



计算机科学

COMPUTER SCIENCE

结合多尺度卷积块与密集卷积块的遥感图像融合

侯林昊, 刘帆

引用本文

侯林昊, 刘帆. [结合多尺度卷积块与密集卷积块的遥感图像融合](#) [J]. 计算机科学, 2024, 51(6A): 230400110-6.

HOU Linhao, LIU Fan. [Remote Sensing Image Fusion Combining Multi-scale Convolution Blocks and Dense Convolution Blocks](#) [J]. Computer Science, 2024, 51(6A): 230400110-6.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[面向产线AI质检的少样本评测方法研究和验证](#)

Study and Verification on Few-shot Evaluation Methods for AI-based Quality Inspection in Production Lines

计算机科学, 2024, 51(6A): 230700086-8. <https://doi.org/10.11896/jsjcx.230700086>

[基于BERT和CNN的药物不良反应个案报道文献分类方法](#)

Literature Classification of Individual Reports of Adverse Drug Reactions Based on BERT and CNN

计算机科学, 2024, 51(6A): 230400049-6. <https://doi.org/10.11896/jsjcx.230400049>

[DUWe:动态未知词嵌入方法在Web异常检测中的应用](#)

DUWe:Dynamic Unknown Word Embedding Approach for Web Anomaly Detection

计算机科学, 2024, 51(6A): 230300191-5. <https://doi.org/10.11896/jsjcx.230300191>

[WiCare:一种非接触式的老人如厕跌倒监测模型](#)

WiCare:Non-contact Fall Monitoring Model for Elderly in Toilet

计算机科学, 2024, 51(6A): 230700044-8. <https://doi.org/10.11896/jsjcx.230700044>

[深度学习驱动下IaaS云运维异常检测算法的研究进展](#)

Research Progress of Anomaly Detection in IaaS Cloud Operation Driven by Deep Learning

计算机科学, 2024, 51(6A): 230400016-8. <https://doi.org/10.11896/jsjcx.230400016>

结合多尺度卷积块与密集卷积块的遥感图像融合

侯林昊 刘帆

太原理工大学大数据学院 山西 晋中 030600

(451704938@qq.com)

摘要 遥感图像融合的目的是获得与多光谱图像相同光谱分辨率和与全色图像相同空间分辨率的高分辨率多光谱图像。尽管深度学习在遥感图像融合方面取得了显著的成果,但由于深度模型网络的限制,网络无法充分提取图像中丰富的空间信息,导致融合图像空间信息缺失,融合结果质量低。因此引入了多尺度块,不同尺度的图像特征可以通过不同大小的卷积核学习,从而增加提取特征的丰富性。随后引入了密集卷积块,通过密集连接来达到特征重用的目的,在网络较深时减少了浅层特征信息的丢失。在特征融合阶段,所提方法将网络不同层次的特征图作为特征融合层的输入,提高融合图像的质量。在 GE1 数据集以及 QB 数据集上与 6 种融合算法进行对比实验,实验结果表明所提方法的融合图像更好地保留了空间信息与光谱信息,在主观和客观评价上均优于对比方法。

关键词: 遥感图像融合;深度学习;多光谱图像;多尺度卷积块;密集连接

中图分类号 TP391

Remote Sensing Image Fusion Combining Multi-scale Convolution Blocks and Dense Convolution Blocks

HOU Linhao and LIU Fan

College of Data Science, Taiyuan University of Technology, Jinzhong, Shanxi 030600, China

Abstract The aim of remote sensing image fusion is to obtain high-resolution multispectral images with the same spectral resolution as multispectral images and the same spatial resolution as panchromatic images. Although deep learning has achieved remarkable results in remote sensing image fusion, the network cannot fully extract the rich spatial information in the image due to the limitation of the deep model network, which leads to the lack of spatial information in the fused image and low quality of the fusion result. Therefore, this paper introduces multi-scale blocks, where image features at different scales can be learned by convolutional kernels of different sizes, thus increasing the richness of the extracted features. Dense convolutional blocks are then introduced to achieve feature reuse through dense connections, reducing the loss of shallow feature information when the network is deep. In the feature fusion stage, the proposed method uses feature maps from different levels of the network as input to the feature fusion layer to improve the quality of the fused images. Comparison experiments are performed with six fusion algorithms on GE1 and QB datasets, and the experimental results show that the fused images of the proposed method retain spatial and spectral information better, and outperform the comparison methods in both subjective and objective evaluations.

Keywords Remote sensing image fusion, Deep learning, Multispectral images, Multiscale convolution block, Dense connection

遥感图像被广泛应用于语义分割、植被分类和道路提取等方面。但受到卫星传感器物理特性的限制,卫星可以获得高空间分辨率但低光谱分辨率的全色(Panchromatic, PAN)图像以及低空间分辨率但高光谱分辨率的多光谱(Multispectral, MS)图像。泛锐化技术旨在融合 MS 图像和 PAN 图像,来获得高空间和光谱分辨率的遥感图像。目前主要的遥感图像融合方法有 3 种^[1],分别是基于组件替换(Component Substitution, CS)的方法、基于多分辨率分析(Multiresolution Analysis, MRA)的方法、基于模型的方法。基于 CS 的方法首先使用光谱变换将 MS 波段投影到一个新的空间,并用高分辨率 PAN 图像替换代表空间信息的一个组件。CS 方法的核心思想是首先依靠转换将 MS 图像投影到另一个空间,以分离空间结构和光谱信息,将空间结构替换为 PAN 图像,最后通过逆变换操作完成平移锐化任务。诸如强度-色调-饱和度

(Intensity-Hue-Saturation, IHS)^[2]、主成分分析(Principal Component Analysis, PCA)^[3]、Gram-Schmidt(GS)^[4]和部分替代(Partial Replacement Adaptive Component Substitution, PRACS)^[5]等方法都采用了这一概念。这些方法在 PAN 图像和 MS 图像高度相关时取得了良好的效果,但由于 PAN 图像和 MS 图像之间的光谱不匹配导致的局部差异,融合结果中存在明显的光谱失真。在 MRA 方法中,使用 3 个主要步骤来融合图像。第一步是使用金字塔变换和小波变换等方法对源图像进行处理,并将其划分为多个尺度。第二步对源图像的每个尺度进行融合,最后通过逆变换操作生成融合结果。基于 MRA 的代表性方法包括小波变换(Wavelets Transform, WT)^[6]、离散小波变换(Discrete Wavelets Transform, DWT)^[7],以及结合多元经验模态分解和加权最小二乘滤波器的遥感图像融合^[8]等。与基于 CS 的方法相比,基于 MRA

通信作者:刘帆(Liufan@tyut.edu.cn)

的方法能够更好地保留光谱信息,但是可能导致空间信息缺失,从而导致融合图像的可视化效果差。基于模型的方法近年来在计算机视觉方面取得了显著的成果,例如基于全变分(Total Variation, TV)的融合算法,通过引入 TV 正则化项来约束模型的优化,提升融合结果的空间细节。这类方法通过迭代优化而获得较好的泛化性能,但存在优化耗时较长和效率低的问题。此外,基于深度学习的方法凭借其强大的特征提取能力和非线性能力,也应用到了遥感图像融合领域,如基于卷积神经网络的遥感图像融合(CNN-based Pansharpening, PNN)^[9]、多尺度多深度卷积神经网络(Multiscale and Multidepth Convolutional Neural Network, MSDCNN)^[10]、基于卷积神经网络的遥感图像融合(CNN-based Remote Sensing Image Fusion, RSIFNN)^[11],以及结合卷积注意模块与卷积自编码器的细节注入遥感图像融合^[12]等。由于遥感图像包含复杂的特征,上述遥感图像融合方法无法在保持光谱质量的同时充分提取空间特征,导致融合结果质量低。

为了解决上述问题,本文提出了结合多尺度块、密集连接块以及全局特征融合层的卷积神经网络,并将其命名为 MultiScale Dense Net(MSDNet)。多尺度块具有不同的感受野,可以更好地从原始图像中提取空间信息。同时,密集连接块通过密集连接,可以将每一层卷积的输出都作为后层卷积的输入,做到了特征重用,减少了融合过程中细节的丢失。随后,全局特征融合层可以同时融合浅层特征以及各个密集连接块所产生的局部特征,增强了网络的学习能力,从而提高融合图像的质量。

1 基于深度学习的遥感图像融合

基于深度学习的泛锐化方法假定原始图像和理想的融合高分辨率 MS 图像之间的关系是复杂和非线性的。然后利用具有显著的非线性表征能力的神经网络来学习理想的融合图像和观察结果之间的网络。所有的参数都是在大规模训练样本的监督下自动学习的。典型的基于深度学习的遥感图像融合方法的示意图见图 1。

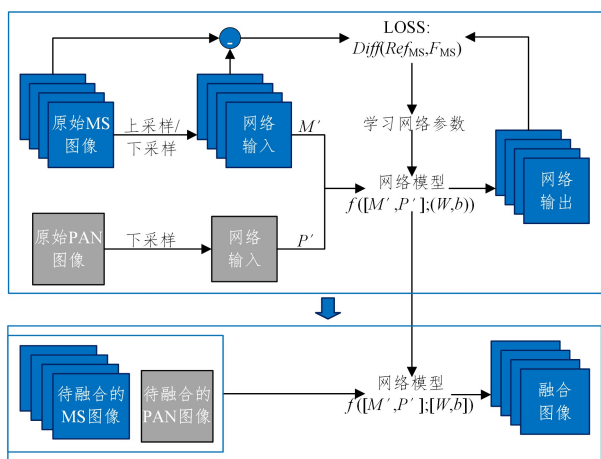


图 1 基于深度学习遥感图像融合的流程

Fig. 1 Flowchart of remote sensing image fusion based on deep learning

如图 1 所示,典型的基于深度学习的泛锐化方法一般包

括两步处理:1)网络训练;2)基于预训练的网络获得融合后的图像。其中,网络训练相对更重要,它的作用是学习从观测值到理想的融合高分辨率 MS 图像的转换关系。应该指出的是,实际的理想高分辨率 MS 图像一般不存在。因此,训练样本通常是根据 Wald 协议获得的,即原始 MS 和 Pan 图像通过高分辨率 Pan 图像和 low 分辨率 MS 图像之间的空间分辨率差进行空间退化,然后将原始 MS 图像视为要得到的高分辨率 MS 图像。在网络训练中,卷积神经网络的所有卷积层的参数 $\{W, b\}$ 从训练样本中学习。这可以通过最小化损失函数 $Diff(Ref_{MS}, F_{MS})$ 实现,该函数是基于网络的输出 F_{MS} 和目标标签图像 Ref_{MS} 之间的差异构建的。

2 结合多尺度卷积块和密集卷积块的遥感图像融合算法

2.1 基于多尺度卷积块和密集卷积块的遥感图像融合算法流程

图 2 为本章所提出的遥感图像融合网络的算法流程。对于 PNN 和 MSDCNN 等网络,网络的输入是由经过预处理的 MS 图像与 PAN 图像进行拼接操作得到的。这样的操作会导致无法充分地提取 MS 图像中的光谱信息以及 PAN 图像的空间信息。为了充分地提取输入图像中的信息,本文采用双分支结构,具体步骤如下。

1)输入图像预处理:根据 Wald 协议,将原始多光谱图像和全色图像进行空间降级作为本章遥感图像融合算法的训练集,空间降级后的多光谱图像通过二次立方插值上采样到全色图像的分辨率,将其与空间降级后的全色图像作为网络的输入。因此,原始多光谱图像可以作为网络训练的标签。

2)输入的 PAN 图像首先通过第一个层卷积层的处理,输出的特征再经过多尺度块处理,从而得到包含更加丰富的空间信息的特征。输入的 MS 图像用两次卷积核大小为 3×3 的卷积层进行特征提取,获得多光谱图像的特征。

3)将多尺度块输出的全色图像的特征以及两次卷积后输出的多光谱图像的特征拼接,作为后续网络的输入。拼接得到的特征作为 DB1 模块的输入。后续网络中的 DB1, DB2, DB3 是 3 个密集连接块,采用密集连接思想,每一个卷积层的卷积核大小为 3×3 。密集连接块通过层与层之间的密集连接,在特征重用的同时避免特征信息的丢失。

4)密集连接块 DB3 的输出将作为特征融合层的输入,特征融合层是一个卷积核大小为 1×1 的卷积层。为了利用到网络处理过程中的浅层特征和深层语义特征,将第 3)步中通过拼接操作得到的特征以及 DB1, DB2, DB3 这 3 个密集连接块的输出作为特征融合层的输入。特征融合层可以自适应地从这些输入特征中学习有用的信息。

5)特征融合层的输出特征经过最后一层卷积核大小为 3×3 的卷积层处理,将特征融合层输出的特征图的通道维数降低到原始多光谱图像的通道数。生成的空间细节注入到上采样后的多光谱图像中,得到空间细节丰富的融合图像。

6)训练网络使用融合图像与参考图像之间的均方误差作为损失函数,使用 Adam 优化器,通过反向传播算法对模型参数进行优化。本章算法训练周期设置为 100,批量块的大小为 16,优化器的学习率设置为 0.0002。

设最终输出的高质量融合图像为 F_{MS} , 训练的标志即原始 MS 图像为 f_{MS} , 其中 F_{MS}^i 是高质量融合图像的第 i 个通道, f_{MS}^i 是原始 MS 图像的第 i 个通道。本文用均方误差作为网络的损失函数, 计算公式如下:

$$Loss = \frac{1}{n} \sum_{i=1}^n \| F_{MS}^i - f_{MS}^i \|^2 \quad (1)$$

接下来具体介绍本章算法中使用的多尺度块、密集连接块以及跳跃连接。

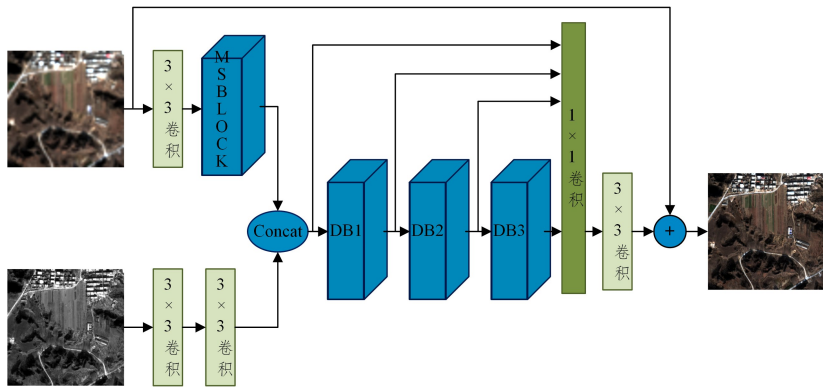


图2 算法流程

Fig. 2 Method flowchart

2.2 多尺度卷积块

粗糙结构和纹理细节是需要从地面物体和场景中提取的特征。在具有米级或亚米级空间分辨率的遥感影像中, 地面物体的尺寸从非常小的邻域到包含数千像素的大区域不等, 而一个地面场景可能涵盖许多具有不同尺寸的物体。如果仅仅使用尺寸单一的卷积核进行处理, 则会导致提取的特征比较单一。为了充分利用高分辨率全色图像中丰富的空间信息, 提高对各种复杂地面场景特征提取的鲁棒性, 我们引入了多尺度卷积层块, 通过使用不同大小的卷积核对特征图进行处理, 随后对处理的结果进行拼接操作, 可以提取到更加丰富的特征, 从而提高融合结果。图3给出了多尺度卷积块的结构。




图3 多尺度卷积块

Fig. 3 Multiscale convolution block

输入数据 S 与不同大小的核进行卷积, 其可以通过以下公式表示:

$$map_{i,j} = f\left(\sum_m \sum_{h=0}^{K_i-1} \sum_{w=0}^{K_i-1} W_{i,j,m}^{h,w} S_m^{(x+h),(y+w)} + b_{i,j}\right) \quad (2)$$

其中, i 表示平行层的序号, j 为该层中特征图的通道数, $S_m^{x,y}$ 代表输入数据 S 在 m 通道上 (x, y) 位置的值, b 是偏置, $f(\cdot)$ 是激活函数, 选择 ReLU 作为激活函数。 $W_{i,j,m}^{h,w}$ 是卷积核在位置 (h, w) 的值, 该卷积核连接到第 j 个特征图, K_i 是核的大小, 本文中 $K_{i=1,2,3} = 3, 5, 7$ 。多尺度块的输出为 $f_e(S)$, $f_e(S)$ 是由每个卷积层的输出拼接而成, N 代表每一层卷积核的个数:

$$f_e(S) = [\{map_{1,j}\}_{j=1}^N, \dots, \{map_{3,j}\}_{j=1}^N] \quad (3)$$

2.3 密集连接模块

2017年, Huang等提出了密集连接网络^[13]。密集连接在超分辨率等领域取得了显著的效果^[14-15], 因此本文引入密集连接块。在密集连接块中, 每一层之前的层所产生的特征图都会作为本层的输入, 同时每一层的输出也会作为后续层

的输入。与残差连接不同, 残差连接是将特征图进行求和操作, 而密集连接是在维度上将各个特征图进行拼接操作。密集连接在改善信息和梯度流的同时, 还能够有效保留和重复利用特征。

设第 l 层的输出为 x_l , 则可以以下述公式来表示密集连接的思想:

$$x_l = RELU(\omega_l * [x_0, x_1, x_2, \dots, x_{l-1}] + b_l) \quad (4)$$

其中, ReLU 为本文所使用的非线性激活函数, ω_l 为第 l 个卷积层的权重, b_l 为其偏置, $[x_0, x_1, x_2, \dots, x_{l-1}]$ 是包含输入在内以及所有卷积层输出特征图的拼接。假设密集连接模块一共有 n 层, 则该密集连接模块最后一层的输出 x_n 也可以表示为:

$$x_n = \omega_n * x_{n-1} + b_n \quad (5)$$

如图4所示, 本章遥感图像融合算法中所使用的密集连接模块中有 $n=3$ 个卷积层, 卷积核的大小为 3×3 。




图4 密集连接

Fig. 4 Dense connection

3 实验结果与分析

3.1 数据集与实验设置

本文所采用的数据集为 QuickBird(QB)数据集与 GeoEye-1(GE1)数据集, 数据集中包含了多种场景, 如城市地区、乡村地区和沿海地区等。其中, GE1 卫星的 MS 图像和 PAN 图像的空间分辨率分别为 1.84 m 和 0.46 m, 而 QB 卫星的 MS 图像和 PAN 图像的空间分辨率分别为 2.44 m 和 0.61 m。两个数据集图像均被切割为 64×64 的 MS 图像块和 256×256 的 PAN 图像块。其中, GE1 数据集包含 6427 对图像块作为训练集, 713 对图像块作为测试集。而 QB 数据集包含 11000 对图像块作为训练集, 940 对图像块作为测试集。

网络模型通过 Pytorch 深度学习框架实现, 模型通过在两块 NVIDIA TESLA P4 GPU 上进行训练, 使用 Adam 作为优化器来优化参数, 批量块大小为 4。在遥感图像融合实验

中,训练模型所需的标签,即高空间分辨率的 MS 图像是不存在的。所以通过 Wald 协议^[16],将原始的 MS 图像作为标签,将原始的 MS 图像先上采样处理再下采样处理得到的 MS 图像作为网络的输入,同时将 PAN 图像经过下采样处理同样也作为网络的输入。需要注意的是,上述上采样及下采样操作使得图像变换的比例是同原始 MS 图像与 PAN 图像的空间分辨率之比是相同的。

3.2 结果分析

为了证明本文基于深度学习模型的有效性和可靠性,选择了一些具有代表性的基于传统方法的算法和基于深度学习的模型进行比较。具体比较方法为波段相关的空间细节 (Band-Dependent Spatial Detail, BDSD)^[17]算法、自适应的 GS (The Adaptive GS, GSA)^[18]算法、调制传递函数-广义拉普拉斯金字塔-高通滤波调制 (Modulation Transfer Function-Generalized Laplacian Pyramid High-Pass Modulation, MTF-GLP-HPM)^[19]算法、PNN 算法、MSDCNN 算法和全深度特征融合网络 (Full-Depth Feature Fusion Network, FDFNet)^[20]算法。上述方法在 QB 数据集以及 GE1 数据集进行模拟数据实验以及真实数据实验,通过主观评价与客观评价指标来对融合图像进行评估。主观评价观察融合图像和参考图像的空间信息以及光谱信息的接近程度;而客观评价采用了以下几个评价指标:光谱角 (Spectral Angle Mapper, SAM),相对全局融合误差 (Erreur Relative Global Adimensionnelle Synthese ERGAS),空间相关系数 (spatial Correlation Coefficient, sCC), Q^{2n} ,无参考质量指标 (Quality with No Reference, HQNR), D_s , D_λ 。

3.3 模拟数据集下与其他方法的比较

在模拟图像实验部分,分别在 QB 数据集以及 GE1 数据集上与其他方法进行了比较。QB 数据集上的融合结果和局部放大图如图 5 所示,对应的评价指标如表 1 所列。




图 5 QB 数据集模拟图像实验融合结果

Fig. 5 Fusion results of simulated images on QB dataset

在图 5(c)–图 5(e)中,传统方法局部放大图中的红色屋顶均存在光谱失真问题。与参考图像 MS 图像相比,红色屋顶的整体颜色提取并不充分。对于图 5(e)而言,建筑物的

边缘信息存在模糊现象,空间信息存在一定的丢失。而对于深度学习方法,图 5(f)是 PNN 算法的结果图,由于 PNN 算法只用到了三层卷积层,提取空间信息和光谱信息的能力有限,所以结果图中光谱信息和空间信息提取并不完善。从图 5(g)中可以看出,MSDCNN 算法在局部放大图中的光谱信息提取并不充分,但其空间信息相比于传统方法有所改善。从图 5(h)可以看出,FDFNet 算法相比于之前的方法,空间信息提取较好,同时光谱失真问题得到了较大的改善。本文提出的方法结果图如图 5(i),在局部放大图中,红色屋顶的光谱信息与参考图像最为接近,同时房屋的边缘信息也有一个较好的效果,所以从主观视觉评价方面而言,本文提出的方法在光谱信息保真度和空间信息的增强方面取得了较好的平衡,图像的整体质量较好。

表 1 为 QB 数据集上的客观评价指标。在客观评价方面,基于深度学习方法客观评价指标结果均优于参与比较的传统方法,而本文的客观评价指标相比于其他基于深度学习的方法得到了进一步的提升,说明本文提出的算法保留了更多的空间信息和光谱信息。

表 1 模拟 QB 数据融合结果评估

Table 1 Simulation of QB data fusion results evaluation

方法	SAM	EGRAS	sCC	Q^{2n}
BDSD	2.1909	1.2424	0.9509	0.9205
GSA	2.2808	1.2930	0.9266	0.9148
MTF-GLP-HPM	2.2520	1.8924	0.9336	0.8737
PNN	1.5626	1.3017	0.9791	0.9669
MSDCNN	1.2241	1.0132	0.9857	0.9768
FDFNet	1.1054	0.9702	0.9873	0.9806
本文方法	0.9307	0.8073	0.9916	0.9866
理想值	0	0	1	1

图 6 为 GE1 数据集上的模拟实验融合结果和局部放大图,对应的评价指标如表 2 所列。




图 6 GE1 数据集模拟图像实验融合结果

Fig. 6 Fusion results of simulated images on GE1 dataset

从图 6(c)–图 6(e)中可以看出,传统方法通过牺牲光谱信息来改善纹理细节信息。图 6(f)为 PNN 算法,由于 PNN 网络的网络深度较浅,建筑物边缘存在模糊,光谱失真问题较传统方法有所改善。MSDCNN 相比于 PNN,空间信

息的提取能力得到了提高。对于 FDFNet 算法与本文提出的算法,融合结果较原始 MS 图像而言,光谱信息与空间信息均取得了较好的结果,与原始 MS 图像相似。表 2 是 GE1 数据集上模拟实验下的指标。传统方法融合结果的 SAM 值均大于深度学习方法,这表明传统方法对光谱信息的提取不完整。在主观视觉上,FDFNet 算法与本文方法接近,但是通过表 2 可以看出,本文的方法在各项指标上均取得了最优的结果。

表 2 模拟 GE1 数据融合结果评估

Table 2 Simulation of GE1 data fusion results evaluation

方法	SAM	EGRAS	SCC	Q^{2n}
BDSB	8.1265	6.2186	0.9037	0.8763
GSA	7.9911	6.3059	0.8979	0.8685
MTF-GLP-HPM	7.1813	5.8147	0.9241	0.8864
PNN	6.4713	4.7745	0.9641	0.9318
MSDCNN	6.1305	4.5826	0.9689	0.9359
FDFNet	5.9157	4.5565	0.9703	0.9380
本文方法	5.8412	4.4884	0.9716	0.9397
理想值	0	0	1	1

3.4 真实数据集下与其他方法的比较

在真实图像实验部分, QB 数据集和 GE1 数据集对应的主观视觉图分别如图 7 和图 8 所示,客观评价指标分别如表 3 与表 4 所列。从图 7 的 QB 数据集真实实验视觉图可以看到,传统方法均改善了空间信息,但光谱信息均有一定程度的丢失,如图 7(c)一图 7(e)中的建筑物颜色。对于深度学习的方法,PNN,MSDCNN 和 FDFNet 方法在增强空间信息的同时也改善了光谱信息。而本文提出的方法在光谱信息和空间信息方面均有较大的提升,所以从主观视觉效果看,本文提出的方法在 QB 数据集上有较好的表现。




图 7 QB 数据集真实图像实验融合结果

Fig. 7 Fusion results of real images on QB dataset

表 3 为 QB 数据集真实实验的融合结果评估。可以看出本文方法的前两个指标均取得了最优的结果;而 D_s 指标方面,FDFNet 方法取得了最优的结果,本文的方法与 MSDCNN 十分接近。但是结合主观视觉图而言,本文的方法在改善空间信息的同时,光谱信息与 MS 图像最为接近。所以对于 QB 数据集,本文提出的方法综合主观评价与客观评价,取得了较好效果。

表 3 真实 QB 数据融合结果评估

Table 3 Evaluation of real QB data fusion results

方法	QNR	D_λ	D_s
BDSB	0.9290	0.0539	0.0181
GSA	0.9062	0.0604	0.0355
MTF-GLP-HPM	0.9453	0.0327	0.0228
PNN	0.9493	0.0313	0.0200
MSDCNN	0.9568	0.0285	0.0152
FDFNet	0.9599	0.0264	0.0141
本文方法	0.9601	0.0250	0.0153
理想值	1	0	0

GE1 数据集真实实验的融合结果如图 8 所示。从图 8(c)一图 8(e)的局部放大图可以看出,BDSB 方法、GSA 方法以及 MTF 方法均存在一定程度的光谱失真现象,房屋屋顶的颜色均与原始 MS 图像有较大的差异;同时图像中包含绿色植被的区域也存在光谱信息的丢失。与传统方法相比,深度学习方法在增强空间细节的同时,更好地保留了光谱信息。而与 PNN 方法、MSDCNN 方法以及 FDFNet 方法相比,本文方法在光谱高保真的同时,空间信息得到了较好的提升。所以从视觉效果上看,本文方法在 GE1 数据集上表现突出。

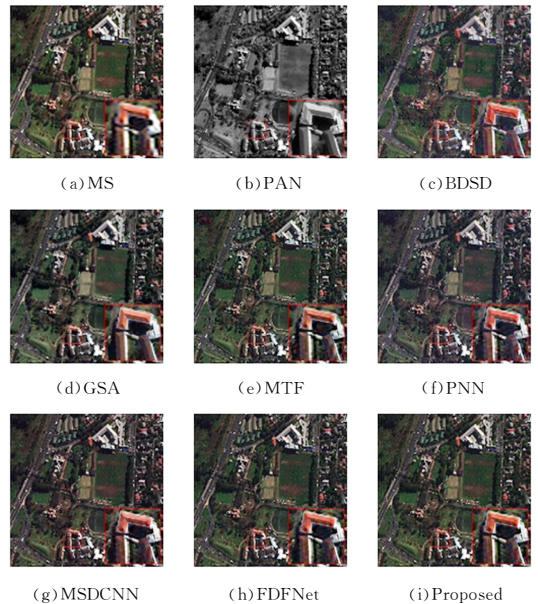


图 8 GE1 数据集真实图像实验融合结果

Fig. 8 Fusion results of real images on GE1 dataset

表 4 为 GE1 数据集上真实实验的评价指标。可以看出,传统方法的 D_s 均高于深度学习方法,对应了图 8 中传统方法存在不同程度的光谱失真现象。对于深度学习方法,光谱失真和空间失真均得到了改善,图片质量得到了提高。而本文方法在 3 个指标中均得到了最优的结果,所以对于 GE1 数据集而言,综合主观评价与客观评价,本文方法效果最优。

表 4 真实 GE1 数据融合结果评估

Table 4 Evaluation of real GE1 data fusion results

方法	QNR	D_λ	D_s
BDSB	0.7361	0.2463	0.0234
GSA	0.7148	0.1678	0.1411
MTF-GLP-HPM	0.8034	0.1092	0.0981
PNN	0.8441	0.1312	0.0285
MSDCNN	0.8786	0.0929	0.0314
FDFNet	0.9198	0.0567	0.0250
本文方法	0.9255	0.0562	0.0194
理想值	1	0	0

结束语 本文方法使用了多尺度卷积块、密集连接卷积块以及将网络各层次特征作为输入的特征融合层的方法,通过多尺度卷积块对特征图进行处理得到对应尺度的特征,通过多个密集连接块对特征进行重复利用的同时,也减少了特征从浅层到深层传递过程中信息的丢失,为融合结果提供了更加丰富的信息。在特征融合层,浅层特征和深层特征均作为特征融合层的输入,提高了融合图像的质量。本文方法在GE1数据集和QB数据集的主观评价和客观评价上均取得了良好的结果,融合图像的质量有所提高。但是本文方法未考虑不同特征之间的差异性,认为每个特征对于融合网络的贡献程度都相同,因此缺乏对融合过程中冗余信息的抑制。将来可以通过引入注意力机制来抑制融合过程的冗余信息。

参考文献

- [1] VIVONE G, DALLA MURA M, GARZELLI A, et al. A new benchmark based on recent advances in multispectral pansharpening: Revisiting pansharpening with classical and emerging pansharpening methods[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2020, 9(1): 53-81.
- [2] LEUNG Y, LIU J, ZHANG J. An Improved Adaptive Intensity-Hue-Saturation Method for the Fusion of Remote Sensing Images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(5): 985-989.
- [3] SHAH V P, YOUNAN N H, KING R L. An Efficient Pan-Sharpener Method via a Combined Adaptive PCA Approach and Contourlets[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(5): 1323-1335.
- [4] LABEN C A, BROWER B V. Process for Enhancing the Spatial Resolution of Multispectral Imagery Using Pan-Sharpener; US Patent 6,011,875,4[P]. 2000-01.
- [5] CHOI J, YU K, KIM Y. A new adaptive component-substitution-based satellite image fusion by using partial replacement [J]. *IEEE Transaction on Geoscience and Remote Sensing*, 2011, 49(1): 295-309.
- [6] KIM Y, LEE C, HAN D, et al. Improved Additive-Wavelet Image Fusion[C]// *IEEE Geoscience and Remote Sensing Letters*. 2011: 263-267.
- [7] LI S T, KWOK JAMES T, WANG Y. Using the discrete wavelet frame transform to merge Landsat TM and SPOT panchromatic images[J]. *Information Fusion*, 2002, 3(1): 17-23.
- [8] ZHANG J, CHEN H T, LIU F. Remote Sensing Image Fusion Based on Multivariate Empirical Mode Decomposition and Weighted Least Squares Filter[J]. *Acta Photonica Sinica*, 2019, 48(5): 510003.
- [9] MASI G, COZZOLINO D, VERDOLIVA L, et al. Pansharpening by convolutional neural networks [J]. *Remote Sensing*, 2016, 8(7): 594.
- [10] YUAN Q, WEI Y, MENG X, et al. A Multiscale and Multidepth Convolutional Neural Network for Remote Sensing Imagery Pan-Sharpener[C]// *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2018: 978-989.
- [11] SHAO Z, CAI J. Remote Sensing Image Fusion With DeepConvolutional Neural Network[C]// *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2018: 1656-1669.
- [12] LI M, LIU F, LI J Z. Combining Convolutional Attention Module and Convolutional Auto-encoder for Detail Injection Remote Sensing Image Fusion[J]. *Acta Photonica Sinica*, 2022, 51(6): 0610005.
- [13] LI J, FANG F, LI J, et al. MDCN: Multi-Scale Dense Cross Network for Image Super-Resolution[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, 31(7): 2547-2561.
- [14] CHANG C Y, CHIEN S Y. Multi-scale Dense Network for Single-image Super-resolution[C]// *2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2019)*. IEEE, 2019.
- [15] WALD L, RANCIAN T, MANGOLINI M. Fusion of satellite images of different spatial resolutions: Assessing the quality of resulting images[J]. *Photogrammetric Engineering and Remote Sensing*, 1997, 63: 691-699.
- [16] GARZELLI A, ENCINI F, CAPOBIANCO L. Optimal MMSE Pan Sharpener of Very High Resolution Multispectral Images [C]// *IEEE Transactions on Geoscience and Remote Sensing*. 2008: 228-236.
- [17] AIAZZI B, BARONTI S, SELVA M. Improving component substitution pansharpening through multivariate regression of MS+Pan data [J]. *IEEE Trans. Geosci. Remote Sens.*, 2007, 45(10): 3230-3239.
- [18] VIVONE G, RESTAINO R, DALLA MURA M, et al. Contrast and error-based fusion schemes for multispectral image pansharpening[J]. *IEEE Geoscience and Remote Sensing Letters*, 2013, 11(5): 930-934. -
- [19] JIN Z, ZHUO Y, ZHANG T, et al. Remote Sensing Pansharpening by Full-Depth Feature Fusion [J]. *Remote Sensing*, 2022, 14(3).



HOU Linhao, born in 1996, postgraduate. His main research interests include remote sensing image fusion and deep learning.



LIU Fan, born in 1982, Ph.D., professor, is a member of CCF(No. 49460M). Her main research interests include machine learning and remote sensing image fusion.