高分辨率光谱图像。此后,Yang等人(2017)在全色光谱融合超分辨率网络中引入了残差的思想,在网络输出端加上插值后的多光谱图像,并在高频域而不是图像域训练网络参数,以更好地保留图像的空间和光谱特征。Yuan等人(2018)也使用了残差,并且引入了多尺度卷积提取不同距离的特征。与先前方法使用双三次插值或数据驱动的训练策略对低分辨率多光谱图像进行上采样不同,Zheng等人(2020)使用深度光谱先验对低分辨率多光谱图像进行上采样,再用由通道空

表1 单图超分辨率研究归纳

Table 1 Overview of single spectral image super-resolution methods

方法	场景	基础框架	监督范式	发表期刊/会议
3D-FCNN(Mei等,2017)	SpaSR	CNN	有监督	Remote Sens.
SDCNN(Li等,2017b)	SpaSR	CNN	有监督	Neurocomputing
1D2DCNN(Li等,2019)	SpaSR	CNN	有监督	Remote Sens.
IDN(Hu等,2019)	SpaSR	CNN	有监督	Remote Sens.
MW-3D-CNN(Yang等,2019)	SpaSR	CNN	有监督	Remote Sens.
DFMF(Xie等,2019b)	SpaSR	CNN	有监督	IEEE TGRS
RIFN(Hu等,2020)	SpaSR	CNN	有监督	IEEE TGRS
3DASRGAN(Dou等,2020)	SpaSR	GAN	有监督	Remote Sens.
MCNet(Li等,2020c)	SpaSR	CNN	有监督	Remote Sens.
SSPSR(Jiang等,2020)	SpaSR	CNN	有监督	IEEE TGRS
SFCSR(Wang等,2021a)	SpaSR	CNN	有监督	IEEE TIE
MMCA(Magid等,2021)	SpaSR	CNN	有监督	ICCV
Bi3DQRNN(Fu等,2021)	SpaSR	CNN	有监督	IEEE JSTARS
INR(Zhang等,2023b)	SpaSR	CNN	有监督	IEEE TGRS
RFSR(Wang等,2022)	SpaSR	CNN	有监督	IEEE TGRS
DualSR(Li等,2022a)	SpaSR	CNN	有监督	IEEE TIP
SRAGAN(Li等,2022b)	SpaSR	GAN	有监督	IEEE TGRS
LE-GAN(Shi等,2022)	SpaSR	CNN	有监督	IEEE TGRS
DSSTSR(Long等,2023)	SpaSR	Transformer	有监督	IEEE TGRS
ESSAformer(Zhang等,2023c)	SpaSR	Transformer	有监督	ICCV
HSCNN(Xiong等,2017)	SpeSR	CNN	有监督	ICCVW
GANSSR(Lore等,2019)	SpeSR	GAN	有监督	CVPRW
AWAN(Li等,2020b)	SpeSR	CNN	有监督	CVPRW
PDFN(Zhang等,2020a)	SpeSR	CNN	有监督	AAAI
SSRAN(Zheng等,2022b)	SpeSR	CNN	有监督	IEEE TGRS
DAGDN(Zhu等,2021b)	SpeSR	DUN	有监督	IEEE TCI
SEN(Zhu等,2021c)	SpeSR	CNN	无监督	ICCV
HSACS(Li等,2023c)	SpeSR	CNN	有监督	IEEE TNNLS
SSRN-IPH(Hang等,2021)	SpeSR	CNN	有监督	IEEE TIP
SSN(Fu等,2022b)	SpeSR	CNN	有监督	IEEE TPAMI
DRCRNet(Li等,2022a)	SpeSR	CNN	有监督	CVPRW
PoNet(He等,2022)	SpeSR	DUN	有监督	Inform. Fusion
MST++(Cai等,2022)	SpeSR	Transformer	有监督	CVPRW
MFormer(Li等,2023b)	SpeSR	Transformer	无监督	IEEE TGRS
HPRN(Wu等,2023)	SpeSR	CNN	有监督	IEEE TNNLS
CTJN(Du等,2023)	SpeSR	CNN和Transformer	有监督	IEEE TGRS
SSFAN(Liu等,2023)	SpeSR	GAN	有监督	IEEE JSTARS
SSJSR(Mei等,2020)	SSSR	CNN	有监督	IEEE TGRS
US3RN(Ma等,2021)	SSSR	DUN	有监督	IEEE TIP
SSFIN(Ma等,2022b)	SSSR	CNN	有监督	IEEE TCI
INRJSR(Zhang等,2023a)	SSSR	CNN	有监督	IMT

间注意力残差模块堆叠成的网络进行融合。Wang 等人(2021b)则是先将光谱图像通过卷积映射到空间域,再执行上采样操作。Zhou 等人(2022c)将全色图像和低分辨率多光谱图像独立地投影到模态感知特征空间中,然后对其进行互信息最小化,以明确鼓励互补信息学习,并减少信息冗余,提高模型性能。Bandara 等人(2022)向传统光谱能量函数引入额外的空间域约束,可以进一步提高上采样光谱图像的质量。Zhou 等人(2022d)首先尝试解决空间和频率域中的全色锐化问题,并提出了一种空间频率信息集成网络,该网络由空间域信息分支、频域信息分支和双域交互组成。进一步地,Zhou 等人(2022b)先测量全色图像和低分辨率多光谱图像的模态感知频率信息差异,再自适应地挑选出不同模态对应的低频分量,然后通过空间和频率域信息集成为恢复期望的低频分量,最后将细化的低频分量与原始高频图像融合用于潜在高频重建。Gao 等人(2022)提出了一种用于全色光谱融合超分辨率任务的通用算法,即深度图像插值,其主要思想是通过在深度神经网络中将两个低质量图像插值以获取高质量的融合结果。Dong 等人(2022a)提出具有上下文感知引导注意力的交叉反馈密集网络,允许网络学习高级特征的注意力图并以反馈方式跨分支细化低级特征。Zhou 等人(2023)将多光谱特征增强和多聚焦特征融合模块应用于全色光谱融合超分辨率。

Transformer 方法在深度学习领域取得了巨大突破,Meng 等人(2022)将 Transformer 引入全色光谱融合超分辨率领域,将低分辨率多光谱图像插值后与全色图像在通道维度拼接后输入 Transformer 得到高分辨率多光谱图像。Xu 等人(2022)使用 Transformer 分别提取全色图像和低分辨率多光谱图像的特征,在特征融合阶段将全色图像特征和低分辨率光谱图像特征在通道维度拼接。Bandara 和 Patel (2022)将低分辨率多光谱图像和全色图像的特征分别表示为编码器中的查询向量和键向量,高分辨率纹理特征从全色图像转移到低分辨率多光谱图像特征,Zhou 等人(2022a)则相反,以全色图像特征为查询向量而低分辨率多光谱图像特征为键向量。

尽管深度学习方法取得了很好的性能,却仍缺乏可解释性,Xu 等人(2021)将基于模型的方法与深度学习方法相结合,以迭代求解的方式学习从全色

图像和低分辨率多光谱图像到高分辨率多光谱图像的映射,通过多次迭代取得更好的结果。Cao 等人(2022b)和 Cao 等人(2022a)先使用卷积稀疏编码技术建立全色光谱融合超分辨率的观测模型,设计近端梯度算法来求解该模型,再使用卷积神经网络学习近端算子并将迭代算法展开为深度网络。Yang 等人(2022)将全色光谱融合超分辨率表述为基于去噪先验和非局部自回归先验的变分模型的最小化问题,为增强纹理细节利用内置 CNN 的迭代算法进行可解释模型设计。此外,为了充分挖掘多光谱图像不同通道的潜力,将全色图像与多光谱图像每个通道相结合,选择性地提供高频细节并减轻复制伪影。Qu 等人(2023)将基于半二次分裂法的全色光谱融合超分辨率模型的迭代步骤展开为可深度解释的迭代生成对抗网络。在每次迭代中,生成器与空间判别器和光谱判别器建立对抗博弈,在没有真实图像的情况下同时更新空间和光谱信息。

基于 GAN 的全色光谱融合超分辨率方法也取得了长足的发展。Ma 等人(2020)提出了基于生成对抗网络的无监督全色光谱融合超分辨率框架,在网络训练期间不依赖于有监督数据,生成器分别与光谱判别器和空间判别器建立对抗博弈。Xu 等人(2023)提出了基于光谱和纹理损失约束的生成对抗网络,首先专注于生成均值差分图像而不是直接输出融合图像,然后通过由粗到精的策略生成融合图像。

### 1.2.2 多光谱高光谱融合超分辨率

多光谱图像通常包含几个相对宽的光谱波段,具有较高的空间分辨率,但无法提高充分的光谱信息。高光谱图像具有更高的光谱分辨率,通常包含数百个狭窄的连续光谱波段,然而其往往具有较低的空间分辨率,因此不能提供足够的细节。多光谱高光谱图像融合的主要目标是将这两种图像类型的优势结合起来,以获得同时具有高空间分辨率和高光谱分辨率的图像。根据监督方式,多光谱高光谱融合可分为有监督和无监督两种。

受经典的基于小波分解的图像融合的启发,Zhu 等人(2021a)提出了轻量级的渐进式零中心残差网络,从两个输入中沿着光谱维度以渐进的方式学习高分辨率和零中心的残差图像,然后将其以均值不变的方式叠加到上采样的低分辨率高光谱图像上,并通过挖掘空谱相关性以获取高质量高光谱图

像。Guo等人(2022)设计了外部和内部联合注意力网络,同时考虑同一图像像素间的相关性和不同图像间的相关性。Ran等人(2023)充分考虑多光谱高光谱融合超分辨率的特点,提出了高分辨率引导的通用CNN融合框架,高分辨率引导分支将高分辨率引导图像分解成多个尺度,特征重建分支利用低分辨率图像和多尺度高分辨率引导图像重建高分辨率融合图像。Hu等人(2022a)首次将Transformer应用于多光谱高光谱融合超分辨率,全局地探索特征内部的内在关系。Deng等人(2023)提出了PSRT(pyramid shuffle-and-reshuffle transformer),通过将图像块置乱再恢复的方式考虑图像块之间的全局相关性。

为增加网络的可解释性,Xie等人(2019b)和Xie等人(2022)考虑了低分辨率图像观测模型和光谱低秩知识,设计了基于近端梯度法的深度展开网络,使用卷积神经网络学习邻近算子和模型参数。Dong等人(2021)提出了基于深度高光谱图像去噪的迭代多光谱高光谱图像融合超分辨率算法,以利用领域知识似然和深度图像先验。进一步地,Dong等人(2022b)提出了空间—光谱双优化模型驱动的深度网络,将多光谱高光谱融合的内在生成机制嵌入到网络中。Wang等人(2019)提出了基于深度学习的盲多光谱高光谱融合超分辨率方法,在超分辨率重建过程中迭代和交替地优化观测模型的估计和融合过程。

有监督学习需要大量成对数据,但在多光谱高光谱融合超分辨率领域往往难以满足。Qu等人(2018)首次尝试使用无监督编码器—解码器架构以解决多光谱高光谱融合超分辨率问题。Fu等人(2019)利用额外构造的低分辨率多光谱图像辅助学习多光谱到高光谱的映射关系,并通过参数共享和无监督的方式学习该映射关系。Zhang等人(2021)首先利用额外构造的低分辨率多光谱图像分别学习空间和光谱超分辨率网络并获取两个粗略的高分辨率高光谱图像,然后将两个图像融合生成精细的高分辨率高光谱图像。Li等人(2022a)则是利用额外构造的低分辨率多光谱图像分别学习空间和光谱退化网络,并将两个退化网络作为约束条件生成高分辨率高光谱图像。Zheng等人(2021b)设计了两个特殊的卷积层作为与3个自动编码器网络协调的桥梁,并且训练过程中在两个卷积层中自适应地学习

参数。Wang等人(2020)提出了由光谱生成网络、空间相关先验网络和空间谱变分推理网络组成的自动编码器框架,以无监督的方式联合优化,形成端到端的融合系统。Yao等人(2020)提出了基于交叉注意力机制的耦合解混合网络,通过在网络上强制执行合理的一致性假设,从多光谱高光谱图像对中自适应地学习光谱和空间响应函数。Liu等人(2022)基于非负矩阵分解模型构建了无监督多光谱高光谱融合超分辨率网络。Zhang等人(2019)和Fu等人(2022a)提出了深度外部和内部学习框架,首先使用外部学习在数据上学习通用图像先验,然后使用内部学习将其泛化到特定的高光谱图像。进一步地,Zhang等人(2020b)提出了无监督自适应学习框架,使用两个深度网络分别学习通用图像先验和特定图像先验。Zhang等人(2023d)通过渐进融合网络和渐进训练策略实现多光谱高光谱图像融合超分辨率。Li等人(2023a)将基于半二次分裂法的深度展开网络与无监督学习相结合,实现高分辨率高光谱图像获取。

针对数据可能存在不对齐的问题,Qu等人(2022)提出了不对齐的无监督双向狄利克雷网络,通过共享编码器—解码器结构提取两种不同维度的模态的空间信息和光谱信息,采用互信息捕获两种模态表示及其原始输入之间的非线性统计依赖性。Zheng等人(2022b)提出了无监督光谱分解和图像对齐校正网络,将图像对齐和超分辨率任务集成到统一模型中,使两项任务可以相辅相成,从而获得更好的结果。

基于深度学习的光谱图像融合超分辨率算法归纳如表2所示。

## 2 数据集与评价指标

### 2.1 数据集

随着光谱图像处理的发展,各种光谱数据集被采集(Zhang等,2021;Zhang等,2022b;Zheng等,2022c)。对于光谱超分辨率数据集可主要分为单图超分辨率数据集和融合超分辨率数据集。

#### 2.1.1 光谱单图超分辨率数据集

CAVE数据集(<http://www.cs.columbia.edu/CAVE/databases/multispectral>)是由可调滤波片(varispec liquid crystal tunable filter)和CCD相机(Apogee Alta

表2 融合超分辨率研究归纳

Table 2 Overview of fusion-based spectral image super-resolution methods

方法	场景	基础框架	监督范式	发表期刊/会议
PNN(Masi等,2016)	PS	CNN	有监督	Remote Sens.
PanNet(Yang等,2017)	PS	CNN	有监督	ICCV
MSDCNN(Yuan等,2018)	PS	CNN	有监督	IEEE TGRS
PanGAN(Ma等,2020)	PS	GAN	无监督	Inform. Fusion
SSConv(Wang等,2021b)	PS	CNN	有监督	ACM MM
GPPNN(Xu等,2021)	PS	DUN	有监督	CVPR
HyperKite(Bandara等,2022)	PS	CNN	有监督	IEEE TGRS
PanCSC-Net(Cao等,2022b)	PS	DUN	有监督	IEEE TGRS
HyperTransformer(Bandara和Patel,2022)	PS	Transformer	有监督	CVPR
Proximal PanNet(Cao等,2022a)	PS	DUN	有监督	AAAI
panformer(Zhou等,2022a)	PS	Transformer	有监督	AAAI
DIIB(Gao等,2022)	PS	CNN	无监督	CVPR Workshop
MDCUN(Yang等,2022)	PS	DUN	有监督	CVPR
MutInf(Zhou等,2022d)	PS	CNN	有监督	CVPR
LHFnet(Zhou等,2022b)	PS	CNN	有监督	ACM MM
DR-NET(Xu等,2022)	PS	Transformer	有监督	IEEE TGRS
PanViT(Meng等,2022)	PS	Transformer	有监督	IEEE TGRS
SFINet(Zhou等,2022c)	PS	CNN	有监督	ECCV
UPanGAN(Xu等,2023)	PS	GAN	无监督	Inform. Fusion
iGDANet(Qu等,2023)	PS	DUN	无监督	IEEE TCYB
PBFE(Zhou等,2023)	PS	CNN	有监督	IEEE TCI
uSDN(Qu等,2018)	MHF	CNN	无监督	CVPR
DBIN(Wang等,2019)	MHF	CNN	有监督	ICCV
HSRG(Fu等,2019)	MHF	CNN	无监督	CVPR
CUCaNet(Yao等,2020)	MHF	CNN	无监督	ECCV
FusionNet(Wang等,2020)	MHF	CNN	无监督	IEEE TIP
UAL(Zhang等,2020b)	MHF	CNN	无监督	CVPR
DBSR(Zhang等,2021)	MHF	CNN	无监督	IEEE TNNLS
u2-MDN(Qu等,2022)	MHF	CNN	无监督	IEEE TGRS
PZRes-Net(Zhu等,2021a)	MHF	CNN	有监督	IEEE TIP
MHF-Net(Xie等,2022)	MHF	DUN	有监督	IEEE TPAMI
HyCoNet(Zheng等,2021b)	MHF	CNN	无监督	IEEE TGRS
NonRegSRNet(Zheng等,2022b)	MHF	CNN	无监督	IEEE TGRS
MoG-DCN(Dong等,2021)	MHF	DUN	有监督	IEEE TIP
DEIL(Fu等,2022a)	MHF	CNN	无监督	IEEE TPAMI
S <sup>2</sup> DMDN(Dong等,2022b)	MHF	DUN	有监督	IEEE TGRS
Fusformer(Hu等,2022a)	MHF	Transformer	有监督	IEEE TGRS
GuidedNet(Ran等,2023)	MHF	CNN	有监督	IEEE TCYB
PSRT(Deng等,2023)	MHF	Transformer	有监督	IEEE TGRS
DPLN(Zhang等,2023d)	MHF	CNN	无监督	CAAI TRIT
BUSIFusion(Li等,2023a)	MHF	DUN	无监督	IEEE TCI

U260)采集的,由32幅日常物体(例如雕像、食物)的光谱图像组成,在400~700 nm范围内以10 nm的波长间隔采集,分辨率为 $512 \times 512 \times 31$ 像素。

Harvard数据集(<http://vision.seas.harvard.edu/hyperspec/explore.html>)是使用可调滤波片光谱相机Nuance FX采集的,包含50个真实世界的室内和室外图像,具有420~720 nm范围内间隔10 nm的31个通道,空间分辨率为 $1\,392 \times 1\,040$ 像素。

ICVL数据集(<https://icvl.cs.bgu.ac.il/hyperspectral/>)是使用Specim PS Kappa DX4光谱相机采集的,包含203个城市(住宅/商业)、郊区、农村、室内和植物场景。原始图像拥有400~1 000 nm的519个通道和 $1\,392 \times 1\,300$ 像素的空间分辨率,常用的数据为400~700 nm内大约间隔10 nm的31个通道。

NUS数据集([http://www.comp.nus.edu.sg/~whitebal/spectral\\_reconstruction/index.html](http://www.comp.nus.edu.sg/~whitebal/spectral_reconstruction/index.html))是使用Specim PFD-CL-65-V10E光谱相机采集的,包含64个场景。原始图像同样是400~1 000 nm,常用的是400~700 nm内的31个通道。

Botswana数据集([https://www.ehu.eus/ccwintco/index.php?title=Hyperspectral\\_Remote\\_Sensing\\_Scenes](https://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes))是由美国宇航局地球观测1号(EO-1)卫星上的Hyperion传感器拍摄的,由400~2 500 nm的242个光谱通道组成,光谱分辨率为10 nm。空间大小为 $1\,496 \times 256$ 像素。

Chikusei数据集(<http://naotoyokoya.com/Download.html>)是由Headwall Hyperspec-VNIR-C成像传感器在日本Chikusei的农业和城市地区拍摄的,由363~1 018 nm的128个光谱波段组成。空间大小为 $2\,517 \times 2\,335$ 像素,其中单个像素相当于 $2.5 \times 2.5 \text{ m}^2$ 的几何分辨率。

Pavia University数据集([https://www.ehu.eus/ccwintco/index.php?title=Hyperspectral\\_Remote\\_Sensing\\_Scenes](https://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes))是由意大利帕维亚大学上空的ROSIS机载传感器于2003年获取的,包括 $610 \times 340$ 像素和115个光谱通道。

此外,Pavia Center数据集([https://www.ehu.eus/ccwintco/index.php?title=Hyperspectral\\_Remote\\_Sensing\\_Scenes](https://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes))、Urban数据集(<https://rslab.ut.ac.ir/data/>)、Washington DC数据集(<https://engineering.purdue.edu/~biehl/MultiSpec/hyperspectral.html>)、Indians Pines数据集(<https://www.ehu.eus/ccwintco/index.php?title=>

Hyperspectral\_Remote\_Sensing\_Scenes)、Foster数据集([https://personalpages.manchester.ac.uk/staff/d.h.foster/Local\\_Illumination\\_HSIs/Local\\_Illumination\\_HSIs/\\_2015.html](https://personalpages.manchester.ac.uk/staff/d.h.foster/Local_Illumination_HSIs/Local_Illumination_HSIs/_2015.html))、Houston数据集(<http://dase.grss-ieee.org/>)、UCMERCED数据集(<http://vision.ucmerced.edu/datasets>)也是常用的光谱单图超分辨率数据集。

### 2.1.2 光谱融合超分辨率数据集

QuickBird数据集(<https://www.satimagingcorp.com/satellite-sensors/quickbird/>)是由QuickBird卫星采集的,包括低分辨多光谱图像和全色图像。低分辨多光谱图像和全色图像的空间分辨率分别为2.44 m和0.61 m。低分辨多光谱图像为450~900 nm的4个通道,分别是R、G、B、NIR。

HypSen数据集是由Earth Observing-1卫星上的Hyperion传感器采集的30 m分辨率高光谱图像和Sentinel-2A卫星采集的10 m分辨率多光谱图像组成。去除噪声和水吸收带后,低分辨率高光谱图像由84个光谱通道组成,而高分辨率多光谱图像包含13个光谱通道。

AVIRIS Cuprite数据集是由NASA的机载可见光和红外成像光谱仪(AVIRIS)在美国内华达州赤铜矿区上空遥感采集,包含4幅尺寸为 $512 \times 512 \times 224$ 像素的图像,光谱范围为370 nm~2 500 nm。

光谱数据集总结归纳如表3所示,部分数据集场景样例如图5所示。

## 2.2 评价指标

### 2.2.1 全参考评价指标

1)均方根误差(root mean square error, RMSE)通常做图像质量评价的指标之一,用于比较参考图像与经过处理后的图像之间的差异。

2)峰值信噪比(peak signal-to-noise ratio, PSNR)通过比较参考图像与处理后的图像之间的峰值信噪比来衡量它们之间的相似度。

3)结构相似性指数(structural similarity index, SSIM)与PSNR不同,不仅考虑了图像的亮度信息,还考虑了图像的结构和感知信息,因此更能反映人眼对图像质量的感知。通常情况下,SSIM的值在-1到1之间,1表示两幅图像完全相同,0表示没有相似性,-1表示两幅图像完全相反。

4)相关系数(correlation coefficient, CC)衡量了这两个变量之间的线性关系程度。CC计算为

表3 光谱图像超分辨率数据集归纳

Table 3 Overview of spectral image super-resolution datasets

超分辨率类型	数据集	图像数量/幅	空间分辨率/像素	光谱范围/nm	光谱通道数
单图超分辨率	CAVE	32	512 × 512	400~700	31
	Harvard	50	1 392 × 1 040	420~720	31
	ICVL	203	1 392 × 1 300	400~700	31
	NUS	64	/	400~700	31
	Botswana	1	1 496 × 256	400~2 500	242
	Chikusei	1	2 517 × 2 335	363~1 018	128
	Pavia University	1	610 × 340	/	115
融合超分辨率	QuickBird	34	1 655 × 1 128	450~900	4
	HypSen	1	1 023 × 1 095	400~2 500	84
	AVIRIS Cuprite	4	512 × 512	370~2 500	224

注：“/”表示未提供该信息。

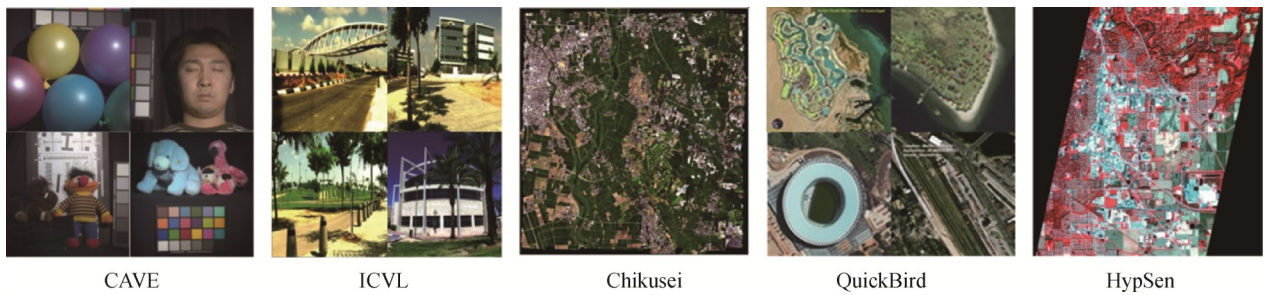


图5 光谱图像数据集样例

Fig. 5 Samples of spectral image dataset

$$\begin{cases} CC(\mathbf{x}, \mathbf{y}) = \frac{1}{l} \sum_{i=1}^l CCS(\mathbf{x}^i, \mathbf{y}^i) \\ CCS(\mathbf{a}, \mathbf{b}) = \frac{\sum_{j=1}^n (\mathbf{a}_j - \mu_a)(\mathbf{b}_j - \mu_b)}{\sqrt{\sum_{j=1}^n (\mathbf{a}_j - \mu_a)^2 \sum_{j=1}^n (\mathbf{b}_j - \mu_b)^2}} \end{cases} \quad (1)$$

式中,  $\mathbf{x}^i$  和  $\mathbf{y}^i$  分别表示参考图像和经处理后的图像,  $\mu$  为图像像素平均值,  $n$  为空间像素数,  $l$  为光谱通道数,  $\mathbf{a}, \mathbf{b}$  为光谱图像的某个通道。

5) SAM (spectral angle mapper) 通过计算两个光谱向量之间的角度来评估像元与不同类别之间的相似性。SAM 计算为

$$SAM(\mathbf{x}, \mathbf{y}) = \frac{1}{n} \sum_{j=1}^n \arccos \frac{\langle \mathbf{x}_j, \mathbf{y}_j \rangle}{\|\mathbf{x}_j\|_2 \|\mathbf{y}_j\|_2} \quad (2)$$

式中,  $\langle \cdot, \cdot \rangle$  为向量内积操作。

6) ERGAS (relative dimensionless global error in synthesis) 计算两个图像之间的光谱差异性。ERGAS 计算为

$$ERGAS(\mathbf{x}, \mathbf{y}) = 100 \frac{1}{d^2} \sqrt{\frac{1}{l} \sum_{i=1}^l \frac{RMSE(\mathbf{x}_j, \mathbf{y}_j)}{\mu_{y_j}}} \quad (3)$$

式中,  $d$  为超分辨率比例。

ERGAS 的值通常以百分比表示, 表示 RMSE 在原始图像均值基础上的百分比误差。ERGAS 值越低, 代表经过处理的图像与原始图像之间的差异越小, 质量越好。较高的 ERGAS 值则意味着图像质量较差。

### 2.2.2 无参考评价指标

无参考质量评价指标 (quality with no reference, QNR) 不需要参考图像即可评价超分辨率光谱图像的质量, 具体为

$$\begin{aligned} QNR &= (1 - D_\lambda)^\eta (1 - D_s)^\rho \quad (4) \\ D_\lambda &= \sqrt{\frac{1}{l(l-1)} \sum_{q_1=1}^l \sum_{\substack{q_2=1 \\ q_2 \neq q_1}}^l \|Q_a^{q_1, q_2} - Q_b^{q_1, q_2}\|^e} \\ D_s &= \sqrt{\frac{1}{l} \sum_{q=1}^l \|Q(a^q, p) - Q(b^q, p_{lr})\|^\delta} \end{aligned}$$

式中,  $Q(\cdot, \cdot)$  为 Q 指标 (Wang 和 Bovik, 2002),  $Q_a^{q_1, q_2} = Q(a^{q_1}, a^{q_2})$  和  $Q_b^{q_1, q_2} = Q(b^{q_1}, b^{q_2})$  计算了低分辨率高光谱图像  $a$  和高分辨率高光谱图像  $b$  光谱通道对之间的差异。而  $p$  和  $p_{lr}$  分别为高分辨率多光谱图像和低分辨率低光谱图像。

### 3 评 估

为了全面分析各种算法的效果,对单图超分辨率和融合超分辨率两个任务的共 18 种方法进行了实验,采用定量指标和定性分析对超分辨率结果进行评价。本文所有实验结果均为作者使用开源代码复现的结果。

#### 3.1 单图超分辨率实验

##### 3.1.1 实验设置

在单图超分辨率实验中,选取了 3D-FCNN (3D full convolutional neural network) (Mei 等, 2017)、IFN (intra fusion network) (Hu 等, 2020)、MCNet (mixed 2D/3D convolutional network) (Li 等, 2020c)、SFCSR (super-resolution using spectrum and feature context) (Wang 等, 2021a)、SSPSR (spatial-spectral prior for super-resolution) (Jiang 等, 2020)、Bi3DQRNN (bidirectional 3D quasi-recurrent neural network) (Fu 等, 2021)、ESSAformer (efficient Transformer with SCC-kernel-based self-attention) (Zhang 等, 2023c) 进行实验,采用 PSNR、SSIM 和 SAM 作为评价指标,在 Pavia Center 数据集上进行训练与测试。在本实验中,采用 Pavia Center 中心  $256 \times 256$  个像素作为测试集,其余部分作为训练集。本实验的任务为进行 4 倍的

空间超分辨率。

##### 3.1.2 实验结果与分析

定量实验的结果见表 4,在各项指标中,ESSAformer 表现最好,表明其在保留图像细节、保持图像结构和光谱保真度方面表现最好。3D-FCNN 使用的 3D 卷积在 PSNR、SSIM 和 ERGAS 指标表现也很好,但是在 SAM 表现略低于 SSPSR 和 IFN,表明其在还原图像细节和结构效果较好,但是光谱特征保持较差。IFN 模型在 PSNR 方面表现稍逊,但在 SAM 方面略优于 MCNet 和 SSPSR。

图 6 是对测试集第 88 个波段的 4 倍超分的可视化结果,从红框部分中可以看出, Bi3DQRNN 和 ESSAformer 的超分辨率结果保留了更多的纹理信息, IFN 和 Bi-3DQRNN 的超分辨率结果也保留了部分纹理信息, SFCSR 和 SSPSR 的超分辨率结果则比较模糊。可视化结果与量化指标中 PSNR 和 SSIM 的结果基本一致。

表 4 单图超分辨率定量比较结果

Table 4 Results of single image super-resolution quantitative comparison

模型	PSNR/dB	SSIM	SAM	ERGAS
3D-FCNN	25.49	0.815 8	6.40	98.34
IFN	25.22	0.789 2	6.31	104.32
MCNet	25.13	0.811 5	6.44	124.62
SFCSR	25.27	0.812 7	6.34	106.55
SSPSR	25.16	0.743 5	6.99	169.74
Bi3DQRNN	25.71	0.820 4	5.94	87.36
ESSAformer	<b>26.16</b>	<b>0.853 3</b>	<b>5.74</b>	<b>72.56</b>

注:加粗字体表示各列最优结果。




图 6 单图超分可视化结果

Fig. 6 Results of single image super-resolution visualization

#### 3.2 融合超分辨率实验

##### 3.2.1 实验设置

本节分别对多光谱高光谱融合超分辨率以及全色光谱融合超分辨率进行了实验评估。

在多光谱高光谱融合超分辨率实验中,选取了 uSDN (unsupervised sparse dirichlet-net) (Qu 等, 2018)、CUCaNet (coupled unmixing network with cross-attention) (Yao 等, 2020)、HyCoNet (hyperspec-

tral coupled network)(Zheng 等, 2021b)、UAL(unsupervised adaptation learning)(Zhang 等, 2020b)、MHF-Net(multispectral and hyperspectral fusion network)(Xie 等, 2022)、NonRegSRNet(nonrigid registration super-resolution network)(Zheng 等, 2022a)和PSRT(pyramid shuffle-and-reshuffle Transformer)(Deng 等, 2023)进行验证。其中, MHF-Net和PSRT为有监督方法, 其余5个为无监督方法。采用PSNR、SSIM、SAM和ERGAS作为评价指标。本实验在CAVE数据集上进行训练, 对于无监督学习方法, 随机选择12幅高光谱图像进行融合超分辨率, 对于有监督学习方法, 随机选20幅高光谱图像用于训练, 剩余12幅用于测试(与无监督相同)。融合超分辨率的倍率设置为32。

在全色光谱融合超分辨率实验中, 选取了PNN(pansharpening neural network)(Masi 等, 2016)、PanNet(pansharpening network)(Yang 等, 2017)、MSDCNN(multi-scale and multi-depth convolutional neural network)(Yuan 等, 2018)、GPPNN(gradient projection network for pansharpening)(Xu 等, 2021)、MDCUN(memory-augmented deep conditional unfolding network)(Yang 等, 2022)、SFIINet(spatial-frequency information integration network)(Zhou 等, 2022c)和PBFE(pan-guided band-aware feature enhancement)(Zhou 等, 2023)进行验证, 采用PSNR、SSIM、SAM和ERGAS作为评价指标。在world view 3上进行训练和测试。全色光谱融合超分辨率的任务为4倍超分辨率。

### 3.2.2 实验结果与分析

多光谱高光谱融合超分辨率实验的定量结果见

表5, UAL在除PSNR外的其他指标上都取得了最好的表现, 表明其在融合的过程中更好地保留了高光谱图像的光谱特征和多光谱图像的空间特征。无监督的CUCaNet和有监督的PSRT取得了相近的表现。

表5 多光谱高光谱融合超分辨率定量比较结果

Table 5 Results of multispectral and hyperspectral fusion quantitative comparison

模型	PSNR/dB	SSIM	SAM	ERGAS
uSDN	36.84	0.948	7.37	81.22
CUCaNet	37.58	0.959	7.27	76.66
HyCoNet	35.93	0.942	7.74	85.91
UAL	37.74	<b>0.969</b>	<b>7.12</b>	<b>71.32</b>
MHF-Net	37.43	0.964	7.30	74.47
NonRegSRNet	32.41	0.917	9.12	97.85
PSRT	<b>37.83</b>	0.953	7.33	79.34

注: 加粗字体表示各列最优结果。

图7是多光谱高光谱融合超分辨率实验的可视化结果, 第1行是各个模型在CAVE的balloons的第10个波段的32倍的超分结果, 第2行是各个像素与参考图像间的误差图像。从结果可以看出, UAL、CUCaNet和PSRT超分的图像与参考图像的差值比较低。uSDN在部分小区域存在很高的误差, HyCoNet和NonRegSRNet与真值的差值比较高。可视化结果与量化结果的指标相符。

全色光谱融合超分辨率的定量实验结果见表6, PBFE在各个指标上表现最好, SFIINet、GPPNN和MSDCNN在PSNR和SSIM方面表现相似, 都具有很高的图像质量。MDUCN模型在PSNR和SSIM方面表现相对较差, 但在SAM和ERGAS方面表现更好。




图7 多光谱高光谱融合超分可视化结果

Fig. 7 Visualization results of multispectral and hyperspectral fusion super-resolution

PNN和PanNet在PSNR和SSIM方面介于前三者和MDCUN之间,但它们在SAM和ERGAS方面表现更好。

图8是全色光谱融合超分辨率的可视化结果,第1行是各个模型在world view 3的测试集的2230

号图像,第2行是各个像素与参考图像间的误差图像。从图中可以看出,MDCUN的误差比较大,PBFE的误差最小,MSDCNN、PanNet、GPPNN和SFIINet的误差处于二者之间。




图8 全色光谱融合超分可视化结果

Fig. 8 Visualization results of pansharpening

表6 全色光谱融合超分辨率定量比较结果

Table 6 Results of pansharpening quantitative comparison

模型	PSNR/dB	SSIM	SAM	ERGAS
PNN	33.47	0.946	2.80	11.73
PanNet	33.20	0.942	2.86	12.14
MSDCNN	33.78	0.949	2.72	11.35
GPPNN	33.81	0.950	2.74	11.31
MDCUN	32.84	0.939	3.11	12.65
SFIINet	33.91	0.950	2.76	11.17
PBFE	<b>34.52</b>	<b>0.967</b>	<b>2.24</b>	<b>11.02</b>

注:加粗字体表示各列最优结果。

## 4 结 语

光谱图像超分辨率技术的目标是从低空间分辨率和光谱分辨率的图像中恢复高空间分辨率和光谱分辨率的图像,在植被调查、地质勘探、环境保护、异常检测和目标追踪等遥感领域有着广泛应用。随着深度学习的兴起,基于深度学习的光谱图像超分辨率算法如雨后春笋般涌现。为使相关领域的研究者快速了解基于深度学习的光谱图像超分辨率方法,把握其发展脉络,本文对光谱图像超分辨率领域最前沿的深度学习算法进行了全面调研与分析。结合具体的光谱图像超分辨率任务,本文从网络结构和监督范式等多个角度综合介绍了各类方法的基本思

想与特点。此外,为了方便后续相关研究者开展研究,本文详细介绍了常用的光谱图像超分辨率数据和评估指标。对于每一类光谱图像超分辨率任务,从定量评估和定性评估等多个方面分析了代表性方法的性能。

虽然深度学习在光谱图像超分辨率领域发展迅猛,但是仍面临一些严峻的挑战。

1)高质量光谱超分辨率数据集。目前基于深度学习的光谱图像超分辨率方法都是数据驱动的,只要是数据驱动的方法必然面临训练数据的问题。现在尚无大规模高质量的真实成对数据集,大多方法在仿真数据集上具有很高的精度,但是在真实数据上就会大打折扣。虽然已有一些方法开始考虑使用无监督等方案解决该问题,但是这种做法治标不治本,采集大规模高质量真实成对数据才能从根本上解决该问题。

2)模型驱动与深度学习相结合的超分辨率方法。现在的趋势是使用模型驱动和深度学习相结合的方法。深度学习方法一般有更强的建模能力,而模型驱动方法一般有更好的泛化能力。不论是将模型驱动方法展开为网络,还是将深度去噪网络作为去噪器插入模型驱动算法,还是在学习网络中引入模型优化,仅仅在一定程度上结合了模型驱动和深度学习两方面的优势。后续如何更好地结合模型驱动方法和深度学习方法,以及结合其他先进方法将成为重要的方向。

3)实时光谱图像超分辨率。光谱图像超分辨率往往作为光谱图像应用的预处理过程。对于光谱图像应用任务,通常对预处理速度有着较高的要求。目前的深度学习方法处理速度相对较快但是依赖强大的GPU计算资源,而卫星光谱载荷往往计算资源有限。因此,在保证光谱图像超分辨率性能的前提下,设计适合卫星光谱载荷、边缘计算平台的轻量化深度网络模型,实现实时光谱图像超分辨率对于扩展应用范围是至关重要的。

4)全面的评估指标。由于大部分遥感光谱图像难以采集高质量的参考图像,因此如何全面评估光谱图像超分辨率的性能面临巨大的挑战。利用非对齐参考图像或者低质量参考图像设计评估指标是一个可行的方向。进一步地,在没有参考图像情况下,设计公平准确的无参考评估指标对光谱图像超分辨率意义重大。这既可以更加全面地评估不同超分辨率算法,也有助于构造更好的损失函数用于深度网络训练。

## 参考文献(References)

- Bandara W G C and Patel V M. 2022. Hypertransformer: a textural and spectral feature fusion transformer for pansharpening//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 1757-1767 [DOI: 10.1109/CVPR52688.2022.00181]
- Bandara W G C, Valanarasu J M J and Patel V M. 2022. Hyperspectral pansharpening based on improved deep image prior and residual reconstruction. IEEE Transactions on Geoscience and Remote Sensing, 60: #5520816 [DOI: 10.1109/TGRS.2021.3139292]
- Bioucas-Dias J M, Plaza A, Dobigeon N, Parente M, Du Q, Gader P and Chanussot J. 2012. Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 5(2): 354-379 [DOI: 10.1109/JSTARS.2012.2194696]
- Cai Y H, Lin J, Lin Z D, Wang H Q, Zhang Y L, Pfister H, Timofte R and Van Gool L. 2022. MST++: multi-stage spectral-wise transformer for efficient spectral reconstruction//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. New Orleans, USA: IEEE: 744-754 [DOI: 10.1109/CVPRW56347.2022.00090]
- Cao X Y, Chen Y and Cao W F. 2022a. Proximal pannel: a model-based deep network for pansharpening//Proceedings of the 36th AAAI Conference on Artificial Intelligence. [s. l.]: AAAI: 176-184 [DOI: 10.1609/aaai.v36i1.19892]
- Cao X Y, Fu X Y, Hong D F, Xu Z B and Meng D Y. 2022b. PanCSC-Net: a model-driven deep unfolding method for pansharpening. IEEE Transactions on Geoscience and Remote Sensing, 60: #5404713 [DOI: 10.1109/TGRS.2021.3115501]
- Chen L C, Papandreou G, Kokkinos I, Murphy K and Yuille A L. 2018. Deeplab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. IEEE Transactions on Pattern Analysis and Machine Intelligence, 40(4): 834-848 [DOI: 10.1109/TPAMI.2017.2699184]
- Chen L W, Fu Y, You S D and Liu H Z. 2022. Hybrid supervised instance segmentation by learning label noise suppression. Neurocomputing, 496: 131-146 [DOI: 10.1016/j.neucom.2022.05.026]
- Deng S Q, Deng L J, Wu X, Ran R, Hong D F and Vivone G. 2023. PSRT: pyramid shuffle-and-reshuffle transformer for multispectral and hyperspectral image fusion. IEEE Transactions on Geoscience and Remote Sensing, 61: #5503715 [DOI: 10.1109/TGRS.2023.3244750]
- Dian R W, Fang L Y and Li S T. 2017. Hyperspectral image super-resolution via non-local sparse tensor factorization//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 3862-3871 [DOI: 10.1109/CVPR.2017.411]
- Dian R W and Li S T. 2019. Hyperspectral image super-resolution via subspace-based low tensor multi-rank regularization. IEEE Transactions on Image Processing, 28(10): 5135-5146 [DOI: 10.1109/TIP.2019.2916734]
- Dong W Q, Qu J H, Zhang T Z, Li Y S and Du Q. 2022a. Context-aware guided attention based cross-feedback dense network for hyperspectral image super-resolution. IEEE Transactions on Geoscience and Remote Sensing, 60: #5530814 [DOI: 10.1109/TGRS.2022.3180484]
- Dong W Q, Zhang T Z, Qu J H, Li Y S and Xia H M. 2022b. A spatial-spectral dual-optimization model-driven deep network for hyperspectral and multispectral image fusion. IEEE Transactions on Geoscience and Remote Sensing, 60: #5542016 [DOI: 10.1109/TGRS.2022.3217542]
- Dong W S, Zhou C, Wu F F, Wu J J, Shi G M and Li X. 2021. Model-guided deep hyperspectral image super-resolution. IEEE Transactions on Image Processing, 30: 5754-5768 [DOI: 10.1109/TIP.2021.3078058]
- Dou X Y, Li C Y, Shi Q and Liu M X. 2020. Super-resolution for hyperspectral remote sensing images based on the 3D attention-SRGAN network. Remote Sensing, 12(7): #1204 [DOI: 10.3390/rs12071204]
- Du D K, Gu Y F, Liu T Z and Li X. 2023. Spectral reconstruction from satellite multispectral imagery using convolution and transformer joint network. IEEE Transactions on Geoscience and Remote Sensing, 61: #5515015 [DOI: 10.1109/TGRS.2023.3285893]

- Fang S and Xu M. 2022. Hyperspectral and multispectral image fusion focused on error compensation. *Journal of Image and Graphics*, 28(1): 277-289 (方帅, 许漫. 2022. 面向误差补偿的高光谱与多光谱图像融合. *中国图象图形学报*, 28(1): 277-289) [DOI: 10.11834/jig.220568]
- Fu Y, Liang Z Y and You S D. 2021. Bidirectional 3D quasi-recurrent neural network for hyperspectral image super-resolution. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 2674-2688 [DOI: 10.1109/JSTARS.2021.3057936]
- Fu Y, Zhang T, Wang L Z and Huang H. 2022a. Coded hyperspectral image reconstruction using deep external and internal learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(7): 3404-3420 [DOI: 10.1109/TPAMI.2021.3059911]
- Fu Y, Zhang T, Zheng Y Q, Zhang D B and Huang H. 2019. Hyperspectral image super-resolution with optimized RGB guidance//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 11653-11662 [DOI: 10.1109/CVPR.2019.01193]
- Fu Y, Zhang T, Zheng Y Q, Zhang D B and Huang H. 2022b. Joint camera spectral response selection and hyperspectral image recovery. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(1): 256-272 [DOI: 10.1109/TPAMI.2020.3009999]
- Fu Y, Zheng Y Q, Huang H, Sato I and Sato Y. 2018a. Hyperspectral image super-resolution with a mosaic RGB image. *IEEE Transactions on Image Processing*, 27(11): 5539-5552 [DOI: 10.1109/TIP.2018.2855412]
- Fu Y, Zheng Y R, Zhang L and Huang H. 2018b. Spectral reflectance recovery from a single RGB image. *IEEE Transactions on Computational Imaging*, 4(3): 382-394 [DOI: 10.1109/TCI.2018.2855445]
- Fu Y, Zheng Y R, Zhang L, Zheng Y Q and Huang H. 2020. Simultaneous hyperspectral image super-resolution and geometric alignment with a hybrid camera system. *Neurocomputing*, 384: 282-294 [DOI: 10.1016/j.neucom.2019.12.024]
- Gao J H, Li J, Su X, Jiang M H and Yuan Q Q. 2022. Deep image interpolation: a unified unsupervised framework for pansharpening//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. New Orleans, USA: IEEE: 608-617 [DOI: 10.1109/CVPRW56347.2022.00076]
- Guo Z L, Xin J W, Wang N N, Li J and Gao X B. 2022. External-internal attention for hyperspectral image super-resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5538714 [DOI: 10.1109/TGRS.2022.3207230]
- Han X L, Yu J and Sun W D. 2017. Hyperspectral image super-resolution based on non-factorization sparse representation and dictionary learning//Proceedings of 2017 IEEE International Conference on Image Processing. Beijing, China: IEEE: 963-966 [DOI: 10.1109/ICIP.2017.8296424]
- Hang R L, Liu Q S and Li Z. 2021. Spectral super-resolution network guided by intrinsic properties of hyperspectral imagery. *IEEE Transactions on Image Processing*, 30: 7256-7265 [DOI: 10.1109/TIP.2021.3104177]
- He J, Yuan Q Q, Li J and Zhang L P. 2022. PoNet: a universal physical optimization-based spectral super-resolution network for arbitrary multispectral images. *Information Fusion*, 80: 205-225 [DOI: 10.1016/j.inffus.2021.10.016]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]
- Heylen R, Parente M and Gader P. 2014. A review of nonlinear hyperspectral unmixing methods. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6): 1844-1868 [DOI: 10.1109/JSTARS.2014.2320576]
- Hohmann M, Kanawade R, Klämpfl F, Douplik A, Mudter J, Neurath M F and Albrecht H. 2017. In-vivo multispectral video endoscopy towards in-vivo hyperspectral video endoscopy. *Journal of Biophotonics*, 10(4): 553-564 [DOI: 10.1002/jbio.201600021]
- Hu J, Jia X P, Li Y S, He G and Zhao M H. 2020. Hyperspectral image super-resolution via intrafusion network. *IEEE Transactions on Geoscience and Remote Sensing*, 58(10): 7459-7471 [DOI: 10.1109/tgrs.2020.2982940]
- Hu J, Shen L and Sun G. 2018. Squeeze-and-excitation networks//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE: 7132-7141 [DOI: 10.1109/CVPR.2018.00745]
- Hu J, Zhao M H and Li Y S. 2019. Hyperspectral image super-resolution by deep spatial-spectral exploitation. *Remote Sensing*, 11(10): #1229 [DOI: 10.3390/rs11101229]
- Hu J F, Huang T Z, Deng L J, Dou H X, Hong D F and Vivone G. 2022a. Fusformer: a transformer-based fusion network for hyperspectral image super-resolution. *IEEE Geoscience and Remote Sensing Letters*, 19: #6012305 [DOI: 10.1109/LGRS.2022.3194257]
- Hu J W, Liu Y T, Kang X D and Fan S S. 2022b. Multilevel progressive network with nonlocal channel attention for hyperspectral image super-resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5543714 [DOI: 10.1109/TGRS.2022.322155]
- Huang G, Liu Z, Van Der Maaten L and Weinberger K Q. 2017. Densely connected convolutional networks//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 2261-2269 [DOI: 10.1109/CVPR.2017.243]
- Jiang J J, Sun H, Liu X M and Ma J Y. 2020. Learning spatial-spectral prior for super-resolution of hyperspectral imagery. *IEEE Transactions on Computational Imaging*, 6: 1082-1096 [DOI: 10.1109/TCI.2020.2996075]
- Jiao J and Wu L D. 2019. Fusion of multispectral and panchromatic images via morphological filter and improved PCNN in NSST

- domain. *Journal of Image and Graphics*, 24(3): 435-446 (焦姣, 吴玲达. 2019. 形态学滤波和改进PCNN的NSST域多光谱与全色图像融合. *中国图象图形学报*, 24(3): 435-446 [DOI: 10.11834/jig.180399])
- Keshava N and Mustard J F. 2002. Spectral unmixing. *IEEE Signal Processing Magazine*, 19(1): 44-57 [DOI: 10.1109/79.974727]
- Lai Z Q, Wei K X and Fu Y. 2022. Deep plug-and-play prior for hyperspectral image restoration. *Neurocomputing*, 481: 281-293 [DOI: 10.1016/j.neucom.2022.01.057]
- Li H L, Sudusinghe K, Liu Y Z, Yoon J, Van Der Schaar M, Blasch E and Bhattacharyya S S. 2017a. Dynamic, data-driven processing of multispectral video streams. *IEEE Aerospace and Electronic Systems Magazine*, 32(7): 50-57 [DOI: 10.1109/MAES.2017.160132]
- Li J B, Li Y Q, Wang C, Ye X L and Heidrich W. 2023a. BUSIFusion: blind unsupervised single image fusion of hyperspectral and RGB images. *IEEE Transactions on Computational Imaging*, 9: 94-105 [DOI: 10.1109/TCL.2023.3241549]
- Li J J, Cui R X, Li B, Song R, Li Y S and Du Q. 2019. Hyperspectral image super-resolution with 1D-2D attentional convolutional neural network. *Remote Sensing*, 11(23): #2859 [DOI: 10.3390/rs11232859]
- Li J J, Du S C, Wu C X, Leng Y H, Song R and Li Y S. 2022a. DRCR Net: dense residual channel re-calibration network with non-local purification for spectral super resolution//*Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. New Orleans, USA: IEEE: 1258-1267 [DOI: 10.1109/CVPRW56347.2022.00132]
- Li J J, Leng Y H, Song R, Liu W, Li Y S and Du Q. 2023b. MFormer: taming masked transformer for unsupervised spectral reconstruction. *IEEE Transactions on Geoscience and Remote Sensing*, 61: #5508412 [DOI: 10.1109/TGRS.2023.3264976]
- Li J J, Wu C X, Song R, Li Y S and Liu F. 2020b. Adaptive weighted attention network with camera spectral sensitivity prior for spectral reconstruction from RGB images//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Seattle, USA: IEEE: 1894-1903 [DOI: 10.1109/CVPRW50498.2020.00239]
- Li J J, Wu C X, Song R, Li Y S, Xie W Y, He L H and Gao X B. 2023c. Deep hybrid 2D-3D CNN based on dual second-order attention with camera spectral sensitivity prior for spectral super-resolution. *IEEE Transactions on Neural Networks and Learning Systems*, 34(2): 623-634 [DOI: 10.1109/TNNLS.2021.3098767]
- Li Q, Wang Q and Li X L. 2020c. Mixed 2D/3D convolutional network for hyperspectral image super-resolution. *Remote Sensing*, 12(10): #1660 [DOI: 10.3390/rs12101660]
- Li Q, Yuan Y, Jia X P and Wang Q. 2022a. Dual-stage approach toward hyperspectral image super-resolution. *IEEE Transactions on Image Processing*, 31: 7252-7263 [DOI: 10.1109/TIP.2022.3221287]
- Li S T, Dian R W, Fang L Y and Bioucas-Dias J M. 2018. Fusing hyperspectral and multispectral images via coupled sparse tensor factorization. *IEEE Transactions on Image Processing*, 27(8): 4118-4130 [DOI: 10.1109/TIP.2018.2836307]
- Li X and Orchard M T. 2001. New edge-directed interpolation. *IEEE Transactions on Image Processing*, 10(10): 1521-1527 [DOI: 10.1109/83.951537]
- Li X, Wei H W and Zhang H Q. 2018. Super-resolution reconstruction of single remote sensing image combined with deep learning. *Journal of Image and Graphics*, 23(2): 209-218 (李欣, 韦宏卫, 张洪群. 2018. 结合深度学习的单幅遥感图像超分辨率重建. *中国图象图形学报*, 23(2): 209-218) [DOI: 10.11834/jig.170194]
- Li Y D, Mavromatis S, Zhang F, Du Z H, Sequeira J, Wang Z Y, Zhao X W and Liu R Y. 2022b. Single-image super-resolution for remote sensing images using a deep generative adversarial network with local and global attention mechanisms. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #3000224 [DOI: 10.1109/TGRS.2021.3093043]
- Li Y S, Hu J, Zhao X, Xie W Y and Li J J. 2017b. Hyperspectral image super-resolution using deep convolutional neural network. *Neurocomputing*, 266: 29-41 [DOI: 10.1016/j.neucom.2017.05.024]
- Liang Z Y, Wang S, Zhang T and Fu Y. 2023. Blind super-resolution of single remotely sensed hyperspectral image. *IEEE Transactions on Geoscience and Remote Sensing*, 61: #5523314 [DOI: 10.1109/TGRS.2023.3302128]
- Lin Y G, Zheng Y R, Fu Y and Huang H. 2018. Hyperspectral image super-resolution under misaligned hybrid camera system. *IET Image Processing*, 12(10): 1824-1831 [DOI: 10.1049/iet-ipr.2017.1340]
- Liu D H, Li J and Yuan Q Q. 2021. A spectral grouping and attention-driven residual dense network for hyperspectral image super-resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 59(9): 7711-7725 [DOI: 10.1109/tgrs.2021.3049875]
- Liu J J, Wu Z B, Xiao L and Wu X J. 2022. Model inspired autoencoder for unsupervised hyperspectral image super-resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5522412 [DOI: 10.1109/TGRS.2022.3143156]
- Liu W, Anguelov D, Erhan D, Szegedy C, Reed S, Fu C Y and Berg A C. 2016. SSD: single shot MultiBox detector//*Proceedings of the 14th European Conference on Computer Vision*. Amsterdam, the Netherlands: Springer: 21-37 [DOI: 10.1007/978-3-319-46448-0\_2]
- Liu Z Y, Zhu H and Chen Z Z. 2023. Adversarial spectral super-resolution for multispectral imagery using spatial spectral feature attention module. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16: 1550-1562 [DOI: 10.1109/JSTARS.2023.3238853]
- Long Y Q, Wang X, Xu M, Zhang S Y, Jiang S G and Jia S. 2023. Dual self-attention swin transformer for hyperspectral image super-resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 61: #5512012 [DOI: 10.1109/TGRS.2023.3275146]

- Lore K G, Reddy K K, Giering M and Bernal E A. 2019. Generative adversarial networks for spectral super-resolution and bidirectional RGB-to-multispectral mapping//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Long Beach, USA: IEEE: 926-933 [DOI: 10.1109/cvprw.2019.00122]
- Lu X C, Yang D Z, Zhang J P and Jia F D. 2021. Hyperspectral image super-resolution based on spatial correlation-regularized unmixing convolutional neural network. *Remote Sensing*, 13 (20) : #4074 [DOI: 10.3390/rs13204074]
- Ma J Y, Yu W, Chen C, Liang P W, Guo X J and Jiang J J. 2020. Pan-GAN: an unsupervised pan-sharpening method for remote sensing image fusion. *Information Fusion*, 62: 110-120 [DOI: 10.1016/j.inffus.2020.04.006]
- Ma Q, Jiang J J, Liu X M and Ma J Y. 2022a. Deep unfolding network for spatio-spectral image super-resolution. *IEEE Transactions on Computational Imaging*, 8: 28-40 [DOI: 10.1109/TCI.2021.3136759]
- Ma Q, Jiang J J, Liu X M and Ma J Y. 2022b. Multi-task interaction learning for spatio-spectral image super-resolution. *IEEE Transactions on Image Processing*, 31: 2950-2961 [DOI: 10.1109/TIP.2022.3161834]
- Magid S A, Zhang Y L, Wei D L, Jang W D, Lin Z D, Fu Y and Pfister H. 2021. Dynamic high-pass filtering and multi-spectral attention for image super-resolution//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 4268-4277 [DOI: 10.1109/ICCV48922.2021.00425]
- Masi G, Cozzolino D, Verdoliva L and Scarpa G. 2016. Pansharpening by convolutional neural networks. *Remote Sensing*, 8 (7) : #594 [DOI: 10.3390/rs8070594]
- McElfresh C, Harrington T and Vecchio K S. 2018. Application of a novel new multispectral nanoparticle tracking technique. *Measurement Science and Technology*, 29(6) : #065002 [DOI: 10.1088/1361-6501/aab940]
- Mei S H, Jiang R T, Li X and Du Q. 2020. Spatial and spectral joint super-resolution using convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 58 (7) : 4590-4603 [DOI: 10.1109/TGRS.2020.2964288]
- Mei S H, Yuan X, Ji J Y, Zhang Y F, Wan S and Du Q. 2017. Hyperspectral image spatial super-resolution via 3D full convolutional neural network. *Remote Sensing*, 9(11) : #1139 [DOI: 10.3390/rs9111139]
- Meng X C, Wang N, Shao F and Li S T. 2022. Vision transformer for pansharpening. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5409011 [DOI: 10.1109/TGRS.2022.3168465]
- Murguía J, Diaz G, Reeves T, Nelson R, Mooney J, Shepherd F, Griffith G and Franco D. 2010. Applications of multispectral video//Proceedings of SPIE 7780, Detectors and Imaging Devices: Infra-red, Focal Plane, Single Photon. San Diego, USA: SPIE: #77800B [DOI: 10.1117/12.861631]
- Nie J T, Zhang L, Wei W, Yan Q S, Ding C, Chen G C and Zhang Y N. 2023. A survey of hyperspectral image super-resolution method. *Journal of Image and Graphics*, 28 (6) : 1685-1697 (聂江涛, 张磊, 魏巍, 闫庆森, 丁晨, 陈国超, 张艳宁. 2023. 高光谱图像超分辨率重建技术研究进展. *中国图象图形学报*, 28(6) : 1685-1697) [DOI: 10.11834/jig.230038]
- Qu J H, Dong W Q, Li Y S, Hou S X and Du Q. 2023. An interpretable unsupervised unrolling network for hyperspectral pansharpening. *IEEE Transactions on Cybernetics*, 53(12) : 7943-7956 [DOI: 10.1109/TCYB.2023.3241165]
- Qu Y, Qi H R and Kwan C. 2018. Unsupervised sparse dirichlet-net for hyperspectral image super-resolution//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE: 2511-2520 [DOI: 10.1109/CVPR.2018.00266]
- Qu Y, Qi H R, Kwan C, Yokoya N and Chanussot J. 2022. Unsupervised and unregistered hyperspectral image super-resolution with mutual Dirichlet-Net. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5507018 [DOI: 10.1109/tgrs.2021.3079518]
- Ran R, Deng L J, Jiang T X, Hu J F, Chanussot J and Vivone G. 2023. GuidedNet: a general CNN fusion framework via high-resolution guidance for hyperspectral image super-resolution. *IEEE Transactions on Cybernetics*, 53 (7) : 4148-4161 [DOI: 10.1109/TCYB.2023.3238200]
- Redmon J, Divvala S, Girshick R and Farhadi A. 2016. You only look once: unified, real-time object detection//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE: 779-788 [DOI: 10.1109/CVPR.2016.91]
- Ren S Q, He K M, Girshick R and Sun J. 2017. Faster R-CNN: towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6) : 1137-1149 [DOI: 10.1109/tpami.2016.2577031]
- Shelhamer E, Long J and Darrell T. 2017. Fully convolutional networks for semantic segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39 (4) : 640-651 [DOI: 10.1109/TPAMI.2016.2572683]
- Shi C and Wang L. 2014. Incorporating spatial information in spectral unmixing: a review. *Remote Sensing of Environment*, 149: 70-87 [DOI: 10.1016/j.rse.2014.03.034]
- Shi Y, Han L X, Han L H, Chang S, Hu T L and Dancesy D. 2022. A latent encoder coupled generative adversarial network (LE-GAN) for efficient hyperspectral image super-resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5534819 [DOI: 10.1109/TGRS.2022.3193441]
- Tang L F, Zhang H, Xu H and Ma J Y. 2023. Deep learning-based image fusion: a survey. *Journal of Image and Graphics*, 28(1) : 3-

- 36 (唐霖峰, 张浩, 徐涵, 马佳义. 2023. 基于深度学习的图像融合方法综述. 中国图象图形学报, 28(1): 3-36 [DOI: 10.11834/jig.220422])
- Tang S Z, Xu Y, Huang L L and Sun L. 2019. Hyperspectral image super-resolution via adaptive dictionary learning and double  $\ell_1$  constraint. *Remote Sensing*, 11(23): #2809 [DOI: 10.3390/rs11232809]
- Wang Q, Li Q and Li X L. 2021a. Hyperspectral image superresolution using spectrum and feature context. *IEEE Transactions on Industrial Electronics*, 68(11): 11276-11285 [DOI: 10.1109/TIE.2020.3038096]
- Wang W, Zheng W H, Huang Y, Ding X H and Paisley J. 2019. Deep blind hyperspectral image fusion//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea (South): IEEE: 4149-4158 [DOI: 10.1109/ICCV.2019.00425]
- Wang X Y, Ma J Y and Jiang J J. 2022. Hyperspectral image super-resolution via recurrent feedback embedding and spatial-spectral consistency regularization. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5503113 [DOI: 10.1109/TGRS.2021.3064450]
- Wang Y, Chen X A, Han Z and He S Y. 2017. Hyperspectral image super-resolution via nonlocal low-rank tensor approximation and total variation regularization. *Remote Sensing*, 9(12): #1286 [DOI: 10.3390/rs9121286]
- Wang Y D, Deng L J, Zhang T J and Wu X. 2021b. SSconv: explicit spectral-to-spatial convolution for pansharpening//Proceedings of the 29th ACM International Conference on Multimedia. Virtual Event: ACM: 4472-4480 [DOI: 10.1145/3474085.3475600]
- Wang Z and Bovik A. 2002. A universal image quality index. *IEEE Signal Processing Letters*, 9(3): 81-84 [DOI: 10.1109/97.995823]
- Wang Z J, Chen B, Lu R Y, Zhang H, Liu H W and Varshney P K. 2020. FusionNet: an unsupervised convolutional variational network for hyperspectral and multispectral image fusion. *IEEE Transactions on Image Processing*, 29: 7565-7577 [DOI: 10.1109/TIP.2020.3004261]
- Wu C X, Li J J, Song R, Li Y S and Du Q. 2023. HPRN: holistic prior-embedded relation network for spectral super-resolution. *IEEE Transactions on Neural Networks and Learning Systems*: #3260828 [DOI: 10.1109/TNNLS.2023.3260828]
- Xie Q, Zhou M H, Zhao Q, Meng D Y, Zuo W M and Xu Z B. 2019a. Multispectral and hyperspectral image fusion by MS/HS fusion net//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 1585-1594 [DOI: 10.1109/cvpr.2019.00168]
- Xie Q, Zhou M H, Zhao Q, Xu Z B and Meng D Y. 2022. MHF-Net: an interpretable deep network for multispectral and hyperspectral image fusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(3): 1457-1473 [DOI: 10.1109/TPAMI.2020.3015691]
- Xie W Y, Jia X P, Li Y S and Lei J. 2019b. Hyperspectral image super-resolution using deep feature matrix factorization. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8): 6055-6067 [DOI: 10.1109/tgrs.2019.2904108]
- Xiong Z H, Shi Z, Li H Q, Wang L Z, Liu D and Wu F. 2017. HSCNN: CNN-based hyperspectral image recovery from spectrally undersampled projections//Proceedings of 2017 IEEE International Conference on Computer Vision Workshops. Venice, Italy: IEEE: 518-525 [DOI: 10.1109/ICCVW.2017.68]
- Xu Q Z, Li Y, Nie J Y, Liu Q J and Guo M Y. 2023. UPanGAN: unsupervised pansharpening based on the spectral and spatial loss constrained generative adversarial network. *Information Fusion*, 91: 31-46 [DOI: 10.1016/j.inffus.2022.10.001]
- Xu S, Zhang J S, Zhao Z X, Sun K, Liu J M and Zhang C X. 2021. Deep gradient projection networks for pan-sharpening//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 1366-1375 [DOI: 10.1109/CVPR46437.2021.00142]
- Xu X Y, Li J J and Hua Z. 2022. Transformer-based regression network for pansharpening remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5407423 [DOI: 10.1109/TGRS.2022.3152425]
- Xu Y, Wu Z B, Chanussot J and Wei Z H. 2020. Hyperspectral images super-resolution via learning high-order coupled tensor ring representation. *IEEE Transactions on Neural Networks and Learning Systems*, 31(11): 4747-4760 [DOI: 10.1109/TNNLS.2019.2957527]
- Yang G, Zhou M, Yan K Y, Liu A P, Fu X Y and Wang F. 2022. Memory-augmented deep conditional unfolding network for pansharpening//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 1778-1787 [DOI: 10.1109/CVPR52688.2022.00183]
- Yang J F, Fu X Y, Hu Y W, Huang Y, Ding X H and Paisley J. 2017. PanNet: a deep network architecture for pan-sharpening//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice, Italy: IEEE: 1753-1761 [DOI: 10.1109/iccv.2017.193]
- Yang J X, Zhao Y Q, Chan J C W and Xiao L. 2019. A multi-scale wavelet 3D-CNN for hyperspectral image super-resolution. *Remote Sensing*, 11(13): #1557 [DOI: 10.3390/rs11131557]
- Yao J, Hong D F, Chanussot J, Meng D Y, Zhu X X and Xu Z B. 2020. Cross-attention in coupled unmixing nets for unsupervised hyperspectral super-resolution//Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer: 208-224 [DOI: 10.1007/978-3-030-58526-6\_13]
- Yuan Q Q, Wei Y C, Meng X C, Shen H F and Zhang L P. 2018. A multiscale and multidepth convolutional neural network for remote sensing imagery pan-sharpening. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(3): 978-989 [DOI: 10.1109/JSTARS.2018.2794888]
- Zhang J Z, Xu T F, Jiang S W, Zhang Y H and Li J N. 2023a. Hyperspectral image joint super-resolution via implicit neural representa-

- tion//Proceedings of SPIE 12565, Conference on Infrared, Millimeter, Terahertz Waves and Applications. Shanghai, China: SPIE: #125650Z [DOI: 10.1117/12.2661749]
- Zhang K W, Zhu D D, Min X K and Zhai G T. 2023b. Implicit neural representation learning for hyperspectral image super-resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 61: #5500212 [DOI: 10.1109/TGRS.2022.3230204]
- Zhang L, Lang Z Q, Wang P, Wei W, Liao S C, Shao L and Zhang Y N. 2020a. Pixel-aware deep function-mixture network for spectral super-resolution//Proceedings of the 34th AAAI Conference on Artificial Intelligence. New York, USA: AAAI: 12821-12828 [DOI: 10.1609/aaai.v34i07.6978]
- Zhang L, Nie J T, Wei W, Li Y and Zhang Y N. 2021. Deep blind hyperspectral image super-resolution. *IEEE Transactions on Neural Networks and Learning Systems*, 32 (6): 2388-2400 [DOI: 10.1109/TNNLS.2020.3005234]
- Zhang L, Nie J T, Wei W, Zhang Y N, Liao S C and Shao L. 2020b. Unsupervised adaptation learning for hyperspectral imagery super-resolution//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 3070-3079 [DOI: 10.1109/CVPR42600.2020.00314]
- Zhang L, Wei W, Bai C C, Gao Y F and Zhang Y N. 2018. Exploiting clustering manifold structure for hyperspectral imagery super-resolution. *IEEE Transactions on Image Processing*, 27(12): 5969-5982 [DOI: 10.1109/TIP.2018.2862629]
- Zhang L P, He J, Yang Q Q, Xiao Y and Yuan Q Q. 2022. Data-driven multi-source remote sensing data fusion: progress and challenges. *Acta Geodaetica et Cartographica Sinica*, 51(7): 1317-1337 (张良培, 何江, 杨倩倩, 肖屹, 袁强强. 2022. 数据驱动的多源遥感信息融合研究进展. *遥感学报*. 51(7): 1317-1337) [DOI: 10.11947/j.AGCS.2022.20220171]
- Zhang M J, Zhang C, Zhang Q M, Guo J, Gao X B and Zhang J. 2023c. ESSAformer: efficient transformer for hyperspectral image super-resolution//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE: 23016-23027 [DOI: 10.1109/ICCV51070.2023.02109]
- Zhang T, Fu Y, Huang L W, Li S Y, You S D and Yan C G. 2023d. RGB-guided hyperspectral image super-resolution with deep progressive learning. *CAAI Transactions on Intelligence Technology*: #12256 [DOI: 10.1049/cit2.12256]
- Zhang T, Fu Y and Li C. 2021. Hyperspectral image denoising with realistic data//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 2228-2237 [DOI: 10.1109/ICCV48922.2021.00225]
- Zhang T, Fu Y and Li C. 2022a. Deep spatial adaptive network for real image demosaicing//Proceedings of the 36th AAAI Conference on Artificial Intelligence. [s.l.]: AAAI: 3326-3334 [DOI: 10.1609/aaai.v36i3.20242]
- Zhang T, Fu Y, Wang L Z and Huang H. 2019. Hyperspectral image reconstruction using deep external and internal learning//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea (South): IEEE: 8558-8567 [DOI: 10.1109/ICCV.2019.00865]
- Zhang T, Fu Y, Zhang D B and Hu C. 2023e. Deep external and internal learning for noisy compressive sensing. *Neurocomputing*, 531: 61-73 [DOI: 10.1016/j.neucom.2023.01.092]
- Zhang T, Fu Y and Zhang J. 2022b. Guided hyperspectral image denoising with realistic data. *International Journal of Computer Vision*, 130(11): 2885-2901 [DOI: 10.1007/s11263-022-01660-2]
- Zhang T, Fu Y, Zhang J and Yan C G. 2024. Deep guided attention network for joint denoising and demosaicing in real image. *Chinese Journal of Electronics*, 33(1): 303-312 [DOI: 10.23919/cje.2022.00.414]
- Zhang T, Liang Z Y and Fu Y. 2022c. Joint spatial-spectral pattern optimization and hyperspectral image reconstruction. *IEEE Journal of Selected Topics in Signal Processing*, 16(4): 636-648 [DOI: 10.1109/JSTSP.2022.3179806]
- Zheng K, Gao L R, Hong D F, Zhang B and Chanussot J. 2022a. Non-RegSRNet: a nonrigid registration hyperspectral super-resolution network. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5520216 [DOI: 10.1109/TGRS.2021.3135501]
- Zheng K, Gao L R, Liao W Z, Hong D F, Zhang B, Cui X M and Chanussot J. 2021b. Coupled convolutional neural network with adaptive response function learning for unsupervised hyperspectral super resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 59 (3): 2487-2502 [DOI: 10.1109/TGRS. 2020. 3006534]
- Zheng X T, Chen W J and Lu X Q. 2022b. Spectral super-resolution of multispectral images using spatial-spectral residual attention network. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5404114 [DOI: 10.1109/TGRS.2021.3104476]
- Zheng Y R, Zhang T and Fu Y. 2022c. A large-scale hyperspectral dataset for flower classification. *Knowledge-Based Systems*, 236: #107647 [DOI: 10.1016/j.knsys.2021.107647]
- Zheng Y X, Li J J, Li Y S, Guo J, Wu X Y and Chanussot J. 2020. Hyperspectral pansharpening using deep prior and dual attention residual network. *IEEE Transactions on Geoscience and Remote Sensing*, 58 (11): 8059-8076 [DOI: 10.1109/TGRS. 2020. 2986313]
- Zhou M, Huang J, Fang Y C, Fu X Y and Liu A P. 2022a. Pansharpening with customized transformer and invertible neural network//Proceedings of the 36th AAAI Conference on Artificial Intelligence. [s.l.]: AAAI: 3553-3561 [DOI: 10.1609/aaai.v36i3.20267]
- Zhou M, Huang J, Li C Y, Yu H, Yan K Y, Zheng N S and Zhao F. 2022b. Adaptively learning low-high frequency information integration for pan-sharpening//Proceedings of the 30th ACM International Conference on Multimedia. Lisboa, Portugal: ACM: 3375-3384

[DOI: 10.1145/3503161.3547924]

Zhou M, Huang J, Yan K Y, Yu H, Fu X Y, Liu A P, Wei X and Zhao F. 2022c. Spatial-frequency domain information integration for pan-sharpening//Proceedings of 17th European Conference on Computer Vision. Tel Aviv, Israel: Springer: 274-291 [DOI: 10.1007/978-3-031-19797-0\_16]

Zhou M, Yan K Y, Fu X Y, Liu A P and Xie C J. 2023. PAN-guided band-aware multi-spectral feature enhancement for pan-sharpening. IEEE Transactions on Computational Imaging, 9: 238-249 [DOI: 10.1109/TCI.2023.3248956]

Zhou M, Yan K Y, Huang J, Yang Z H, Fu X Y and Zhao F. 2022d. Mutual information-driven pan-sharpening//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 1788-1798 [DOI: 10.1109/CVPR52688.2022.00184]

Zhu Z Y, Hou J H, Chen J, Zeng H Q and Zhou J T. 2021a. Hyperspectral image super-resolution via deep progressive zero-centric residual learning. IEEE Transactions on Image Processing, 30: 1423-1438 [DOI: 10.1109/tip.2020.3044214]

Zhu Z Y, Liu H, Hou J H, Jia S and Zhang Q F. 2021b. Deep amended gradient descent for efficient spectral reconstruction from single RGB images. IEEE Transactions on Computational Imaging, 7: 1176-1188 [DOI: 10.1109/TCI.2021.3124364]

Zhu Z Y, Liu H, Hou J H, Zeng H Q and Zhang Q F. 2021c. Semantic-embedded unsupervised spectral reconstruction from single RGB images in the wild//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 2259-2268 [DOI: 10.1109/ICCV48922.2021.00228]

## 作者简介

张涛,男,副研究员,主要研究方向为计算机视觉、计算摄像学和图像处理。E-mail:tzhang@hdu.edu.cn

付莹,通信作者,女,教授,主要研究方向为计算机视觉、计算摄像学和图像处理。E-mail:fuying@bit.edu.cn

王彬洋,男,硕士研究生,主要研究方向为深度学习和图像处理。E-mail:wbf\_bit@163.com

刘松荣,男,正高级工程师,主要研究方向为智能信息处理。E-mail:59036251@qq.com

叶吉超,女,高级工程师,主要研究方向为信息技术。

E-mail:155182359@qq.com

单培红,女,高级工程师,主要研究方向为计算机应用和深度学习。E-mail:shanph.zj@chinatelecom.cn

颜成钢,男,研究员,主要研究方向为智能信息处理、机器学习、图像处理和计算摄像学。E-mail:cgyan@hdu.edu.cn