

基于改进的3D-CNN的高光谱遥感图像地物分类

谢幸雨¹, 贺 辉^{1,2}, 邢海花³

(1. 北京师范大学珠海校区自然科学高等研究院, 珠海 519087; 2. 北京师范大学智能工程与教育应用研究中心, 珠海 519087; 3. 海南师范大学信息科学技术学院, 海口 571158)

摘要: 高光谱遥感影像波段众多, 包含丰富的辐射、空间和光谱信息, 是多种信息的综合载体, 应用广泛。但是传统的高光谱影像地物分类方法多着重于光谱维度的特征提取, 却忽略了空间维度上的特征, 进而影响了分类的准确性。三维卷积神经网络(Three-dimensional convolutional neural network, 3D-CNN)可以同时在这三个维度上对数据进行卷积处理, 故本文采用3D-CNN深度网络进行高光谱影像地物分类, 并针对3D-CNN网络存在的问题, 提出了一种基于改进的3D-CNN的高光谱遥感影像地物分类方法。本文方法对提取到的空间和光谱特征实现融合复用, 尽可能发挥特征的价值。此外, 本文引入浅层特征细节保存网络的思想, 提出一种综合浅层特征细节保存的影像分类深度网络模型, 进一步提高了高光谱影像地物分类的准确度。在Tensorflow框架下对2个常用的高光谱遥感影像数据集(Indian Pines和Pavia University)的实验结果表明, 相比基础的3D-CNN网络, 本文方法的分类精度提高了近2%, 而且类别边界更准确。

关键词: 高光谱图像分类; 三维卷积神经网络; 特征融合浅层; 特征细节保存

中图分类号: TP391 **文献标志码:** A

Hyperspectral Remote Sensing Land-Cover Classification Based on Improved 3D-CNN

XIE Xingyu¹, HE Hui^{1,2}, XING Haihua³

(1. Advanced Institute of Natural Sciences, Beijing Normal University, Zhuhai 519087, China; 2. Research Center for Intelligent Engineering and Educational Application, Beijing Normal University, Zhuhai 519087, China; 3. School of Information Science and Technology, Hainan Normal University, Haikou 571158, China)

Abstract: Hyperspectral remote sensing image has dozens or even hundreds of bands. It is a comprehensive carrier of many kinds of information, including rich radiation, spatial and spectral information and is widely used in the field of terrain mapping. However, the traditional hyperspectral image classification methods mostly focus on the feature extraction of spectral dimension, but ignore the features of spatial dimension, which affects the accuracy of classification. The three-dimensional convolutional neural network (3D-CNN) can convolute data in three dimensions at the same time, so this paper uses 3D-CNN depth network to classify ground objects with hyperspectral images, and proposes an improved algorithm based on 3D-CNN for hyperspectral remote sensing land-cover classification. The method can reuse the extracted spatial and spectral features and give full play to the value of features. In addition, this paper introduces the idea of shallow feature preservation network, and proposes a depth network model of

基金项目: 海南省基础与应用基础研究计划(自然科学领域)高层次人才计划(2019RC182)资助项目。

收稿日期: 2020-07-10; **修订日期:** 2020-09-30

image classification integrating shallow feature preservation, which further improves the accuracy of hyperspectral remote sensing land-cover classification. Experimental results of two commonly used hyperspectral remote sensing image data sets (Indian Pines and Pavia University) under the framework of Tensorflow show that compared with the basic 3D-CNN network, the classification accuracy of the proposed method is improved by nearly 2%.

Key words: hyperspectral remote sensing land-cover classification; 3D-CNN network; feature fusion; feature details preservation

引 言

随着高光谱成像技术逐渐成熟,高光谱遥感数据可以提供越来越多的谱域和空域信息,对于描述地物有着重要的意义,在目标精细分类和有效辨识方面已表现出很好的潜力,广泛应用于农业、矿业和地理观测等领域。

针对高光谱遥感数据高维度、高冗余的特点,研究人员对数据的预处理进行了研究^[1]。其中,主成分分析法^[2]是常用的子空间算法,其有助于降维,但由于高光谱数据具有非线性特点^[3],提取到的低维度特征代表性会受到影响。Alborzi等^[4]提出了HYSIME方法,利用高光谱信号子空间识别技术进行子空间选择,取得了较好的降维结果。Chen等^[5]引入基于无监督深度学习的自动编码器来进行降维的处理,获得了比主成分分析法等传统特征提取算法更好的精度。近年来,卷积神经网络(Convolutional neural networks, CNN)已经成为处理计算机视觉任务的有效方法^[6]。Xia等^[7]利用SSGF(Semisupervised graph fusion)方法将光谱、空间和高程这3种特征投影到一个较低的子空间中,得到新的融合特征,提高了分类的准确性。赵斐等^[8]提出多特征图金字塔融合深度网络,提取图像的多层次特征,引入多层次和多尺度特征融合策略,提高了中小型目标分类的准确性。张猛等^[9]提出基于特征融合的卷积神经网络结构,提高了特征的利用率。在改进卷积神经网络方面,Xu等^[10]提出包含两个分支结构的网络来融合Lidar和HSI信息进行分类。Huang等^[11]以“Densenet”为灵感,提出了一个级联网络,用于结合来自不同层的特征与快捷路径。Mou等^[12]基于卷积和反卷积的概念,提出了一种全新的网络结构,用于高光谱的无监督光谱空间特征学习。针对CNN网络影像分类几何失真、特征表示不足以及忽视相邻空间联系的问题,Zhang等^[13]提出了全新的OCNN(Object-based CNN)网络,通过特征融合、目标轮廓保持掩模策略和物体变形系数补充,与常见的算法比具有更快的计算效率和更优的分类效果。由于三维CNN(Three-dimensional CNN, 3D-CNN)能够同时对数据的光谱维度及空间维度进行处理,李冠东等^[14]提出基于双卷积池化结构的3D-CNN高光谱遥感影像分类方法。实验结果表明,简单的线性结构处理数据提到的特征代表性不足,采用特征融合层可以提取到更好的特征,但随着特征融合层数的逐渐增加,会导致特征细节部分的丢失,进而影响到分类精度。针对上述研究,本文提出一个改进的三维卷积神经网络(Intensive-3D-CNN),其贡献有3个方面:(1)通过3D-CNN有效提取高光谱遥感影像的空谱联合特征;(2)引入特征融合层来实现特征的复用,以提升提取特征的代表性;(3)结合浅层特征细节保存网络,提高类别边缘的准确性,减少由于特征复用造成连接处相邻像素空间干扰而导致的大面积错分现象。

1 Intensive-3D-CNN 网络

Intensive-3D-CNN网络通过引入特征融合层和浅层特征细节保存网络来提升基础3D-CNN网络性能,如图1所示,其结构分为4个部分:(1)浅层特征提取网络;(2)卷积特征融合网络;(3)浅层特征细节保存网络;(4)影像分类网络。

1.1 浅层特征提取网络

高光谱遥感数据具有高维数、高冗余及高噪声的特点。直接将遥感影像数据输入后续网络会导致运算量大、效果不明显的问题。因此,本文先通过浅层特征提取网络对输入数据作过滤处理,获得更合适的浅层特征。浅层特征提取网络包括三维卷积层和最大池化层两个部分,如图2所示。输入数据通过三维卷积层进行卷积处理,再通过激活函数 Relu 去除冗余,强化特征,最后通过最大池化层输出结果,结果作为后续网络的输入。

1.2 卷积特征融合网络

不同层级的特征比对研究表明,浅层特征具备更高的分辨率,可以保留更多的空间、细节信息。通过浅层特征能更好地兼顾到数据在空间之间的关联性,更好地从整体去描述数据,浅层特征提取网络结构如图2所示。但是由于其只经过极少的卷积处理,所以语义性更低,而且常常伴有大量的噪声。随着多次卷积,深层特征变动性越来越大,噪声逐渐减少,语义性越来越强,越来越注重影像之间的区分度描述。不可避免的是,其分辨率更低,对细节的感知能力更低,无法注意到数据的关联性。

考虑到浅层特征与深层特征的特点,本文使用卷积特征融合网络对浅层特征和深层特征进行融合处理,目的是通过特征复用获得全新的特征,提高特征的利用率,增强网络的特征表达能力^[15]。卷积特征融合网络使用特征融合单元+过渡单元的结构,如图3所示。特征融合单元负责提取特征并实现单元内的特征融合,过渡单元负责降低特征图的大小,并控制特征图数量。

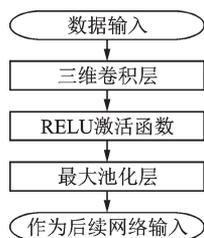


图2 浅层特征提取网络结构

Fig.2 Structure of shallow feature extraction

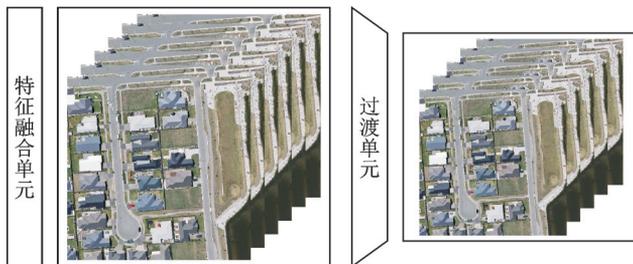


图3 卷积特征融合网络结构

Fig.3 Structure of convolution feature fusion

特征融合单元的具体实现细节如图4所示,单元内有数个三维卷积层 Conv3D,每个三维卷积层输出的特征图大小相同,每个卷积层的连接方式与密集网络连接方式相同,通过 Concat 的形式使每层的特征图在通道维度上实现连接。图中 N 为卷积核大小, K 为卷积核个数。

若输入到特征融合单元的特征为 H ,其输出表示为

$$h_i = C_{N,K}([H, h_1, h_2, h_3, \dots, h_{i-1}]) \quad (1)$$

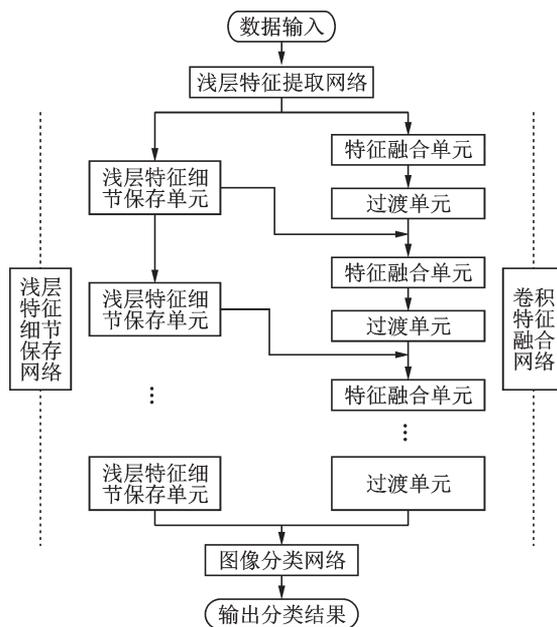


图1 Intensive-3D-CNN网络结构

Fig.1 Structure of intensive-3D-CNN

式中: h_i 表示第*i*个卷积层的输出; $[\cdot]$ 表示各个卷积层的特征图在通道维度上线性连接在一起。

过渡单元的具体实现细节如图5所示,包含1个三维卷积层和1个平均池化层。普通卷积神经网络通过池化层来降低特征图的大小,但Concat的连接方式要求特征图大小必须一样,受到Densenet^[10]中Transition层的启发,本文过渡单元采用大小为 $1 \times 1 \times 1$ 的三维卷积核进行卷积操作来降低特征图的大小。另一方面,通过过渡单元中卷积层的卷积核个数来控制输出特征图数量,解决由于密集连接而导致的特征冗余度过高的问题,并通过平均池化层进一步降低网络的训练难度。

1.3 浅层特征细节保存网络

文献[15]提出了一种像素编码网络用于保存浅层特征的高频细节,最终实现影像超分辨率重建。受其启发,本文提出使用浅层特征细节保存网络来保存浅层特征的局部细节,减少由于特征复用而导致的连接处相邻像素空间干扰。浅层特征细节保存网络的具体实现如图6所示。图6网络由若干个三维卷积层和平均池化层构成,每个卷积层的卷积核大小均为 $1 \times 1 \times 1$,因此可以保存浅层特征原有的结构信息,而且可以根据需要调整浅层特征的大小。卷积层的通道数为*K*,可以通过调整*K*的值使浅层特征卷积层特征输出的形状对应一个过渡单元的形状,得以通过Concat的形式实现浅层特征细节保存网络与特征融合网络的联接。基于高光谱图像类别较为集中的特点,使用平均池化能够使分类的边缘更平滑。

1.4 影像分类网络

影像分类网络结构如图7所示,将最后一个特征融合单元和最后一个浅层特征细节保存网络卷积层的输出特征通过Concat的形式融合,然后将其输入到一个卷积

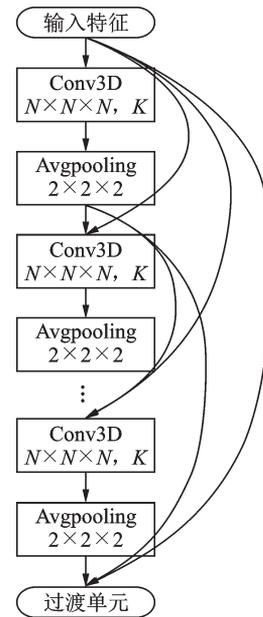


图4 特征融合单元结构

Fig.4 Structure of feature fusion unit

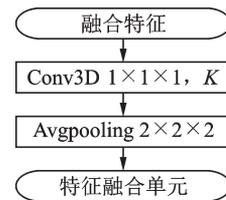


图5 过渡单元结构

Fig.5 Structure of transition unit

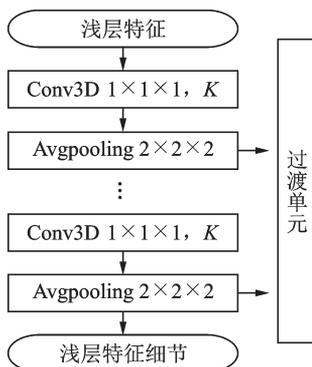


图6 浅层特征细节保存网络

Fig.6 Structure of shallow feature detail preservation

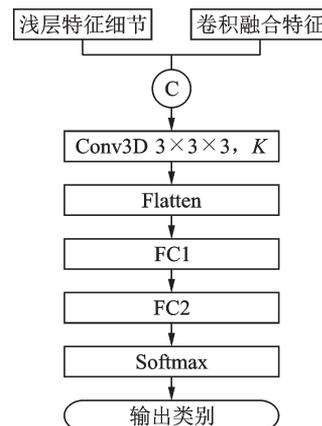


图7 图像分类网络结构

Fig.7 Structure of image classification

核大小为 $3 \times 3 \times 3$ 的三维卷积层,由于需要的是像素级类别标签结果,影像分类网络任务的本质是语义分割,所以提取到具有融合网络信息以及保存网络信息的联合特征,再将四维的特征转化为二维特征,输入到两个全连接层FC1和FC2,而非全卷积网络。最后使用Softmax损失函数来训练遥感影像地物分类网络。得到输出类别后,再进行上采样获得可视化的输出结果。

2 实验与结果分析

2.1 数据集

数据集样本如图8所示,采用了印第安纳州农场(Indian Pines)和帕维亚大学(Pavia University)两个具有挑战性的高光谱遥感影像数据集来测试和检验本文提出的Intensive-3D-CNN网络。

2.1.1 Indian Pines 数据集

Indian Pines数据集是最早使用于高光谱遥感影像分类的数据集,是美国于1992年使用AVIRIS光谱仪对印第安纳州一片农场进行拍摄制作而成。影像大小为145像素 \times 145像素,光谱波段数为220,空间分辨率为20 m,属于典型的早期高光谱数据,分类难度较大。该场景包含了16个地物类别,包括玉米、草场、干草堆和房屋等。训练集使用3 200张图片,测试集使用2 426张图片。

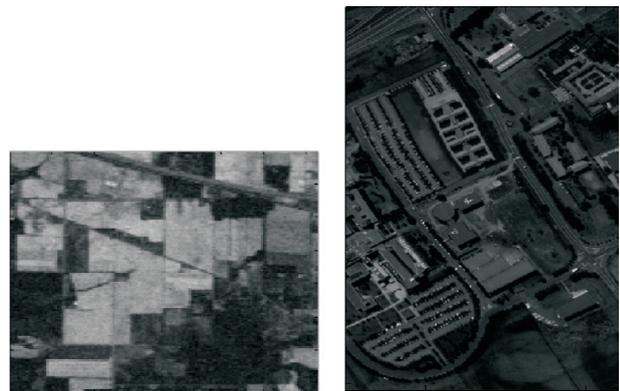
2.1.2 Pavia University 数据集

Pavia University数据集是通过飞机搭载ROSIS传感器,在意大利北部帕维亚大学上空拍摄制作而成的。影像大小为610像素 \times 340像素,光谱波段数为103,空间分辨率为1.3 m。该场景包含了9个地物场景,包括林地、建筑物和马路等。训练集使用1 800张图片,测试集使用10 097张图片。

2.2 参数设置

为实现搭建一个轻量级神经网络的目标,本文使用了尽可能少的网络层数去实现较好的遥感影像地物分类,网络中卷积层的具体参数如表1所示。除此之外,还有两个全连接层FC1和FC2,通道数分别为200,84。

为了验证卷积特征融合网络的效果,参考文献[14]提出的3D-CNN网络,设置了一个基础3D-CNN网络进行对比实验,但为了避免由于参数不同而影响对比,其卷积层数深度、卷积核大小和数量均与前者一致。同时为验证浅层



(a) Indian Pines data set

(b) Pavia University data set

图8 实验数据集样本

Fig.8 Sample of experimental data set

表1 网络卷积层的具体参数

Table 1 Specific parameters of network convolution layer

所属网络	三维卷积核		
	名称	大小	通道
浅层特征提取网络	Conv1	$7 \times 7 \times 7$	512
浅层特征提取网络	Conv2	$3 \times 3 \times 3$	256
特征细节保存网络	Conv3_1	$1 \times 1 \times 1$	256
特征细节保存网络	Conv4_1	$1 \times 1 \times 1$	128
特征细节保存网络	Conv5_1	$1 \times 1 \times 1$	256
卷积特征融合网络	Conv3	$3 \times 3 \times 3$	256
卷积特征融合网络	Conv4	$3 \times 3 \times 3$	256
卷积特征融合网络	Trans1	$1 \times 1 \times 1$	256
卷积特征融合网络	Conv5	$3 \times 3 \times 3$	128
卷积特征融合网络	Conv6	$3 \times 3 \times 3$	128
卷积特征融合网络	Conv7	$3 \times 3 \times 3$	128
卷积特征融合网络	Trans2	$1 \times 1 \times 1$	128
卷积特征融合网络	Conv8	$3 \times 3 \times 3$	256
卷积特征融合网络	Trans3	$1 \times 1 \times 1$	256
图像分类网络	Conv9	$3 \times 3 \times 3$	128

细节保存网络在本文提出的算法中的作用,设置了一个仅含本文提出的特征融合网络结构的对比实验。

2.3 结果分析

实验平台为云虚拟系统,配有4个vCPU,15 GB内存,300 GB虚拟固态硬盘,NVIDIA Tesla P100显卡。Indian Pines和Pavia University数据集实验结果分别如图9、10所示。从目视判读来看,与普通3D-CNN网络的结果相比,基于Intensive-3D-CNN的影像分类算法分类结果中大面积错分的现象大幅度减少。而且,在不关心网络的训练时间和网络深度的情况下,采用Intensive-3D-CNN结构可以通过增加特征融合单元的卷积层深度来提高准确率^[16],但是如果采用普通的卷积结构,随着网络深度的增加会出现梯度弥散和梯度爆炸的情况,影响网络的训练^[17],所以卷积特征融合网络也更具有成长性。此外,使用浅层特征细节保存网络可以使影像类别边界的分类更加准确,而且相对集中的错分区域面积有所减少。

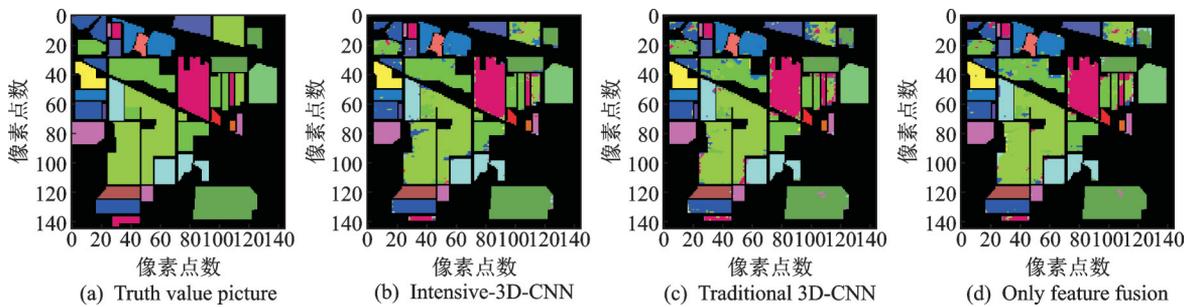


图9 Indian Pines数据集实验结果

Fig.9 Experimental results of Indian Pines data set

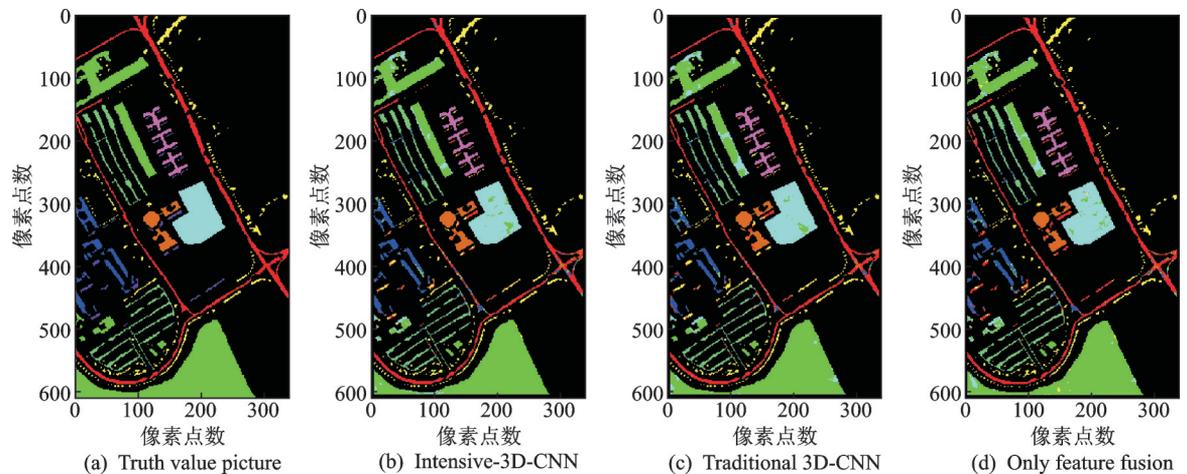


图10 Pavia University数据集实验结果

Fig.10 Experimental results of Pavia University data set

此外,模型训练所需时间、模型分类结果准确度统计结果如表2所示,数据由10次重复实验求平均值得出。由表中数据可知,基于Intensive-3D-CNN的影像分类算法在增加少量时间代价的情况下,大幅提高了影像分类的准确度,同时可以发现增加浅层保存网络可以进一步提高分类结果精准度。相比基础3D-CNN网络结果,本文高光谱影像总体分类准确率提高了约2%。

表2 客观指标比较

Table 2 Objective index comparison

数据集	模型	时间/s	准确率
Indian Pines	Intensive-3D-CNN	762	0.929
	基础3D-CNN	503	0.903
	仅特征融合网络	513	0.906
Pavia University	Intensive-3D-CNN	365	0.914
	基础3D-CNN	343	0.901
	仅特征融合网络	356	0.901

3 结束语

本文为充分发挥高光谱影像有效空间信息和光谱信息的价值,提出了一种特征融合网络结构,且为了减少由于特征复用造成的误差,结合浅层特征细节保存网络,提出了Intensive-3D-CNN网络。结果表明本文提出的网络结构提高了分类结果的准确度,且在类别边界划分上有更好的表现。今后的研究可以借鉴Densenet的最新研究成果,构建更好的特征融合网络;其次,可以研究如何选用更好的浅层特征细节来提升影像分类结果的精准度。

参考文献:

- [1] LI T, ZHANG J P, ZHANG Y. Classification of hyperspectral image based on deep belief networks[C]// Proceedings of IEEE International Conference on Image Processing. Paris: IEEE, 2014: 5132-5136.
- [2] HUANG Hong, QU Huanpeng, Hyperspectral remote sensing image classification based on SSDE[J]. Optics and Precision Engineering, 2014, 22(2): 434-442.
- [3] 黄鸿,何凯,郑新磊,等.基于深度学习的高光谱图像空-谱联合特征提取[J].激光与光电子学进展, 2017(10): 174-182.
HUANG Hong, HE Kai, ZHENG Xinlei, et al. Spatial spectral joint feature extraction of hyperspectral images based on deep learning[J]. Laser & Optoelectronics Progress, 2017(10): 174-182.
- [4] ALBORZI N, POORAHANGARYAN F, BEHESHTI H. Spectral-spatial classification of hyperspectral images using signal subspace identification and edge-preserving filter[J]. Int J Autom Comput, 2020, 17: 222-232.
- [5] CHEN Y, LIN Z, ZHAO X, et al. Deep learning-based classification of hyperspectral data[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2014, 7(6): 2094-2107.
- [6] SERMANET P, CHINTALA S, LECUN Y. Convolutional neural networks applied to house numbers digit classification [C]//Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012). Tsukuba: [s.n.], 2012: 3288-3291.
- [7] XIA J, LIAO W, DU P. Hyperspectral and LiDAR classification with semisupervised graph fusion[J]. IEEE Geoscience & Remote Sensing Letters, 2019, 99: 1-5.
- [8] 赵斐,张文凯,闫志远,等.基于多特征图金字塔融合深度网络的遥感图像语义分割[J].电子与信息学报, 2019, 41(10): 2525-2531.
ZHAO Fei, ZHANG Wenkai, YAN Zhiyuan, et al. Remote sensing image semantic segmentation based on multi feature map Pyramid fusion depth network[J]. Journal of Electronics and Information Technology, 2019, 41(10): 2525-2531.
- [9] 张猛,钱育蓉,杜娇,等.基于特征整合的卷积神经网络草地分类算法[J].计算机工程与科学, 2019, 41(7): 1251-1256.
ZHANG Meng, QIAN Yurong, DU Jiao, et al. Convolution neural network grassland classification algorithm based on feature integration[J]. Computer Engineering and Science, 2019, 41(7): 1251-1256.
- [10] XU X, LI W, RAN Q, et al. Multisource remote sensing data classification based on convolutional neural network[J]. IEEE Trans Geosci Remote Sens, 2018, 56(2): 937-949.
- [11] HUANG G, LIU Z, DER MAATEN L V, et al. Densely connected convolutional networks[J]. Computer Vision and Pattern

- Recognition, 2017, 1: 2261-2269.
- [12] MOU L, GHAMISI P, ZHU X X. Unsupervised spectral-spatial feature learning via deep residual conv-deconv network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(1): 391-406.
- [13] ZHANG Chenxiao, YUE Peng, TAPETE D, et al. A multi-level context-guided classification method with object-based convolutional neural network for land cover classification using very high resolution remote sensing images [J]. International Journal of Applied Earth Observations and Geoinformation, 2020, 88: 102086.
- [14] 李冠东,张春菊,高飞,等. 双卷积池化结构的3D-CNN高光谱遥感影像分类方法[J]. 中国图象图形学报, 2019, 24(4): 639-654.
LI Guandong, ZHANG Chunju, GAO Fei, et al. 3D-CNN hyperspectral remote sensing image classification method based on double convolution pooling structure [J]. Journal of Image and Graphics, 2019, 24(4): 639-654.
- [15] 沈明玉,俞鹏飞,汪荣贵,等. 多阶段融合网络的影像超分辨率重建[J]. 中国图象图形学报, 2019, 24(8): 1258-1269.
SHEN Mingyu, YU Pengfei, WANG Ronggui, et al. Image super resolution reconstruction based on multi-stage fusion network [J]. Journal of Image and Graphics, 2019, 24(8): 1258-1269.
- [16] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks [C]// Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 1646-1654.
- [17] 应自炉,龙祥. 多尺度密集残差网络的单幅影像超分辨率重建[J]. 中国图象图形学报, 2019, 24(3): 410-419.
YING Zilu, LONG Xiang. Super resolution reconstruction of single image based on multi-scale dense residual network [J]. Journal of Image and Graphics, 2019, 24(3): 410-419.

作者简介:



谢幸雨(1996-),男,研究方向:机器学习、图像识别、智能空间信息处理,E-mail: 992343479@qq.com。



贺辉(1979-),通信作者,女,博士,教授,研究方向:机器学习、图像识别、智能空间信息处理,E-mail: hh-dpc@bnu.edu.cn。



邢海花(1975-),女,博士,教授,研究方向:机器学习与人工智能、智能空间信息处理,E-mail: 523239863@qq.com。

(编辑:张黄群)