

# 基于卷积神经网络的多光谱与全色遥感图像融合算法

韩文军<sup>1</sup>, 孙小虎<sup>1</sup>, 吉根林<sup>2</sup>, 苏晓云<sup>3</sup>, 谢 非<sup>3</sup>, 吴 冰<sup>4</sup>, 陈 红<sup>5</sup>

(1. 国家电网经济技术研究院有限公司, 北京 102209)

(2. 南京师范大学计算机与电子信息学院, 江苏 南京 210023)

(3. 南京师范大学南瑞电气与自动化学院, 江苏 南京 210023)

(4. 浙江省电力有限公司经济技术研究院, 浙江 杭州 310000)

(5. 江苏省电力有限公司经济技术研究院, 江苏 南京 210008)

**[摘要]** 地理信息数据具有不同分辨率、不同精度、不同覆盖范围等多尺度特征, 在应用中往往需要同时具备高光谱分辨率和高空间分辨率两种信息的图像。为提高多光谱图像和全色图像融合的准确性, 提出了基于卷积神经网络的多光谱与全色遥感图像融合算法。首先, 对训练集内图像进行预处理, 构建适用于本算法的图像数据集; 然后, 拓展卷积神经网络卷积层, 提高三通道关联性, 提取更多图像信息; 最后, 使用深度可分离卷积神经网络, 提高融合图像的精度, 同时也加快了融合速度。在 Downsampled ImageNet 数据集提供的原始图像上对算法融合准确度和速度进行了验证。实验结果表明, 相较于传统卷积神经网络算法, 本文算法均方误差降低 7%, 融合时间减少了 29%, 具有较好的融合效果。

**[关键词]** 卷积神经网络, 多光谱图像, 全色图像, 融合算法

**[中图分类号]** TP751 **[文献标志码]** A **[文章编号]** 1001-4616(2021)03-0123-08

## Multispectral and Panchromatic Remote Sensing Image Fusion Algorithm Based on Convolutional Neural Networks

Han Wenjun<sup>1</sup>, Sun Xiaohu<sup>1</sup>, Ji Genlin<sup>2</sup>, Su Xiaoyun<sup>3</sup>, Xie Fei<sup>3</sup>, Wu Bing<sup>4</sup>, Chen Hong<sup>5</sup>

(1. State Grid Economic and Technology Research Institute Co. Ltd, Beijing 102209, China)

(2. School of Computer and Electronic Information, Nanjing Normal University, Nanjing 210023, China)

(3. School of Electrical and Automation Engineering, Nanjing Normal University, Nanjing 210023, China)

(4. Economic and Technology Research Institute of Zhejiang Electric Power Co. Ltd, Hangzhou 310000, China)

(5. Economic and Technology Research Institute of Jiangsu Electric Power Co. Ltd, Nanjing 210008, China)

**Abstract:** The geographic information data has multi-scale characteristics such as different resolution, different precision and different coverage. In application, it is often necessary to have both high spectral resolution and high spatial resolution images. In order to improve the accuracy of multispectral image and panchromatic image fusion, a fusion algorithm for multispectral and panchromatic remote sensing images based on convolutional neural networks is proposed. Firstly, the images in the training set is preprocessed to construct the image data set suitable for the algorithm. Secondly, the convolution layers of convolutional neural networks are expanded to improve the three channel correlation and extract more image information. Finally, the depth separable convolutional neural networks are used to improve the accuracy of the fusion image, which can also accelerate the fusion speed. The accuracy and speed of the algorithm are verified using the original images provided by downsampled ImageNet dataset. Experimental results show that the mean square error of the proposed algorithm is 7% lower and the fusion time is reduced by 29% compared with the traditional convolutional neural networks method, and obtain a good fusion effect.

**Key words:** convolutional neural networks, multispectral image, panchromatic image, fusion algorithm

收稿日期: 2020-06-11.

基金项目: 国家电网公司科技项目 (5200-201956106A-0-0-00).

通讯作者: 吉根林, 博士, 教授, 博士生导师, 研究方向: 大数据分析 with 挖掘技术. E-mail: glji@njnu.edu.cn; 谢非, 博士, 副教授, 研究方向: 机器视觉与深度学习. E-mail: xiefei@njnu.edu.cn

随着 GIS 的广泛应用,各行业对空间地理数据的需求越来越大. 但由于多种原因,如各行业的需求、场景的复杂性、输入数据集的时间和光谱变换、不同的空间数据标准、特定的数据以及特定的空间对象分类和分类体系等,遥感数据在精度和形式上存在很多差异<sup>[1]</sup>. 如今,在地球以外的各种观测平台上,已经有许多具有不同功能的遥感卫星. 这些卫星可以提供不同的空间、时间和光谱图像,即遥感图像. 由于卫星传感器的局限性,遥感卫星不能同时获得高光谱图像和高空间分辨率图像,只能分别获得高光谱图像和高空间分辨率全色图像. 在实际应用中,既需要高光谱分辨率的遥感图像,又需要高空间分辨率的遥感图像,这使得遥感图像融合具有重要的应用价值<sup>[2-3]</sup>.

近年来,随着科学技术的不断发展,遥感图像融合方法也取得了不断的进步. 图像融合分为像素级、特征级和决策级. 遥感图像融合的基础是像素级融合,且像素融合能产生丰富的图像信息. 基于多尺度变换(multi-scale transformation, MST)和稀疏表示(sparse representation, SR)的图像融合方法是像素级图像融合方法<sup>[4-7]</sup>中最普遍的方法,这种方法需要人工设计图像特征提取器,耗时长,运算效率低;同时,提取的单个图像用于各种复杂的图像环境中,在灰度均匀的区域容易产生误判. Candes E J 和 Donoho D L 在小波理论的基础上提出了 Curvelet 变换理论<sup>[8]</sup>,Curvelet 变换具有任意角度的方向特性,在表达图像边缘特征信息方面效果更加突出,但是其也有较难离散化、冗余度大的问题. Chunha A L 等又提出了一种具有平移不变特性的 Contourlet 变换-非下采样 Contourlet 变换(nonsampled contourlet transform, NSCT),在图像去噪和图像增强领域中得到应用<sup>[9]</sup>. 从目前的研究现状来看,虽然很多机构和学者都在进行遥感图像融合的研究,但传统的融合算法还存在着融合精度不高、速度较慢的缺点.

本文提出一种基于卷积神经网络(convolutional neural networks, CNN)的多光谱和全色图像融合方法,针对传统的融合算法还存在着融合精度不高、速度较慢的问题进行改进. 相对于传统算法,本文的创新点如下:

- (1)利用卷积神经网络对数字电网中的不同比例尺下多尺度的多光谱图像和全色图像进行融合,通过深化卷积层数和使用深度可分离卷积算法,提升了传统算法计算效率,减少程序运行时间,得到同时具备高光谱和高分辨率两种信息的图像.
- (2)采用一种通用简单的变换方法,将全色图像转换为模型融合所需的近似全色图像,然后将近似全色图像和多光谱图像直接输入到融合模型中,得到最终的融合图像,提高了融合的效率.

1 多光谱图像与全色图像特性分析与预处理

多光谱图像用于地物的精确分类,高空间分辨率的全色图像用于地物形状和纹理的描述<sup>[10-11]</sup>. 将多光谱(multispectral, MS)图像和全色(panchromatic, Pan)图像相融合的过程称为多传感器数据融合. 受到训练数据集的限制,需要通过训练集构造近似全色图像代替全色图像和多光谱图像. 该模型中使用的全色图像并不是直接全色图像,而是近似的全色图像代替图像,但这并不影响融合模型性质,即 Pan 和 MS 是通过回归学习融合函数来融合的,图 1 为融合模型流程框图.

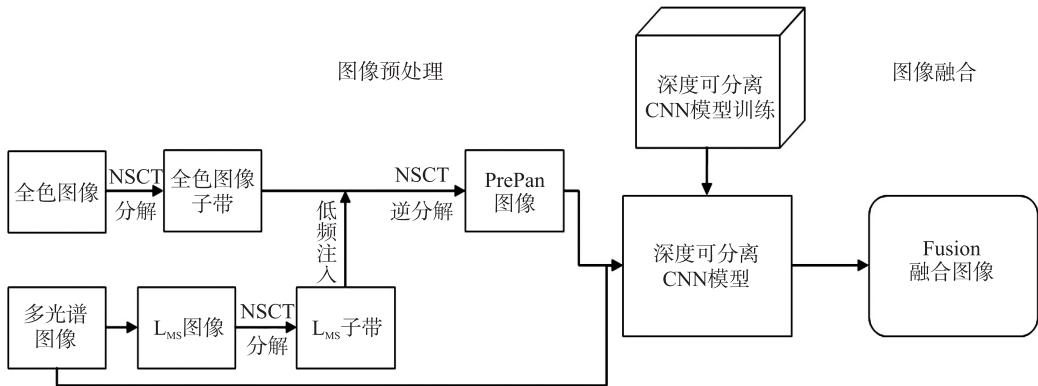


图 1 融合模型流程框图

Fig. 1 The flow chart of fusion model

## 1.1 多光谱图像特性分析与预处理

多光谱是指地面目标辐射中多个单波段的吸收. 多光谱图像又称 MS 图像,如图 2 所示,获得的 MS 图像数据将包含多个波段的光谱信息. 将 RGB 颜色赋予不同的波段将得到彩色图像. 例如,如果 R、G 和 B 分别得到 R、G 和 B 波段的光谱信息,则将合成模拟的真彩色图像. 多波段遥感图像可以获取地物的颜色信息,但空间分辨率较低. 光谱通道越多,分辨物体的能力越强,即光谱分辨率越高.

在实际应用中,直接获得理想的原始融合图像比较困难,因此无法成功地训练融合模型. 因此可以将数据集中的原始图像进行预处理. 首先对原始图像进行采样,将其下采样到原始图像大小的一半,然后将其上采样到原始图像大小作为 MS 图像.

### 1.1.1 采样方法

上采样可以简单的理解为任何可以让图像变成更高分辨率的技术. 本文使用的是双线性内插法.

双线性插值是通过四点左右计算权重,然后确定插入图像的像素值. 新生成的图像中的每个点将计算一次. 利用待计算像素的 4 个相邻像素的灰度值在两个方向上进行线性插值,如图 3 所示.



图 2 多光谱图像 MS

Fig. 2 The multispectral image MS




图 3 双线性内插法

Fig. 3 The bilinear interpolation method

对于  $(i, j+v)$ ,  $f(i, j)$  到  $f(i, j+1)$  的灰度变化为线性关系,则有:

$$f(i, j+v) = [f(i, j+1) - f(i, j)] * v + f(i, j). \quad (1)$$

同理,对于  $(i+1, j+v)$  则有:

$$f(i+1, j+v) = [f(i+1, j+1) - f(i+1, j)] * v + f(i+1, j). \quad (2)$$

从  $f(i, j+v)$  到  $f(i+1, j+v)$  的灰度变化也为线性关系,由此可推导出待求像素灰度的计算式如下:

$$f(i+u, j+v) = (1-u) * (1-v) * f(i, j) + (1-u) * v * f(i, j+1) + u * (1-v) * f(i+1, j) + u * v * f(i+1, j+1) \quad (3)$$

双线性内插法的计算比最邻近点法复杂,计算量较大,但不存在灰度不连续性的缺陷,计算结果基本令人满意. 双线性插值算法输出的图像的每个像素都是原图中 4 个像素  $(2 \times 2)$  运算的结果,这种算法大大地消除了锯齿现象. 它具有低通滤波的特性,破坏了高频分量,图像轮廓可能会有一点模糊.

### 1.1.2 下采样方法

对于一幅图像  $I$  尺寸为  $M \times N$ ,  $M$  为行数,  $N$  为列数,对其进行  $s$  倍下采样,即得到  $(M/s) \times (N/s)$  尺寸的分辨率图像,其中  $s$  是  $M$  和  $N$  的公约数,如果考虑的是矩阵形式的图像,即把原始图像  $s \times s$  窗口内图像变成一个像素,这个像素点的值就是窗口内所有像素的均值:

$$P_k = \sum_{i \in \text{win}(k)} I_i s^2. \quad (4)$$

双三次插值法是双线性内插法的一种改进算法. 其输出图像的每个像素都是原图 16 个像素  $(16 \times 16)$  运算的结果. 该方法利用三次多项式  $S(x)$  得到理论上最佳插值函数  $\sin(x)/x$ ,待求像素  $(x, y)$  的灰度值由其周围 16 个灰度值加权内插获得,如下图 4 所示. 待求像素的灰度计算式如下:

$$f(x, y) = f(i+u, j+v) = ABC. \quad (5)$$

$$\text{式中, } \mathbf{A} = \begin{pmatrix} S(1+v) \\ S(v) \\ S(1-v) \\ S(2-v) \end{pmatrix}^T, \mathbf{B} = \begin{pmatrix} f(i-1, j-1) & f(i-1, j) & f(i-1, j+1) & f(i-1, j+2) \\ f(i, j-1) & f(i, j) & f(i, j+1) & f(i, j+2) \\ f(i+1, j-1) & f(i+1, j) & f(i+1, j+1) & f(i+1, j+2) \\ f(i+2, j-1) & f(i+2, j) & f(i+2, j+1) & f(i+2, j+2) \end{pmatrix}, \mathbf{C} = \begin{pmatrix} S(1+v) \\ S(v) \\ S(1-v) \\ S(2-v) \end{pmatrix}.$$

## 1.2 全色图像特性分析与预处理

全色波段,一般指使用  $0.5 \mu\text{m}$  到  $0.75 \mu\text{m}$  左右的单波段. 全色遥感图像也就是对地物辐射中全色波段的影像采集,因为是单一的波段,所以它在图上显示是灰度图片. 全色遥感图像通常具有较高的空间分辨率,但不能显示地物的颜色,如图 5 所示.




图 4 三次内插法示意图

Fig. 4 The schematic diagram of three interpolation method




图 5 全色遥感图像 Pan

Fig. 5 The panchromatic remote sensing images Pan

对于数据集中任意一张图像  $I$ , 需要构建全色遥感图像 Pan 的一个近似版本 PrePan, 这也是上文融合模型中模型输入为近似 Pan. 将图像  $I$  在 HLS 空间的  $L$  分量作为 PrePan, 其中  $L$  表示物体亮度, 计算公式为:

$$L = \frac{(\max(R, G, B) + \min(R, G, B) + \text{ave}(R, G, B))}{3}. \quad (6)$$

对遥感图像融合时, 只需将全色遥感图像转化成 PrePan 图像, 再和多光谱图像 MS 一起输入模型即可得到最终的融合图像.

设  $L_{\text{MS}}$  是 MS 图像计算得到的  $L$  图像,  $L_{\text{Fusion}}$  是融合图像对应的  $L$  图像, 即 PrePan. 需要计算  $L_{\text{Fusion}}$ , 即将  $L_{\text{MS}}$  的光谱信息注入 Pan 即可.

非下采样轮廓波变换是一种常用的图像分解方法, 利用非下采样金字塔分解和非下采样方向滤波器组, 可以在不同尺度下得到图像多个方向上的轮廓信息. 对于非下采样金字塔分解, 经过 3 级分解可以得到 3 个高频带通和 1 个低频带通, 并且低频带通包含了图像的光谱信息. 本文采用非下采样轮廓波变换将  $L_{\text{MS}}$  的光谱信息注入 Pan, 算法如下:

(1) 使用非下采样轮廓波变换将  $L_{\text{MS}}$  和 Pan 进行多级分解. 先进行 3 级非下采样金字塔分解, 再将高频带通通过滤波器组得到方向子带.

$$L_{\text{MS}} \xrightarrow{\text{NSCT}} \{L_{\text{MS}}^0, L_{\text{MS}}^1, \dots, L_{\text{MS}}^{N-1}\}, \quad (7)$$

$$\text{Pan} \xrightarrow{\text{NSCT}} \{\text{Pan}^0, \text{Pan}^1, \dots, \text{Pan}^{N-1}\}, \quad (8)$$

式中,  $L_{\text{MS}}^0$  和  $\text{Pan}^0$  分别是  $L_{\text{MS}}$  和 Pan 的低频子带,  $L_{\text{MS}}^i (1 \leq i < N)$  和  $\text{Pan}^i (1 \leq i < N)$  代表是  $L_{\text{MS}}$  和 Pan 的第  $i$  个高频子带.

(2) 将 Pan 进行非下采样轮廓波变换分解后的低频子带  $\text{Pan}^0$  替换为  $L_{\text{MS}}$  分解后的低频子带  $L_{\text{MS}}^0$ :  $\{L_{\text{MS}}^0, \text{Pan}^1, \dots, \text{Pan}^{N-1}\}$ .

(3) 使用非下采样轮廓波变换逆变换来重构  $L_{\text{Fusion}}$ ,  $L_{\text{Fusion}}$  也就是融合模型中的 PrePan.

$$L_{\text{Fusion}} \xleftarrow{\text{NSCT}} \{L_{\text{MS}}^0, \text{Pan}^1, \dots, \text{Pan}^{N-1}\}. \quad (9)$$



## 2 多光谱与全色图像融合算法

### 2.1 深度可分离卷积神经网络模型框架

卷积神经网络是一种具有深度结构和卷积运算的前向神经网络,是深度学习的重要算法之一.近年来,越来越多的卷积神经网络架构被提出用来解决卷积神经网络应用中的一些问题,典型的比如 GoogLeNet<sup>[12]</sup>、HighwayNet<sup>[13]</sup>、ResNet<sup>[14]</sup>和 DenseNet<sup>[15]</sup>等.

相比于普通卷积神经网络中卷积核对 3 个通道同时做卷积.也就是 3 个通道在一次卷积运算后,输出一个数.深度可分离卷积分为两步,如图 6 所示,通过两次卷积实现:




图 6 深度可分离卷积步骤

Fig. 6 The procedure of depth separable convolutional layer

第一步,用  $5 \times 5 \times 1$  的卷积核对 3 个通道分别进行卷积操作,输出  $8 \times 8 \times 3$  的特征图.第二步,将  $8 \times 8 \times 3$  的特征图与  $1 \times 1 \times 3$  卷积核进行卷积操作,可得到  $8 \times 8 \times 1$  的特征图.如果要提取更多特征,则需要进行更多的卷积操作.如图 7 所示,在应用了 256 个  $1 \times 1 \times 3$  的卷积之后,可以得到大小为  $8 \times 8 \times 256$  的卷积层.




图 7 共 256 次深度可分离卷积

Fig. 7 The total 256 depth separable convolutional layers

普通卷积下,有 256 个  $5 \times 5 \times 3$  核移动了  $8 \times 8$  次,也就是  $256 \times 5 \times 5 \times 3 \times 8 \times 8 = 1\,228\,800$  次乘法.

可分离卷积在第一个深度卷积步骤,有 3 个  $5 \times 5 \times 1$  核移动  $8 \times 5$  次,也就是  $3 \times 5 \times 5 \times 1 \times 8 \times 8 = 4\,800$  次乘法.在  $1 \times 1 \times 3$  卷积的第二步,有 256 个  $1 \times 1 \times 3$  核移动  $8 \times 8$  次,即  $256 \times 1 \times 1 \times 3 \times 8 \times 8 = 49\,152$  次乘法.因此,深度可分离卷积共有  $4\,800 + 49\,152 = 53\,952$  次乘法.这样的成本大概仅有传统卷积的 4%.所以,深度可分离卷积相比于传统卷积,所需的操作要少得多,计算效率更高,程序运行时间更短.

### 2.2 基于深度可分离卷积神经网络的融合算法

针对卷积神经网络特性和遥感图像融合的特点,提出使用一种深度可分离卷积神经网络.深度可分离卷积神经网络是一种特殊的卷积神经网络,它可以对多尺度图像进行融合.数字电网中的地理信息数据具有不同分辨率、不同精度、不同覆盖范围等多尺度特征,在应用中需要融合高光谱和高分辨率两种信息的图像.深度可分离卷积神经网络可以对多尺度图像进行融合.其中,输入为 MS 图像和 Pan 图像,输出为融合后的图像.通过构造训练集,可以很好地训练融合网络,最终有效地得到融合函数.

作为一种栅格数据,遥感图像的周围要素的相关性较高,即局部每一个要素都会受到周围区域要素的影响.遥感图像融合中,假设  $F(i, j)$  为融合图像在坐标  $(i, j)$  处的像素,其对应的 Pan 和 MS 图像的像素分别为  $P(i, j)$  和  $M(i, j)$ .为了合理计算  $F(i, j)$ ,首先要考虑  $P(i, j)$  和  $M(i, j)$  临近像素,计算待融合像素  $NP(i, j)$  和  $NM(i, j)$ ,然后再通过  $NP(i, j)$  和  $NM(i, j)$  来计算融合像素  $F(i, j)$ .

将 Pan 图像和 MS 图像分别进行深度可分离卷积运算,然后对  $NP$  和  $NM$  采用  $1 \times 1$  大小的卷积核进行卷积操作得到融合图像  $F$ .为了提高模型的融合能力,在卷积后进行非线性运算,最终的卷积运算定义为:

$$F = \text{ReLU}(X * w), \quad (10)$$

式中,  $X$  为卷积输入,  $w$  为卷积核,  $*$  为卷积运算,  $\text{ReLU}$  为非线性激活函数:

$$\text{ReLU}(x) = \max\{0, x\}. \quad (11)$$

深度可分离 CNN 模型见图 8.  $MS^1$  中的待融合像素是在原始 MS 图的基础上采用一次  $N \times N$  的卷积操作得来,  $MS^2$  至  $MS^5$  则是依次采用一次  $N \times N$  卷积操作获取的. 随着层数的增加, 待融合像素的区域信息逐渐增多.  $Pan^1$  至  $Pan^5$  同理. 计算如下:

$$MS^k = \text{ReLU}(MS^{k-1} * \omega_{MS}^k), \quad (12)$$

$$PAN^k = \text{ReLU}(PAN^{k-1} * \omega_{PAN}^k). \quad (13)$$

式中,  $\omega$  为融合处理卷积核.

$PanMS^1$  至  $PanMS^5$  以及最终的融合图像 Fusion 都是在原始 MS 图像和 PAN 图像基础上, 进行  $1 \times 1$  卷积操作获取的结果, 每一次的融合都是在上一级融合的基础上进行的. 最终的融合图像 Fusion 则是在多种尺度下融合的图像.  $PanMS^k$  和 Fusion 的计算分别为:

$$PanMS^k = \text{ReLU}([MS^{k-1}, PAN^{k-1}, PanMS^{k-1}] * \omega_{PanMS}^k), \quad (14)$$

$$Fusion = ([MS^5, PAN^5, PanMS^5]) * \omega_{PanMS}, \quad (15)$$

式中,  $[ ]$  是特征通道方向的组合.

图 8 中的五层融合深度可分离 CNN 模型表示一个多光谱与全色遥感图像融合函数  $F(MS, PrePan) = Fusion$ , 其输入为 PrePan 图像和 MS 图像, 输出为图像 Fusion. 在实际应用中, 需要先将 Pan 处理为 PrePan, 输入模型即可, 具体转换步骤 2.2 节已详细介绍.

为了减少边界信息的丢失, 进行卷积操作时不直接在特征图边缘填充 0, 而是在 Pan 图像和 MS 图像的边缘进行 0 元素填充, 将原始图像尺寸大小由  $32 \times 32$  增加至  $42 \times 42$ , 最后经过五层  $3 \times 3$  卷积网络, 每一个卷积层都使用 ReLU 激活函数, 输出的融合图像大小固定为  $32 \times 32$ .

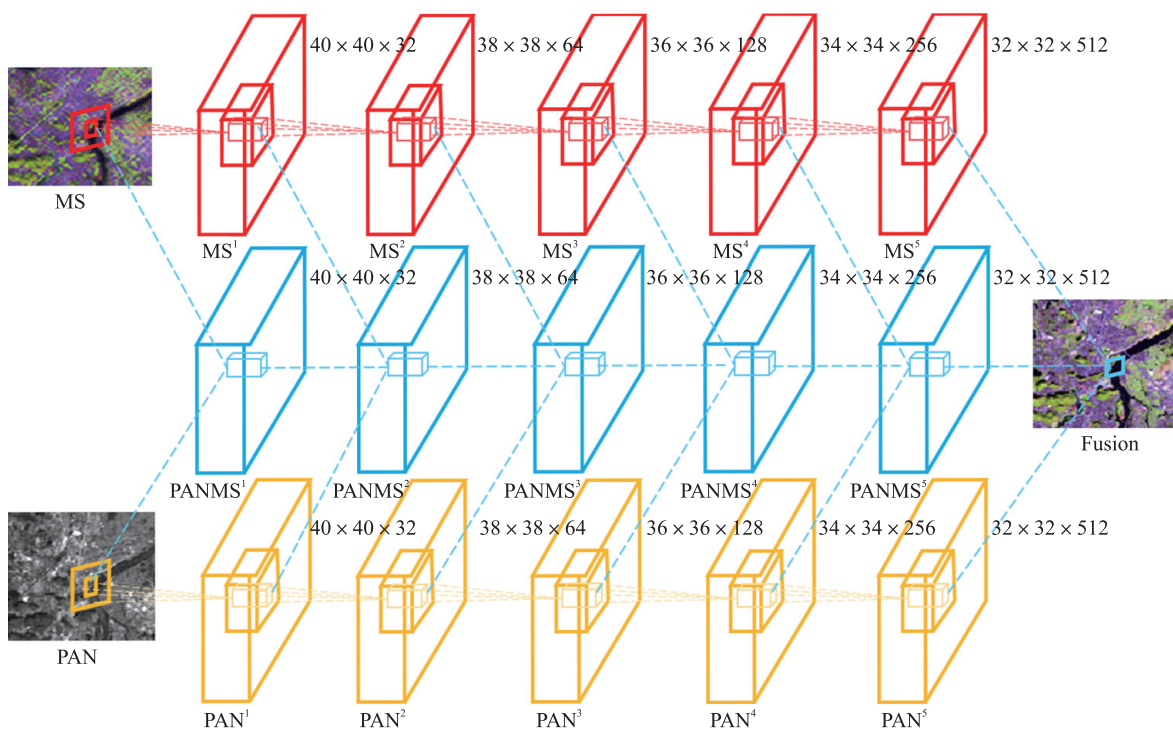


图 8 五层融合深度可分离 CNN 模型

Fig. 8 The depth separable CNN model with five layers fusion

### 3 实验与分析

#### 3.1 模型训练过程

本文选择 ImageNet 数据集中的图像作为训练集中的原始图像. ImageNet 中的 Downsampled ImageNet 提供了  $32 \times 32$  和  $64 \times 64$  两种像素图像, 使用  $32 \times 32$  的原始图像. 其中提供训练图像共 4GB. ImageNet 数据集中的物体类别多, 图片多样性强, 数据量大, 这样训练出的数学模型更为可靠准确. 从中选取 50 000 张图片进行模型训练.

此外,采用一个回归模型训练多光谱与全色遥感图像融合函数  $F(MS, PrePan) = Fusion$ , 并且使用均方误差作为损失函数,其定义如下:

$$L(\theta) = \frac{1}{n} \sum_{i=1}^n \|I - F(\theta, Apan, MS)\|^2, \quad (16)$$

式中,  $I$  为训练集中的原始融合图像,  $PrePan$  为近似全色图像,  $MS$  为多光谱图像,  $F(Apan, MS)$  为模型融合的输出图像,  $n$  为训练样本数。

训练模型采用 NVIDIA TITAN RTX 显卡, 优化算法为基于自适应学习的 Adam 算法。初始学习率设置为 0.001, 训练模型总共迭代 30 000 次, 当迭代次数为 24 000 时将学习率设为 0.000 1。当学习率设置较小时, 需要更多的时间进行样本的训练; 当学习率设置较大时, 训练结果会出现震荡, 导致精度不稳定。所以一开始将学习率设置为 0.001, 加快收敛过程, 当训练到一定时间后, 将学习率设置为 0.000 1, 减少梯度在最小值附近的来回震荡。经过训练后, 模型最终的损失函数损失值为 0.000 001 8, 基本接近于 0, 满足要求。

### 3.2 深度可分离 CNN 算法模型测试结果

为了测试本文算法对不同尺度的多光谱图像和全色图像的融合效果, 选取了在不同尺度下同一地点的多光谱  $MS$  图像和全色  $Pan$  图像。图 9 为模型在测试图像上的融合结果, 其中 (a)、(b)、(c) 和 (d) 分别为  $MS$  图像(低分辨率图像)、 $PrePan$  近似全色图像( $L$  分量)、传统 CNN 融合图像和本文算法融合图像, 从图中可以看出, 本文算法融合图像可以保留更多的光谱信息和空间信息, 具有较好的融合效果。




图 9 模型测试结果图

Fig. 9 The test results of the proposed model

### 3.3 其他模型对比结果

为了表现本文算法的鲁棒性和有效性, 选取高通滤波器(high pass filter, HPF)<sup>[16]</sup>、深度支撑值学习融合网络(deep support value learning networks, DSVL Nets)<sup>[17]</sup>、传统 CNN 模型作为对比融合方法, 对比结果如表 1 所示。

从表 1 中数据可以看出, 在 4 种融合方法中, 本文所使用的深度可分离 CNN 算法在多光谱和全色图像的融合上取得了相对较好的结果。在均方根误差上, 本文使用的方法与其余 3 种方法处在同一量级且



低于 HPF 算法,并且相较于传统 CNN 算法,本文算法均方误差降低 7%,此外,本文提出的深度可分离 CNN 算法图像融合时间比传统 CNN 减少了 29%。试验结果表明本文算法获得的融合图像可以保留更多的光谱信息和空间信息,融合时间更短,具有较好的融合效果。

表 1 对比算法融合图像评判指标

Table 1 The evaluation indexes of fusion images using comparing algorithms

算法	均方根误差 RMSE	相关系数 CC	通用质量 UQI	峰值信噪比 PSNR	时间 T/s
HPF	26.983	0.882	0.887	17.998	3.7612
DSVL Nets	27.319	0.955	0.955	13.762	2.1032
传统 CNN	28.287	0.932	0.904	19.982	3.8911
深度可分离 CNN	26.313	0.941	0.969	20.878	2.5724

4 结论

本文提出了一种基于卷积神经网络的多光谱和全色图像融合的方法,针对以往全色与多光谱图像融合精度不高的问题,通过加深卷积层层数和使用深度可分离卷积对传统算法进行优化改善。最后实验结果表明,相较于传统 CNN,本文算法获得的融合图像可以保留更多的高光谱信息和高分辨率信息,融合速度快,准确率高,融合质量更高。

[参考文献]

[1] 李昌洁,宋慧慧,张开华,等. 条件生成对抗遥感图像时空融合[J]. 中国图象图形学报,2021,26(3):714-726.

[2] 李树涛,李聪好,康旭东. 多源遥感图像融合发展现状与未来展望[J]. 遥感学报,2021,25(1):148-166.

[3] 黄波,姜晓璐. 增强型空间像元分解时空遥感影像融合算法[J]. 遥感学报,2021,25(1):241-250.

[4] 顾宇鑫,马小虎. 采用稀疏变换和拉普拉斯金字塔的数字水印算法[J]. 计算机辅助设计与图形学学报,2018,30(5):901-910.

[5] 傅志中,王雪,李晓峰,等. 基于视觉显著性和 NSCT 的红外与可见光图像融合[J]. 电子科技大学学报,2017,46(2):357-362.

[6] 殷明,段普宏,褚标,等. 基于非下采样双树复轮廓波变换和稀疏表示的红外和可见光图像融合[J]. 光学精密工程,2016,24(7):1763-1771.

[7] 刘先红,陈志斌,秦梦泽. 结合引导滤波和卷积稀疏表示的红外与可见光图像融合[J]. 光学精密工程,2018,26(5):1242-1253.

[8] 张建明,邱晓晖. 基于 Curvelet 变换的指纹图像去噪[J]. 计算机技术与发展,2018,28(5):164-167.

[9] 颜正恕,王璟. 基于非下采样轮廓波变换耦合对比度特征的遥感图像融合算法[J]. 电子测量与仪器学报,2020,34(3):28-35.

[10] GHASSEMIAN H. A review of remote sensing image fusion methods[J]. Information fusion,2016,32:75-89.

[11] FAN C,WANG L,LIU P,et al. Compressed sensing based remote sensing image reconstruction via employing similarities of reference images[J]. Multimedia tools and applications,2016,75(19):12201-12225.

[12] LI C M,ZHANG H G,WU P D,et al. A complex junction recognition method based on GoogLeNet model[J]. Transactions in GIS,2020,24(6):1756-1778.

[13] Srivastava R K, Greff K, Schmidhuber J. Training very deep networks [C]//Proceedings of the Advances in Neural Information Processing Systems. Montreal, Canada:MIT Press,2015:2377-2385.

[14] 许可,高尚. 深度卷积神经网络 LeNet-5 和 ResNet 的对比以及应用分析[J]. 电子设计工程,2020,28(2):82-85.

[15] 马永杰,刘培培. 基于 DenseNet 进化卷积神经网络的图像分类算法[J]. 激光与光电子学进展,2020,57(24):1-5.

[16] GANGKOFNER U G,PRADHAN P S,HOLCOMB D W. Optimizing the high-pass filter addition technique for image fusion[J]. Photogrammetric engineering & remote sensing,2007,73(9):1107-1118.

[17] 李红,刘芳,杨淑媛,等. 基于深度支撑值学习网络的遥感图像融合[J]. 计算机学报,2016,39(8):1583-1596.

[责任编辑:陆炳新]