

DOI:10.3969/j.issn.2096-8248.2024.04.011

## 基于深度学习的多光谱与全色遥感图像融合方法综述\*

康家银, 姬云翔, 马寒雁, 章洋洋, 张文慧, 王怀友

(江苏海洋大学 电子工程学院, 江苏 连云港 222005)

**摘要:** 多光谱(multispectral, MS)遥感图像具有丰富的光谱信息,但其空间分辨率相对较低;全色(panchromatic, PAN)遥感图像具有较高的空间分辨率,但缺乏光谱信息。通过图像融合技术将多光谱和全色遥感图像进行信息集成,生成一幅光谱信息丰富、空间分辨率高的融合图像,以便将二者的优势互补,从而有利于后继视觉任务的完成。近年来,随着深度学习的兴起及其在计算机视觉领域的广泛应用,研究者们提出了许多面向图像融合的深度学习方法。鉴于国内鲜有 MS 和 PAN 遥感图像融合方面的研究综述,故对基于深度学习的多光谱和全色遥感图像融合方法进行归纳、分析和总结,并对基于深度学习的多光谱和全色遥感图像融合的发展方向进行展望。

**关键词:** 图像融合; 遥感图像融合; 深度学习; 卷积神经网络; 生成对抗网络; Transformer

**中图分类号:** TP751; TP183 **文献标志码:** A **文章编号:** 2096-8248(2024)04-0083-11

**引用格式:** 康家银, 姬云翔, 马寒雁, 等. 基于深度学习的多光谱与全色遥感图像融合方法综述[J]. 江苏海洋大学学报(自然科学版), 2024, 33(4): 83-93.

## Deep Learning-based Multispectral and Panchromatic Remote Sensing Image Fusion Methods

KANG Jiayin, JI Yunxiang, MA Hanyan, ZHANG Yangyang, ZHANG Wenhui, WANG Huaiyou  
(School of Electronic Engineering, Jiangsu Ocean University, Lianyungang 222005, China)

**Abstract:** Multispectral (MS) remote sensing image has rich spectral information, but its spatial resolution is relatively low. By contrast, panchromatic (PAN) remote sensing image has high spatial resolution, but lacks spectral information. In practice, a fused image can be obtained by integrating the information of MS with that of PAN via image fusion technology, and the fused image contains both rich spectral information and high spatial resolution. In other words, the fused image has the complementary information coming from the MS and PAN remote sensing images, and is more suitable for down-stream vision tasks. With the rise of deep learning and its wide applications in the field of computer vision, researchers have developed numerous deep learning-based methods for image fusion tasks in the past few years. However, the survey works on MS and PAN image fusion are rarely reported in Chinese journals. To this end, according to the different learning manner of network models, this paper classifies, analyzes, and summarizes the deep learning-based methods for MS and PAN remote sensing image fusion. In addition, this paper puts forward some possible future research directions related to deep learning-based MS and

\* 收稿日期: 2024-02-24; 修订日期: 2024-03-11

基金项目: 国家自然科学基金面上资助项目(62271236); 江苏省研究生科研与实践创新计划项目(KYCX2022-41, KYCX2023-10, KYCX24-3682, SJCX24-2105)

作者简介: 康家银(1974—), 男, 宁夏西吉人, 教授, 博士, 研究方向为图像处理与机器学习, (E-mail) kangjiayin2002@163.com。

PAN remote sensing image fusion.

**Key words:** image fusion; remote sensing image fusion; deep learning; convolutional neural network; generative adversarial network; Transformer

## 0 引言

遥感(remote sensing, RS)技术是指通过远距离感知设备(遥感器)探测和采集地物目标的反射光谱、电磁波等信息,从而实现在远距离、非接触的测量条件下感知地物目标。RS 具有快捷高效、探测范围广等优势<sup>[1-2]</sup>。不同的遥感探测设备采集到的图像(遥感图像)具有不同的特性,其中多光谱(multi-spectral, MS)遥感图像与全色(panchromatic, PAN)遥感图像是两种常见的遥感图像。实际中,由于不同遥感器采集图像的原理不同以及遥感器自身的限制性,使得同一遥感器难以采集到不同类型的遥感图像。如在获取光谱信息丰富的多光谱遥感图像时,遥感器需要采集多个光谱波段信息,这会导致空间分辨率降低;而在获取具有高空间分辨率的全色遥感图像时,遥感器需要采集可见光波段区域内的较窄波段范围,这会导致难以获取丰富的光谱信息等。为此,实际应用中通过图像融合技术获取具有不同遥感图像特性的融合图像。如将含有同一地物目标的多光谱与全色遥感图像进行融合,可以得到同时具有丰富的光谱信息与高空间分辨率的融合图像,从而有利于后续进一步的分析和理解<sup>[3]</sup>。

现有的多光谱和全色遥感图像融合方法大致可分为传统的融合方法与基于深度学习的融合方法<sup>[4]</sup>。传统融合方法可进一步分为 4 类:多分辨率分析法(multi-resolution analysis, MRA)、基于变分优化(variational optimization, VO)的方法、组分替换法(component substitution, CS)以及基于模型的方法。传统融合方法具有易于实现、可解释、处理速度快、易于控制融合质量并便于针对不同场景任务进行优化等优点,但存在一定的不足<sup>[5]</sup>,如需要人为设计复杂的融合规则以及先验、特征提取能力较弱等问题。

近年来,由于具有强大的特征提取和数据处理能力,深度学习在图像融合领域取得了优异的成绩。基于深度学习的图像融合方法主要包括卷积神经网络(convolutional neural networks, CNN)<sup>[6]</sup>、生成式对抗网络(generative adversarial networks, GAN)<sup>[7]</sup>

和视觉 Transformer (vision transformer, ViT) 网络。基于深度学习的图像融合方法通常具有如下优势:① 深度学习模型可以从输入的数据中自动提取出最关键的数据特征,从而解决了人工设计特征难度较大的问题;② 深度学习模型可以很好地表现出输入数据与目标间复杂的映射关系;③ 深度学习的一些潜在的图像表示方法更契合于图像融合的任务;④ 基于深度学习的方法往往需要大量的数据支持,很多深度学习库和大规模图像数据集为基于深度学习的图像融合研究提供了帮助<sup>[8-9]</sup>,如 World-View 系列数据集、IKONOS 数据集、QuickBird 数据集等。

基于以上分析,针对多光谱与全色遥感图像的融合问题,本文对近年来提出的基于深度学习的融合方法按照 3 个类别分别进行归纳、分析与总结,即基于卷积神经网络的融合方法、基于生成对抗网络的融合方法以及基于视觉 Transformer 的融合方法。

## 1 基于深度学习的 MS 和 PAN 遥感图像融合方法

### 1.1 基于卷积神经网络(CNN)的融合方法

卷积神经网络是目前基于深度学习的遥感图像融合方法中使用最为广泛的网络模型之一,具有较强的局部特征提取能力与特征整合能力。基于卷积神经网络的方法可进一步分为有监督学习的模型与无监督学习的模型。融合框架如图 1 所示,其中图 1a 为无监督学习的 CNN 图像融合框架,图 1b 为有监督学习的 CNN 图像融合框架。

基于有监督学习与无监督学习的卷积神经网络的遥感图像融合方法均需要设计网络结构和用于约束网络优化的损失函数,区别在于:基于有监督学习的卷积神经网络遥感图像融合模型需要在真实图像(ground truth, GT)与融合图像之间建立一致性度量,以引导融合图像趋向于期望结果;而基于无监督学习的卷积神经网络遥感图像融合模型需要在参考图像(多光谱图像、全色图像)与融合图像之间建立一致性度量,以引导融合图像趋向于期望结果。近

年来基于卷积神经网络的多光谱与全色遥感图像融合方法如表 1 所示。

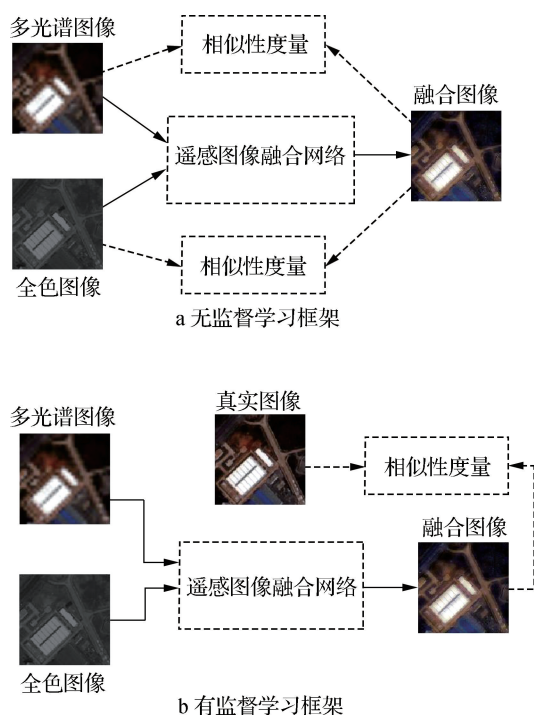


图 1 基于卷积神经网络的遥感图像融合框架

Fig. 1 Remote sensing image fusion framework based on convolutional neural network

表 1 基于 CNN 的 MS 和 PAN 遥感图像融合方法

Table 1 CNN-based methods for MS and PAN remote sensing image fusion

方法	年份	有/无监督学习
UCNN <sup>[10]</sup>	2020	无监督学习
UPSNet <sup>[11]</sup>	2020	无监督学习
BKL <sup>[12]</sup>	2020	无监督学习
TFNet <sup>[13]</sup>	2020	有监督学习
SRPPNN <sup>[14]</sup>	2020	有监督学习
MDCNN <sup>[15]</sup>	2021	有监督学习
GPPNN <sup>[16]</sup>	2021	有监督学习
HMCNN <sup>[17]</sup>	2021	有监督学习
LDP-Net <sup>[18]</sup>	2022	无监督学习
SIPSA-Net <sup>[19]</sup>	2021	有监督学习
SDPNet <sup>[20]</sup>	2020	有监督学习
LAGConv <sup>[21]</sup>	2022	有监督学习
TDNet <sup>[22]</sup>	2022	有监督学习
MCRNN <sup>[23]</sup>	2022	有监督学习
GTP-PNet <sup>[24]</sup>	2021	有监督学习
DPFN <sup>[25]</sup>	2022	有监督学习
DIM-FuNet <sup>[26]</sup>	2022	有监督学习
SUFNet <sup>[27]</sup>	2023	无监督学习
PSCF-Net <sup>[28]</sup>	2023	有监督学习
SDRCNN <sup>[29]</sup>	2023	有监督学习

从卷积神经网络在计算机视觉任务中得到的启发, Liu 等<sup>[13]</sup>提出了一种名为 TFNet 的双支路 MS 与 PAN 遥感图像融合网络。与大多数遥感图像融合网络不同, TFNet 将图像融合视为图像超分辨率问题, 通过将全色图像与多光谱图像融合到特征域, 得到高分辨率的多光谱融合图像。TFNet 包括两个子网络, 即一个用于分别提取全色图像的空间信息与提取多光谱图像的光谱信息的卷积神经网络, 另一个用于将提取得到的特征信息进行融合的网络。此外, 通过分别设计提取全色图像空间信息与提取多光谱图像光谱信息的双支路网络结构, 融合得到同时具有空间信息与光谱信息的融合图像。

由于 MS 和 PAN 遥感图像融合(又称为 Pan-sharpening)与图像超分辨率方法都具有提高遥感图像分辨率的目的, Cai 等<sup>[14]</sup>提出了一种名为 SRPPNN 的基于深度超分辨率卷积神经网络的遥感图像融合方法。SRPPNN 由超分辨率层、渐进式 Pansharpening 层与高通道残差块组成。通过超分辨率层提取多光谱图像的空间细节信息后, 将空间细节信息输入到渐进式 Pansharpening 层, 然后通过高通道残差块提取空间细节后输入到融合图像, 以实现较好的融合效果。

编码器-解码器(encoder-decoder)网络结构在基于 CNN 的遥感图像融合方法中也取得了许多成果。Xu 等<sup>[20]</sup>提出了一种名为 SDPNet 的 MS 和 PAN 遥感图像融合方法。SDPNet 由两个编码器-解码器网络组成, 两个网络分别用于提取源图像的浅层特征与深层特征; 此外, SDPNet 通过一个基于密集连接(densely connection)的泛 Pansharpening 网络来增强融合图像与真实图像间的相似性。

残差网络具有提高网络表达能力、缓解梯度消失、易于优化等优势。Zhang 等<sup>[24]</sup>提出了一种名为 GTP-PNet 的基于梯度转换的残差网络。GTP-PNet 由梯度转换网络(TNet)与泛 Pansharpening 残差网络(PNet)组成, 并通过 TNet 在全色图像与高分辨率多光谱图像之间建立映射关系, 以约束 PNet 生成既包含多光谱图像丰富的光谱信息又符合全色图像空间结构的梯度转换关系的融合图像。

Fang 等<sup>[29]</sup>提出了一种名为 SDRCNN 的单尺度、轻量级卷积神经网络, 通过密集残差连接的卷积神经网络结构实现 MS 与 PAN 遥感图像的融合。该网络在得到具有较少空间细节模糊与光谱失真的

融合图像的同时,减少了网络处理时间,提高了遥感图像融合效率。

基于 CNN 的 Pansharpening 任务通常为有监督学习的图像融合模式,但实际中真实图像往往难以获得。Luo 等<sup>[10]</sup>提出了一种名为 UCNN 的基于 CNN 的无监督遥感图像融合网络模型,该模型通过利用基于全色图像引导与跳跃连接(skip connection)的迭代网络从源图像中不断地提取特征,从而实现遥感图像特征的融合。与此同时,该模型从源图像与融合图像之间的空间约束与光谱一致性两个层面设计了一种无监督训练损失函数,实现了网络表示能力与特征提取能力的增强,并取得了较好的融合效果。

Ni 等<sup>[18]</sup>提出了一种名为 LDP-Net 的无监督泛 Pansharpening 网络模型。该模型通过两个基于 CNN 的模块自适应地学习源图像的退化过程,并设计了一种新的混合损失函数以约束融合图像与全色图像、多光谱图像间的空间一致性与光谱一致性。

Liu 等<sup>[27]</sup>设计了一种有监督—无监督混合的遥感图像融合网络——SUFNet。SUFNet 由一个称为 SMDSNet 的有监督网络与一个称为 USSCNet 的无监督网络组成,其中 SMDSNet 通过集成多尺度机制、空洞卷积与跳跃连接来实现对源图像特征的提取,并通过 USSCNet 进行空间特征补偿与光谱特征补偿,从而最终得到具有较高空间信息保真度与光谱信息保真度的融合图像。

卷积神经网络在遥感图像融合中展现了强大的局部特征提取能力,但一方面,有监督的卷积神经网络模型在训练时需要真实图像,而这一先决条件在实际中往往难以满足;另一方面,通过无监督的卷积神经网络模型获得的融合图像仍存在一定程度的光谱失真、空间细节模糊等问题。

## 1.2 基于生成对抗网络(GAN)的融合方法

基于生成对抗网络的遥感图像融合方法通过构建生成器使其学习和拟合图像的数据分布,从而达到以假乱真的目的;与此同时,构建判别器使其尽可能分辨出生成器所生成的图像与真实图像。GAN 模型通过生成器与判别器之间的对抗训练来提升二者的能力,最终得到一个能够生成预期数据分布的神经网络,从而实现图像融合的目的<sup>[30]</sup>。GAN 的主体结构包括两个模型:一个是捕获数据分布的生成器;另一个是判断样本是来自真实数据还是合成数据的判别器。图 2 所示为基

于 GAN 的 MS 与 PAN 遥感图像融合的框架,其中图 2a 为基于 GAN 的无监督学习的遥感图像融合框架,图 2b 为基于 GAN 的有监督学习的遥感图像融合框架。

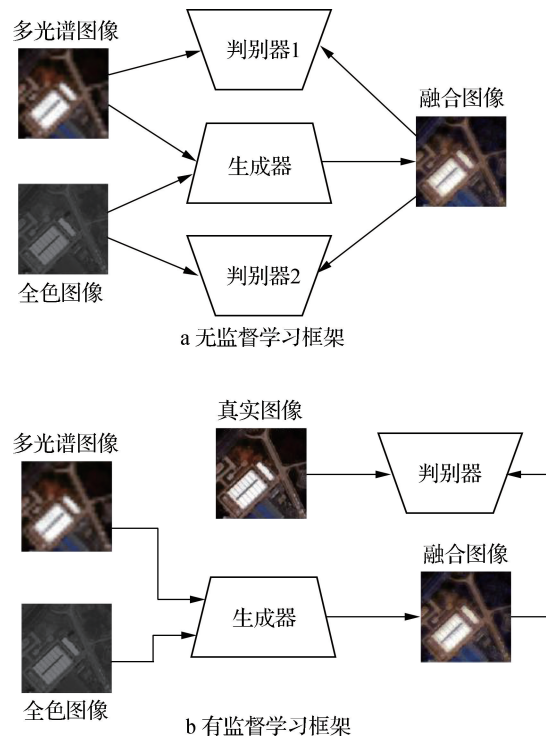


图 2 基于生成对抗网络的遥感图像融合框架  
 Fig. 2 Remote sensing image fusion framework based on generative adversarial network

GAN 的本质是在生成器与判别器之间建立一个对抗博弈,并在不断的迭代训练中提升各自的性能;此外,通过设计生成器与判别器的网络结构和损失函数,引导融合图像趋于目标图像的数据分布。近年来,研究者们提出的基于 GAN 的 MS 和 PAN 遥感图像融合方法如表 2 所示。

Liu 等<sup>[31]</sup>在 2021 年提出了基于生成对抗网络的 MS 和 PAN 遥感图像融合方法——PSGAN。PSGAN 作为生成对抗网络在有监督遥感图像融合任务中的首次尝试方法之一,设计其网络结构为:将全色图像经卷积后提取特征图;将多光谱图像上采样,然后经卷积后提取特征图;将从全色图像和多光谱图像中提取的特征图在通道维度联结,然后输入到生成器中。接着,将真实图像与生成器生成的融合图像分别输入到判别器中,实现判别器对生成器的约束,从而使得生成器最终生成趋于真实图像数据分布的融合图像。

表 2 基于 GAN 的 MS 和 PAN 遥感图像融合方法

Table 2 GAN-based methods for MS and PAN remote sensing image fusion

方法	年份	有/无监督学习
Pan-GAN <sup>[30]</sup>	2020	无监督学习
PSGAN <sup>[31]</sup>	2021	有监督学习
HPGAN <sup>[32]</sup>	2020	有监督学习
MDSSC-GAN <sup>[33]</sup>	2022	无监督学习
PanColorGAN <sup>[34]</sup>	2020	无监督学习
FGF-GAN <sup>[35]</sup>	2021	有监督学习
CycleGAN <sup>[36]</sup>	2021	无监督学习
DI-GAN <sup>[37]</sup>	2022	有监督学习
MSGAN <sup>[38]</sup>	2022	无监督学习
PC-GANs <sup>[39]</sup>	2022	无监督学习
ZeRGAN <sup>[40]</sup>	2022	无监督学习
UCGAN <sup>[41]</sup>	2022	无监督学习
UPanGAN <sup>[42]</sup>	2023	无监督学习
TriLossGAN <sup>[43]</sup>	2024	无监督学习
RMFF-UPGAN <sup>[44]</sup>	2023	无监督学习
MSDI-GAN <sup>[45]</sup>	2023	无监督学习
ICPGAN <sup>[46]</sup>	2023	无监督学习
Mun-GAN <sup>[47]</sup>	2023	无监督学习

考虑到将源图像直接在通道维度联结后输入至生成器的方式会忽略全色图像的空间信息, Zhao 等<sup>[35]</sup>提出了一种基于快速引导滤波(fast guided filter)的生成对抗网络的 MS 和 PAN 遥感图像融合方法——FGF-GAN。该模型通过将源图像经特征增强层、快速引导滤波、空间注意力层处理后逐层联结的方式,更好地保留了全色图像的空间信息。

为保留多光谱图像光谱信息的同时保留全色图像的空间信息, Benzenati 等<sup>[37]</sup>提出了一种名为 DI-GAN 的基于双支路生成对抗网络的 MS 与 PAN 遥感图像融合方法。该方法通过向多光谱图像注入从全色图像中提取的高频细节特征来提高多光谱图像的空间分辨率,致使最终得到融合图像既保留了多光谱图像的光谱信息,又具有较高的空间分辨率。

基于无监督生成对抗网络的遥感图像融合方法近年来也取得了许多成果,其中 Ma 等<sup>[30]</sup>在 2020 年首次提出了基于生成对抗网络的无监督 MS 和 PAN 遥感图像融合方法——Pan-GAN。Pan-GAN 由一个生成器与两个判别器组成,两个判别器分别为空间判别器和光谱判别器。该模型通过生成器与空间判别器、光谱判别器的对抗训练,生成同时具有多光谱图像光谱信息与全色图像空间信息的融合图像。

为了更好地保留全色图像的空间信息与多光谱图像的光谱信息, Gastineau 等<sup>[33]</sup>提出了一种基于空间和光谱判别器的生成对抗网络的 MS 和 PAN

遥感图像融合方法——MDSSC-GAN。该模型将源图像与融合图像分别经 YCbCr 色彩空间转换后分解为 Y 通道分量、Cb 通道分量与 Cr 通道分量,并将源图像、融合图像的近红外光谱带与 Y 通道分量输入到空间判别器中;将源图像、融合图像的 Cb 通道分量与 Cr 通道分量输入到光谱判别器,从而实现融合图像具有较高的空间信息与丰富的光谱信息。

Zhou 等<sup>[41]</sup>提出了一种基于周期一致性和生成对抗网络的无监督 MS 和 PAN 遥感图像融合方法——UCGAN。该方法采用双支路生成器网络从源图像(MS 和 PAN 遥感图像)中提取具有特定模式的特征,并设计了一种基于周期一致性的混合损失函数用以约束生成对抗网络的训练过程,从而取得了较好的融合效果。

为了进一步加深生成器与判别器之间的梯度信息交互,以及优化网络的训练过程, Meng 等<sup>[45]</sup>提出了一种基于多尺度细节信息输入的改进生成对抗网络的 MS 和 PAN 遥感图像融合方法——MSDI-GAN。在 MSDI-GAN 模型的生成器中,每个卷积层都将从源图像中提取到的特征输入到判别器网络中,以实现生成器与判别器之间信息的深度交互,从而生成能够保留较多空间信息与光谱信息的融合图像。

考虑全色图像与多光谱图像在特征融合过程中,若仅采取在通道维度联结或求和的方式会造成关键特征被忽略或冗余特征被保留的问题, Liu 等<sup>[47]</sup>提出了一种基于生成对抗网络的多尺度无监督 MS 和 PAN 遥感图像融合方法——Mun-GAN。模型 Mun-GAN 的生成器包括一个多尺度特征提取模块、一个自适应加权融合模块和一个特征聚合模块。具体地,首先通过多尺度特征提取模块对全色图像与多光谱图像进行多尺度特征提取;然后将提取到的特征输入到自适应加权融合模块中进行特征融合;最后通过特征聚合模块进行多尺度特征重建,从而得到融合图像。

目前,基于生成对抗网络的融合方法已经是 MS 和 PAN 遥感图像融合领域的热门研究方法之一,但是该融合方法仍存在的问题,如训练过程复杂、不稳定、容易导致模式坍塌等。

### 1.3 基于视觉 Transformer(ViT)的融合方法

Transformer 是一种最初被应用于自然语言处理领域的神经网络模型,随后因其具有强大的全局信息提取能力而被广泛地应用于计算机视觉领域。就图像融合任务而言,视觉 Transformer 主要通过注意力机制来提高融合图像的质量。具体地,利用

注意力机制将不同尺度、不同位置的特征进行加权融合,从而提高融合图像的质量。此外,在图像融合任务中,通常将具有强大全局信息提取能力的 Transformer 与具有强大局部特征提取能力的卷积神经网络相结合,以实现二者的优势互补。总体而言,随着对视觉 Transformer 研究的不断深入,其在图像融合领域的应用也将变得越来越广泛。近年来,研究者们提出的基于 ViT 的多光谱和全色遥感图像融合方法如表 3 所示。

表 3 基于 ViT 的 MS 和 PAN 遥感图像融合方法

Table 3 ViT-based methods for MS and PAN remote sensing image fusion

方法	年份	有/无监督学习
Meng 等 <sup>[48]</sup>	2022	有监督学习
Hou 等 <sup>[49]</sup>	2022	有监督学习
LNFIN <sup>[50]</sup>	2022	有监督学习
TRRNet <sup>[51]</sup>	2022	有监督学习
CPT-noRef <sup>[52]</sup>	2022	无监督学习
MSIT <sup>[53]</sup>	2022	有监督学习
LG-HSSRN <sup>[54]</sup>	2022	有监督学习
PMACNet <sup>[55]</sup>	2022	有监督学习
STCP <sup>[56]</sup>	2023	有监督学习
DTEMPan <sup>[57]</sup>	2023	有监督学习
Li 等 <sup>[58]</sup>	2023	有监督学习
DRFormer <sup>[59]</sup>	2023	有监督学习
DBCT-Net <sup>[60]</sup>	2023	有监督学习
CTCP <sup>[61]</sup>	2023	有监督学习
范文盛等 <sup>[62]</sup>	2023	无监督学习
李紫桐等 <sup>[63]</sup>	2023	有监督学习

作为将视觉 Transformer 应用到 MS 和 PAN 遥感图像融合任务中的首次尝试之一, Meng 等<sup>[48]</sup>提出了一种改进的完全基于 ViT 的遥感图像融合方法。具体地,首先将在通道维度联结的多光谱图像与全色图像裁剪成若干个图像块;然后将裁剪得到的图像块输入到 ViT 的自注意力编码器中进行特征提取与重建,从而得到具有较高空间分辨率的多光谱图像,即融合图像。

Swin Transformer 作为传统 ViT 的一种优化网络结构,具有更轻量化、更便于处理多尺度视觉信息的优势,已在遥感图像融合领域中取得了较好的效果。Hou 等<sup>[49]</sup>提出了一种基于 Swin Transformer 的 MS 与 PAN 遥感图像融合方法。该方法基于构建的残差自注意力模块和全色引导的空间分辨率融合网络,充分地利用全色图像的空间信息,从而逐层引导多光谱图像提高其空间分辨率,最终得到具有清晰空间信息与丰富光谱信息的融合图像。

Yin 等<sup>[50]</sup>提出了一种名为 LNFIN 的、用于 MS 与 PAN 遥感图像融合的局部与非局部特征交互网络。该模型由 CNN 支路与 ViT 支路组成,其中 CNN 支路包含一个用于提取源图像局部特征的多尺度密集模块;ViT 支路包含一个用于提取源图像非局部特征的 Transformer 模块,并通过一个 Swin Transformer 模块进一步增强特征的空间表示能力。

目前,将具有强大局部特征提取能力的 CNN 与具有强大上下文全局特征提取能力的视觉 Transformer 相结合,是基于视觉 Transformer 的遥感图像融合任务的研究重点之一。Zhang 等<sup>[51]</sup>提出了一种基于减少冗余的 Transformer 的 MS 和 PAN 遥感图像融合方法——TRRNet。该方法通过卷积块与 Swin Transformer 块分别提取源图像的局部特征和全局特征,并将提取到的特征分为共同特征与独特特征;然后对不同源图像之间的共同结构特征进行平均化处理,以减少结构特征的冗余,从而获得了较好的融合效果。

为克服因单纯使用 CNN 或视觉 Transformer 提取局部或全局特征而导致的空间信息丢失或光谱失真问题, Wang 等<sup>[60]</sup>提出了一种双支路混合 CNN-Transformer 的遥感图像融合网络——DBCT-Net。该网络由多支路密集连接模块与基于 Transformer 的编码器—解码器网络组成,其中在基于 Transformer 的编码器—解码器网络中,采用转置多头注意力来构建自注意力模块,以降低计算复杂度。

基于视觉 Transformer 的 MS 和 PAN 遥感图像融合方法往往会忽略遥感图像中全局与局部特征之间相互作用,从而导致融合图像出现光谱失真或空间失真问题。为此, Su 等<sup>[61]</sup>首次尝试在 Transformer 与 CNN 之间引入交叉机制,提出了一种名为 CTCP 的交叉式 Transformer 与 CNN 网络。具体地,首先构建一个交叉式、结合 Transformer 与 CNN 各自特征学习能力的双分支特征提取模块;然后利用该模块分别提取多光谱图像和全色图像的特征;此外,构建一个基于通道注意力的光谱特征增强融合模块,以提高光谱特征表示的能力。为进一步提取遥感图像的全局上下文特征并有效利用,范文盛等<sup>[62]</sup>提出一种基于双分支 U 形 Transformer 的遥感图像融合方法,该方法通过设计的双分支 U 形网络结构,实现多层特征信息交互,并取得了较好的融合结果。李紫桐等<sup>[63]</sup>提出一种基于改进 Swin Transformer 的多尺度窗口自注意力模块,通过融合不同尺寸的特征信息,保留空间与光谱信息。

基于视觉 Transformer 的 MS 与 PAN 遥感图像融合方法具有强大的全局特征提取能力,如何与其他基于深度学习的方法相结合以实现多种方法的优势互补,仍是目前图像融合研究的重点之一。虽然基于视觉 Transformer 的融合方法取得了优异的融合效果,但仍存在一些问题,如网络模型往往较大、训练参数较多、训练耗时较长等。

## 2 数据集与评价指标

### 2.1 常用数据集

遥感图像融合所需的数据集主要为多源遥感图像,包括全色图像与多光谱图像。全色图像与多光谱图像由多种遥感卫星采集,常用的遥感卫星包括国内发射的高分(GaoFen)系列卫星、国外发射的WorldView系列卫星、IKONOS卫星、QuickBird卫星等<sup>[64]</sup>。遥感卫星采集的多源遥感图像数据集为遥感图像融合提供了数据支持,常用的数据集如表4所示。

表 4 常用数据集参数

Table 4 Parameters of commonly-used dataset

数据集名称	图像	波段数	空间分辨率/m
GaoFen-1	PAN	1	2
	MS	4	8
GaoFen-2	PAN	1	1
	MS	4	4
GaoFen-3	PAN	1	1
	MS	4	4
IKONOS	PAN	1	1
	MS	4	4
QuickBird	PAN	1	0.61
	MS	4	2.44
WorldView-2	PAN	1	0.5
	MS	8	2
WorldView-3	PAN	1	0.31
	MS	8	1.24
WorldView-4	PAN	1	0.31
	MS	4	1.24

### 2.2 光谱信息评价指标

在遥感图像融合中,光谱信息评价指标主要针对融合图像的光谱信息保持度、光谱失真度<sup>[65]</sup>。常用的光谱信息评价指标包括结构相似度(structure similarity, SSIM)、均方根误差(root-mean-square error, RMSE)、光谱互信息(mutual information, MI)、光谱角(spectral angel mapper, SAM)、相对整体维数综合误差(relative dimensionless global er-

ror, ERGAS)、光谱失真指数  $D_\lambda$  等。

SSIM 指融合图像  $I_F$  与多光谱图像  $I_M$  之间的相似程度,由亮度分量  $l(I_F, I_M)$ 、对比度分量  $c(I_F, I_M)$ 、结构分量  $s(I_F, I_M)$  3 部分组成,表示为

$$\text{SSIM} = l(I_F, I_M) \cdot c(I_F, I_M) \cdot s(I_F, I_M)。 \quad (1)$$

亮度分量、对比度分量、结构分量计算公式分别如式(2)、式(3)、式(4)所示。

$$l(I_F, I_M) = \frac{2\mu_{I_F}\mu_{I_M} + C_1}{\mu_{I_F}^2 + \mu_{I_M}^2 + C_1}, \quad (2)$$

$$c(I_F, I_M) = \frac{2\sigma_{I_F}\sigma_{I_M} + C_2}{\sigma_{I_F}^2 + \sigma_{I_M}^2 + C_2}, \quad (3)$$

$$s(I_F, I_M) = \frac{\sigma_{I_F I_M} + C_3}{\sigma_{I_F}\sigma_{I_M} + C_3}。 \quad (4)$$

式中,  $\mu_{I_F}$  和  $\mu_{I_M}$  分别为融合图像与多光谱图像的均值,  $\sigma_{I_F}$  和  $\sigma_{I_M}$  分别为融合图像与多光谱图像的方差,  $\sigma_{I_F I_M}$  为融合图像与多光谱图像的协方差,  $C_1, C_2, C_3$  为 3 个常数。SSIM 的值域介于 0 到 1 之间,值越大表示两幅图像越相似,即融合图像的质量越好。

RMSE 用以计算融合图像与多光谱图像之间的差异,其计算公式如式(5)所示,其中  $H$  和  $W$  分别表示图像的高与宽,  $x$  和  $y$  表示图像中像素的坐标。RMSE 越小,融合图像的质量越好。

$$\text{RMSE} = \sqrt{\frac{\sum_{x=1}^H \sum_{y=1}^W (I_M(x, y) - I_F(x, y))^2}{H \times W}}。 \quad (5)$$

MI 表示融合图像与多光谱图像的互信息,其计算公式如式(6)所示,其中  $p(I_F)$  与  $p(I_M)$  分别表示融合图像与多光谱图像的边缘分布,  $p(I_F, I_M)$  表示融合图像与多光谱图像的联合分布。MI 越大,融合图像与多光谱图像的相似度越高。

$$\text{MI} = \sum_{I_F, I_M} p(I_F, I_M) \log \frac{p(I_F, I_M)}{p(I_F)p(I_M)}。 \quad (6)$$

SAM 主要用以衡量融合图像与多光谱图像之间的光谱扭曲程度,计算公式如式(7)所示,其中  $\langle I_{MS} \cdot I_F \rangle$  表示多光谱图像与融合图像内积,  $\|\cdot\|_2$  表示 2 范数。SAM 越小,表明融合图像的光谱失真越小,融合图像的质量越好。

$$\text{SAM} = \arccos\left(\frac{\langle I_{MS} \cdot I_F \rangle}{\|I_{MS}\|_2 \|I_F\|_2}\right)。 \quad (7)$$

ERGAS 表示融合图像与多光谱图像间的光谱扭曲度,计算公式如式(8)所示,  $K$  表示波段数,  $I_{Fi}$  和  $I_{Mi}$  分别表示融合图像与多光谱图像的第  $i$  个波段。ERGAS 越接近 0,融合图像的质量越好。

$$\text{ERGAS} = 100 \frac{H}{W} \sqrt{\frac{1}{K} \sum_{i=1}^K \left( \frac{\text{RMSE}(I_{Fi}, I_{Mi})}{\mu_{I_{Mi}}} \right)^2} \quad (8)$$

$D_\lambda$  用以计算融合图像的光谱失真程度,如式(9)所示, $D_\lambda$  越小,表明融合图像的光谱失真越小。

$$D_\lambda = \sqrt{\frac{\sum_{x=1}^H \sum_{y=1}^W |Q(I_{MS}^\wedge, I_F^\wedge) - Q(\overline{I_{MS}}, \overline{I_F})|^p}{H \times W}} \quad (9)$$

其中  $I_{MS}^\wedge, I_F^\wedge, \overline{I_{MS}}, \overline{I_F}$  表示多光谱图像与融合图像经不同特征矩阵相乘得到的结果; $Q(\cdot)$  的计算为

$$Q(x, y) = \frac{4\sigma_{xy}\bar{x}\bar{y}}{(\sigma_x^2 + \sigma_y^2)((\bar{x})^2 + (\bar{y})^2)} \quad (10)$$

### 2.3 空间信息评价指标

空间信息评价指标主要针对融合图像的空间细节信息与纹理信息的丰富程度<sup>[65]</sup>。常用的空间信息评价指标包括标准差(standard deviation, STD)、信息熵(information entropy, IE)、图像质量指数(universal image quality index, UIQI)、峰值信噪比(peak signal-to-noise ratio, PSNR)、空间频率(spatial frequency, SF)、空间互信息(spatial mutual information, sMI)。

STD 用来评价图像信息丰富程度,计算公式如式(11)所示,其中  $\mu_{I_F}$  表示融合图像的均值。STD 越大,融合图像的信息越丰富。

$$\text{STD} = \sqrt{\frac{1}{H \times W} \sum_{x=1}^H \sum_{y=1}^W (I_F(x, y) - \mu_{I_F})^2} \quad (11)$$

IE 主要用以衡量融合图像包含信息的丰富程度,计算公式如式(12)所示,其中融合图像的灰度分布为  $p = \{p_0, p_1, \dots, p_i, \dots, p_{L-1}\}$ ,  $p_i$  表示第  $i$  个灰度级的像素个数与总像素个数的比。IE 越大,表明融合图像的信息越丰富,融合图像的质量越好。

$$\text{IE} = - \sum_{i=0}^{L-1} p_i \log_2 p_i \quad (12)$$

UIQI 用以衡量融合图像结构的扭曲程度,如式(13)所示, $\sigma_1$  和  $\sigma_2$  分别表示融合图像与多光谱图像的标准差, $C$  表示协方差, $K$  为常数。UIQI 越大,表明融合图像结构扭曲程度越小,融合图像质量越好。

$$\text{UIQI} = \frac{4\sigma_1\sigma_2C}{(\sigma_1^2 + \sigma_2^2)(C^2 + K)} \quad (13)$$

PSNR 用以评估图像的保真程度,计算公式如式(14)所示,其中 MAX 表示源图像与融合图像间取最大值, MSE 表示源图像与融合图像的均方误

差。PSNR 越大,融合图像的质量越好。

$$\text{PSNR} = 10 \log_{10} \left( \frac{\text{MAX}^2}{\text{MSE}} \right) \quad (14)$$

SF 用以评估图像空间总体活跃程度。SF 由空间行频率 RF、空间列频率 CF 组成,计算公式为

$$\text{SF} = \sqrt{\text{RF}^2 + \text{CF}^2} \quad (15)$$

RF 与 CF 的计算公式分别如式(16)、式(17)所示。SF 越大,图像融合的效果越好。

$$\text{RF} = \sqrt{\frac{1}{H \times W} \sum_{x=1}^H \sum_{y=2}^W [I_F(x, y) - I_F(x, y-1)]^2} \quad (16)$$

$$\text{CF} = \sqrt{\frac{1}{H \times W} \sum_{x=2}^H \sum_{y=1}^W [I_F(x, y) - I_F(x-1, y)]^2} \quad (17)$$

sMI 用以评价融合图像与全色图像的互信息,计算公式如式(18)所示,其中  $I_P$  表示全色图像,  $p(I_F)$  与  $p(I_P)$  分别表示融合图像与全色图像的边缘分布,  $p(I_F, I_P)$  表示融合图像与多光谱图像的联合分布。sMI 越大,融合图像与全色图像的相似度越高。

$$\text{sMI} = \sum_{I_F, I_P} p(I_F, I_P) \log \frac{p(I_F, I_P)}{p(I_F)p(I_P)} \quad (18)$$

## 3 总结与展望

本文针对 MS 与 PAN 遥感图像融合的问题,归纳和总结了近年来提出的基于深度学习的融合方法,包括基于卷积神经网络的融合方法、基于生成对抗网络的融合方法和基于视觉 Transformer 的融合方法。基于卷积神经网络的方法具有强大的局部特征提取能力、较高的计算效率,但往往需要参考图像进行监督学习;基于生成对抗网络的方法在无监督任务中具有更好的表现,但训练过程复杂、不稳定;基于视觉 Transformer 的方法具有强大的全局特征提取能力,但网络模型往往较大、训练过程长。

目前基于深度学习的多光谱和全色遥感图像融合已经取得了许多进展与研究成果,但仍存在一些问题亟待研究者解决,具体如下。

(1) 改进现有的基于深度学习的融合方法。迄今为止的遥感图像融合研究中,基于 CNN 的融合方法展现出了不错的局部特征提取能力;基于 GAN 的融合方法在无监督的融合任务中表现出了较好的融合成果;基于 ViT 的融合方法具有强大的全局特征提取能力。如何进一步深化不同深度学习网络之间的关系并有效结合,以实现不同深度学习网络间

的优势互补,将是未来研究的重要方向之一。

(2) 探索新型网络驱动的多光谱和全色遥感图像融合方法。在计算机视觉领域中,新型网络的诞生为遥感图像融合任务提供了新的机遇,如将扩散模型(diffusion model)与已有的遥感图像融合方法相结合,利用扩散模型的优势处理和解决遥感图像的融合问题,在未来的研究中具有较大的研究潜力与价值。

(3) 完善统一的遥感图像融合评价指标体系。遥感图像融合任务往往缺少真实的参考图像。因此,如何采取统一的评估方式,全面、系统地比较不同融合方法之间的性能差异,仍是一个有待解决的问题。

### 参考文献:

- [1] LIU Yu, CHEN Xun, WANG Zengfu, et al. Deep learning for pixel-level image fusion: recent advances and future prospects[J]. *Information Fusion*, 2018, 42: 158-173.
- [2] MA Lei, LIU Yu, ZHANG Xueliang, et al. Deep learning in remote sensing applications: a meta-analysis and review[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 152: 166-177.
- [3] YILMAZ C, YILMAZ V, GUNGORF O. A theoretical and practical survey of image fusion methods for multispectral pansharpening[J]. *Information Fusion*, 2022, 79: 1-43.
- [4] ZHANG Kai, ZHANG Feng, WAN Wenbo, et al. Panchromatic and multispectral image fusion for remote sensing and earth observation: concepts, taxonomy, literature review, evaluation methodologies and challenges ahead [J]. *Information Fusion*, 2023, 93: 227-242.
- [5] DURAN J, BUADES A, COLL B, et al. A survey of pansharpening methods with a new band-decoupled variational model[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 125: 78-105.
- [6] SHAO Zhenfeng, CAI Jiajun. Remote sensing image fusion with deep convolutional neural network[J]. *Applied Earth Observations and Remote Sensing*, 2018, 5(5): 1656-1669.
- [7] MA Jiayi, YU Wei, LIANG Pengwei, et al. Fusion-GAN: a generative adversarial network for infrared and visible image fusion [J]. *Information Fusion*, 2019, 48: 11-26.
- [8] ZHANG Hao, XU Han, TIAN Xin, et al. Image fusion meets deep learning: a survey and perspective[J]. *Information Fusion*, 2021, 76: 323-336.
- [9] KARIM S, TONG Geng, LI Jinyang, et al. Current advances and future perspectives of image fusion: a comprehensive review[J]. *Information Fusion*, 2023, 90: 185-217.
- [10] LUO Shuyue, ZHOU Shangbo, FENG Yong, et al. Pansharpening via unsupervised convolutional neural networks[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 4295-4310.
- [11] SEO S, CHOI J S, LEE J, et al. UPSNet: unsupervised pan-sharpening network with registration learning between panchromatic and multi-spectral images [J]. *IEEE Access*, 2020, 8: 201199-201217.
- [12] GUO Anjing, DIAN Renwei, LI Shutao. Unsupervised blur kernel learning for pansharpening [C]// *IGARSS IEEE International Geoscience and Remote Sensing Symposium*, 2020: 633-636.
- [13] LIU Xiangyu, LIU Qingjie, WANG Yunhong. Remote sensing image fusion based on two-stream fusion network [J]. *Information Fusion*, 2020, 55: 1-15.
- [14] CAI Jiajun, HUANG Bo. Super-resolution-guided progressive pansharpening based on a deep convolutional neural network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 59(6): 5206-5220.
- [15] DONG Meilin, LI Weisheng, LIANG Xuesong, et al. MDCNN: multispectral pansharpening based on a multiscale dilated convolutional neural network[J]. *Journal of Applied Remote Sensing*, 2021, 15(3): 036516.
- [16] XU Shuang, ZHANG Jiangshe, ZHAO Zixiang, et al. Deep gradient projection networks for pan-sharpening [C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2021: 1366-1375.
- [17] WANG Jiaming, SHAO Zhenfeng, HUANG Xiao, et al. Pan-sharpening via high-pass modification convolutional neural network [C]// *IEEE International Conference on Image Processing (ICIP)*, 2021: 1714-1718.
- [18] NI Jiahui, SHAO Zhimin, ZHANG Zhongzhou, et al. LDP-Net: an unsupervised pansharpening network based on learnable degradation processes[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 5468-5479.
- [19] LEE J, SEO S, KIM M. Sipsa-net: shift-invariant pan sharpening with moving object alignment for satellite imagery [C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2021: 10166-10174.
- [20] XU Han, MA Jiayi, SHAO Zhenfeng, et al. SDP-Net: a deep network for pan-sharpening with en-

- hanced information representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 59(5): 4120-4134.
- [21] JIN Zirong, ZHANG Tianjing, JIANG Taixiang, et al. LAGConv: local-context adaptive convolution kernels with global harmonic bias for pansharpening [C]//*Proceedings of the AAAI Conference on Artificial Intelligence*, 2022, 36(1): 1113-1121.
- [22] ZHANG Tianjing, DENG Liangjian, HUANG Tingzhu, et al. A triple-double convolutional neural network for panchromatic sharpening[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022: 9088-9101.
- [23] WANG Peng, HE Zhongchen, ZHANG Ying, et al. Multispectral pansharpening based on multisequence convolutional recurrent neural network [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 9482-9496.
- [24] ZHANG Hao, MA Jiayi. GTP-PNet: a residual learning network based on gradient transformation prior for pansharpening[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 172: 223-239.
- [25] WANG Jiaming, SHAO Zhenfeng, HUANG Xiao, et al. A dual-path fusion network for pan-sharpening [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-14.
- [26] XIANG Zhikang, XIAO Liang, YANG Jingxiang, et al. Detail-injection-model-inspired deep fusion network for pansharpening[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-15.
- [27] LIU Qiang, MENG Xiangchao, SHAO Feng, et al. Supervised-unsupervised combined deep convolutional neural networks for high-fidelity pansharpening[J]. *Information Fusion*, 2023, 89: 292-304.
- [28] PENG Siyuan, ZHU De, GAO Qingwei, et al. PSCF-Net: deeply coupled feedback network for pansharpening[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 1-12.
- [29] FANG Yuan, CAI Yuanzhi, FAN Lei. SDRCNN: a single-scale dense residual connected convolutional neural network for pansharpening[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 6325-6338.
- [30] MA Jiayi, YU Wei, CHEN Chen, et al. Pan-GAN: an unsupervised pan-sharpening method for remote sensing image fusion[J]. *Information Fusion*, 2020, 62: 110-120.
- [31] LIU Qingjie, ZHOU Huanyu, XU Qizhi, et al. PS-GAN: a generative adversarial network for remote sensing image pan-sharpening[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(12): 10227-10242.
- [32] XIE Weiyang, CUI Yuhang, LI Yunsong, et al. HP-GAN: hyperspectral pansharpening using 3-D generative adversarial networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 59(1): 463-477.
- [33] GASTINEAU A, AUJOL J F, BERTHOUMIEU Y, et al. Generative adversarial network for pansharpening with spectral and spatial discriminators [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 4401611.
- [34] OZCELIK F, ALGANCI U, SERTEL E, et al. Rethinking CNN-based pansharpening: guided colorization of panchromatic images via GANs [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 59(4): 3486-3501.
- [35] ZHAO Zixiang, ZHAN Jianshe, XU Shuang, et al. FGF-GAN: a lightweight generative adversarial network for pansharpening via fast guided filter[C]//*IEEE International Conference on Multimedia and Expo (ICME)*, 2021: 1-6.
- [36] LI Jie, SUN Weixuan, JIANG Menghui, et al. Self-supervised pansharpening based on a cycle-consistent generative adversarial network[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 19: 1-5.
- [37] BENZENATI T, KESSENTINI Y, KALLEL A. Pansharpening approach via two-stream detail injection based on relativistic generative adversarial networks[J]. *Expert Systems with Applications*, 2022, 188: 115996.
- [38] WANG Yajie, XIE Yanyan, WU Yanyan, et al. An unsupervised multi-scale generative adversarial network for remote sensing image pan-sharpening[C]//*International Conference on Multimedia Modeling*, 2022: 356-368.
- [39] XING Yinghui, YANG Shuyuan, WANG Song, et al. PC-GANs: progressive compensation generative adversarial networks for pan-sharpening [J]. *arXiv preprint arXiv: 2207.14451*, 2022.
- [40] DIAO Wenxiu, ZHANG Feng, SUN Jiande, et al. ZeRGAN: zero-reference GAN for fusion of multispectral and panchromatic images[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 34: 8195-8209.
- [41] ZHOU Huanyu, LIU Qingjie, WENG Dawei, et al. Unsupervised cycle-consistent generative adversarial networks for Pan sharpening[J]. *IEEE Transactions*

- on Geoscience and Remote Sensing, 2022, 60: 1-14.
- [42] XU Qizhi, LI Yuan, NIE Jinyan, et al. UPanGAN: unsupervised pansharpening based on the spectral and spatial loss constrained generative adversarial network [J]. Information Fusion, 2023, 91: 31-46.
- [43] HUANG Bo, LI Xiongfei, ZHANG Xiaoli. Triple-loss driven generative adversarial network for pansharpening [J]. IET Image Processing, 2024, 18(1): 211-232.
- [44] WU Yuanyuan, LI Yuchun, FENG Siling, et al. Pansharpening using unsupervised generative adversarial networks with recursive mixed-scale feature fusion [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16: 3742-3759.
- [45] MENG Lingyu, LIU Mingliang, LI Xiaokun. Multi-scale detail injection-based improved generative adversarial networks for pansharpening [J]. International Journal of Remote Sensing, 2023, 44(1): 248-275.
- [46] CESUR N N, ÖZDOĞAN K, ERER I. ICPGAN: intensity component guided pansharpening using generative adversarial network with dual discriminators [C]//31st Telecommunications Forum (TELFOR), 2023: 1-4.
- [47] LIU Xiaobo, LIU Xiang, DAI Haoran, et al. MunGAN: a multi-scale unsupervised network for remote sensing image pansharpening [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-18.
- [48] MENG Xiangchao, WANG Nan, SHAO Feng, et al. Vision transformer for pansharpening [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-11.
- [49] HOU Lu, ZHANG Bo, WANG Bin. PAN-guided multiresolution fusion network using swin transformer for pansharpening [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 20: 1-5.
- [50] YIN Junru, QU Jiantao, SUN Le, et al. A local and nonlocal feature interaction network for pansharpening [J]. Remote Sensing, 2022, 14(15): 3743.
- [51] ZHANG Kai, LI Zhoulin, ZHANG Feng, et al. Pansharpening based on transformer with redundancy reduction [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [52] LI Sijia, GUO Qing, LI An. Pan-sharpening based on CNN + pyramid transformer by using no-reference loss [J]. Remote Sensing, 2022, 14(3): 624.
- [53] ZHANG Feng, ZHANG Kai, SUN Jiande. Multiscale spatial-spectral interaction transformer for pan-sharpening [J]. Remote Sensing, 2022, 14(7): 1736.
- [54] HUANG Wei, JU Ming, ZHAO Zhuobing, et al. Local-global based high-resolution spatial-spectral representation network for pansharpening [J]. Remote Sensing, 2022, 14(15): 3556.
- [55] LIANG Yixun, ZHANG Ping, MEI Yang, et al. PMACNet: parallel multiscale attention constraint network for pan-sharpening [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [56] SU Zhao, YANG Yong, HUANG Shuying, et al. STCP: synergistic transformer and convolutional neural network for pansharpening [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-15.
- [57] QUAN Wuzhou, GUO Wen. DTEMPan: dual texture-edge maintaining transformer for pansharpening [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-16.
- [58] LI Zixu, LI Jinjiang, REN Lu, et al. Transformer-based dual-branch multiscale fusion network for pansharpening remote sensing images [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 17: 614-632.
- [59] ZHANG Feng, ZHANG Kai, SUN Jiande, et al. DRFormer: learning disentangled representation for pan-sharpening via mutual information-based transformer [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 62: 1-15.
- [60] WANG Quanli, JIN Xin, JIANG Qian, et al. DBCT-Net: a dual branch hybrid CNN-transformer network for remote sensing image fusion [J]. Expert Systems with Applications, 2023: 120829.
- [61] SU Zhao, YANG Yong, HUANG Shuying, et al. CTCP: cross transformer and CNN for pansharpening [C]//Proceedings of the 31st ACM International Conference on Multimedia, 2023: 3003-3011.
- [62] 范文盛, 刘帆, 李明. 基于双分支 U 形 Transformer 的遥感图像融合 [J]. 光子学报, 2023, 52(4): 179-193.
- [63] 李紫桐, 赵健康, 徐静冉, 等. 基于改进 Swin transformer 的遥感图像融合方法 [J]. 光子学报, 2023 (11): 255-269.
- [64] 胡建文, 汪泽平, 胡佩. 基于深度学习的空谱遥感图像融合综述 [J]. 自然资源遥感, 2023, 35(1): 1-14.
- [65] 张应刚, 余先川, 张林, 等. 多源遥感影像融合质量性能评估研究 [J]. 制造业自动化, 2019, 41(7): 139-147.