



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所


中国图象图形学报

2021

08

VOL.26

ISSN1006-8961
CN11-3758/TB



“高光谱图像处理与应用”专刊



第26卷第8期 (总第304期)

2021年8月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿, 均视为同意在本刊网站及CNKI等全文数据库出版, 所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用, 所有内容, 未经许可, 不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院

主办单位 中国科学院空天信息创新研究院

中国图象图形学学会

北京应用物理与计算数学研究所

主 编 吴一戎

编辑出版 《中国图象图形学报》编辑出版委员会

通信地址 北京市海淀区北四环西路19号

邮 编 100190

电子信箱 jig@aircas.ac.cn

电 话 010-58887035

网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号

总 发 行 北京报刊发行局

订 购 全国各地邮局

海外发行 中国国际图书贸易集团有限公司

(邮政信箱: 北京399信箱 邮编: 100048)

印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian

Monthly, Started in 1996

Superintended by Chinese Academy of Sciences

Sponsored by Aerospace Information Research Institute, CAS

China Society of Image and Graphics

Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Wu Yirong

Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics

Address No. 19, North 4th Ring Road West, Haidian District, Beijing, P. R. China

Zip code 100190

E-mail jig@aircas.ac.cn

Telephone 010-58887035

Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals

Domestic All Local Post Offices in China

Overseas China International Book Trading Corporation

(P.O.Box 399, Beijing 100048, P.R.China)

Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB


ISSN 1006-8961

CODEN ZTTXFZ

国外发行代号 M1406

国内邮发代号 82-831

国内定价 60.00元



高光谱图像在生物医学中的应用(第1764页)



HSRS-SC:面向遥感场景分类的高光谱图像数据集(第1809页)



多尺度超像素分割和奇异谱分析的高光谱影像分类(第1978页)

序言 何明一 I

编者按 II

综述

高光谱图像空谱特征提取综述

叶珍, 白璘, 何明一 1737

高光谱图像在生物医学中的应用

李伟, 吕蒙, 陈天虹, 楚照耀, 陶然 1764

高光谱成像技术新进展

近红外高光谱图像数据预测技术

梅少辉, 张博威, 马明阳, 贾森 1786

低成本便携式多光谱成像系统的研发及优化

朱豪男, 胡孟晗, 张健, 李庆利 1796

数据集论文

HSRS-SC:面向遥感场景分类的高光谱图像数据集

徐科杰, 邓培芳, 黄鸿 1809

高光谱医学诊断

膜性肾病诊断的高光谱图像张量嵌入分析

吕蒙, 陈天虹, 李伟, 杨悦, 涂天琪, 李文歌 1823

傅里叶变换通道注意力网络的胆管癌高光谱图像分割

郑少佳, 邱崧, 李庆利, 周梅, 胡孟晗, 于观贞 1836

高光谱图像目标检测与识别

局部梯度轮廓变换的高光谱异常检测

胡静, 张钰婧, 赵明华, 李鹏, 李云松 1847

结合孪生网络和像素配对的高光谱图像异常检测

王德港, 饶伟强, 孙旭, 渠瀛, 刘雪梅, 高连如 1860

粗定位和协同表示的高光谱图像异常检测

胡静, 赵明华, 李鹏, 李云松 1871

高光谱图像深度模糊核聚类的洋底锰结核识别

张启忠, 郑恩迪, 王叶剑, 高发荣 1886

高光谱图像融合与恢复

波段自适应细节注入的高分五号与Sentinel-2遥感影像空谱融合

王海荣, 郭擎, 李安 1896

基于频率加权张量核范数的高光谱图像复原

刘盛, 曾海金, 孔文凤, 张鹏丹 1910

高光谱图像分类

面向高光谱图像分类的内容引导卷积深度网络并行实现

刘启超, 肖亮, 杨劲翔 1926

增强类可分性的高光谱图像分类

方帅, 张坤, 张晶, 曹洋, 石为开 1940

高光谱图像分类的自适应决策融合方法

叶珍, 董睿, 陈浩鑫, 白璘 1952

跨数据集评估的高光谱图像分类

潘尔婷, 马泳, 黄珏, 樊凡, 李峰, 马佳义 1969

多尺度超像素分割和奇异谱分析的高光谱影像分类

付航, 孙根云, 赵云华, 潘兆杰, 胡光, 张爱竹 1978

结合倒置特征金字塔和U-Net的高光谱图像分类

程嵩阳, 熊玉洁, 姚瑶, 李庆利 1994

高光谱图像小样本分类的卷积神经网络方法

吴鸿昊, 王立国, 石瑶 2009


3D卷积自编码器高光谱图像分类模型

石延新, 何进荣, 李照奎, 曾志高 2021

封面素材由重庆大学光电工程学院黄鸿教授提供

CONTENTS

JOURNAL OF IMAGE AND GRAPHICS



Application of a hyperspectral image in medical field: a review (P1764)



HSRS-SC: a hyperspectral image dataset for remote sensing scene classification (P1809)



Combining multiscale superpixel segmentation and singular spectral analysis for hyperspectral image classification (P1978)

Review

- Review of spatial-spectral feature extraction for hyperspectral image
Ye Zhen, Bai Lin, He Mingyi 1737
- Application of a hyperspectral image in medical field: a review
Li Wei, Lyu Meng, Chen Tianhong, Chu Zhaoyao, Tao Ran 1764

Advances in Hyperspectral Imaging

- Predicting near-infrared hyperspectral images from visible hyperspectral images
Mei Shaohui, Zhang Bowei, Ma Mingyang, Jia Sen 1786
- Development and optimization of a low-cost and portable multispectral imaging system
Zhu Haonan, Hu Menghan, Zhang Jian, Li Qingli 1796

Dataset

- HSRS-SC: a hyperspectral image dataset for remote sensing scene classification
Xu Kejie, Deng Peifang, Huang Hong 1809

Medical Hyperspectral Imagery

- Tensor-based graph embedding for discriminant analysis of membranous nephropathy hyperspectral data
Lyu Meng, Chen Tianhong, Li Wei, Yang Yue, Tu Tianqi, Li Wen'ge 1823
- Fourier transform channel attention network for cholangiocarcinoma hyperspectral image segmentation
Zheng Shaojia, Qiu Song, Li Qingli, Zhou Mei, Hu Menghan, Yu Guanzhen 1836

Hyperspectral Target Detection and Recognition

- Transformation of local gradient profiles for hyperspectral anomaly detection
Hu Jing, Zhang Yujing, Zhao Minghua, Li Peng, Li Yunsong 1847
- Siamese network with pixel-pair for hyperspectral image anomaly detection
Wang Degang, Rao Weiqiang, Sun Xu, Qu Ying, Liu Xuemei, Gao Lianru 1860
- Rough location and collaborative representation for hyperspectral image anomaly detection
Hu Jing, Zhao Minghua, Li Peng, Li Yunsong 1871
- Recognition of ocean floor manganese nodules by deep kernel fuzzy C-means clustering of hyperspectral images
Zhang Qizhong, Zheng Endi, Wang Yejian, Gao Farong 1886

Hyperspectral Image Fusion and Restoration

- Spatial-spectral fusion based on band-adaptive detail injection for GF-5 and Sentinel-2 remote sensing images
Wang Hairong, Guo Qing, Li An 1896
- Hyperspectral image restoration based on frequency-weighted tensor nuclear norm
Liu Sheng, Zeng Haijin, Kong Wenfeng, Zhang Pengdan 1910

Hyperspectral Image Classification

- Parallel implementation of content-guided deep convolutional network for hyperspectral image classification
Liu Qichao, Xiao Liang, Yang Jinxiang 1926
- Hyperspectral image classification with enhanced class separability
Fang Shuai, Zhang Kun, Zhang Jing, Cao Yang, Shi Weikai 1940
- Adjustive decision fusion approaches for hyperspectral image classification
Ye Zhen, Dong Rui, Chen Haoxin, Bai Lin 1952
- Hyperspectral image classification evaluated across different datasets
Pan Erting, Ma Yong, Huang Jun, Fan Fan, Li Hao, Ma Jiayi 1969
- Combining multiscale superpixel segmentation and singular spectral analysis for hyperspectral image classification
Fu Hang, Sun Genyun, Zhao Yunhua, Pan Zhaojie, Hu Guang, Zhang Aizhu 1978
- Hyperspectral image classification using an inverted feature pyramid network with U-Net
Cheng Songyang, Xiong Yujie, Yao Yao, Li Qingli 1994
- Convolution neural network method for small-sample classification of hyperspectral images
Wu Honghao, Wang Liguang, Shi Yao 2009
- Hyperspectral image classification model based on 3D convolutional auto-encoder
Shi Yanxin, He Jinrong, Li Zhaokui, Zeng Zhigao 2021

中图法分类号: TP751 文献标识码: A 文章编号: 1006-8961(2021)08-2009-12

论文引用格式: Wu H H, Wang L G and Shi Y. 2021. Convolution neural network method for small-sample classification of hyperspectral images. Journal of Image and Graphics, 26(08): 2009-2020 (吴鸿昊, 王立国, 石瑶. 2021. 高光谱图像小样本分类的卷积神经网络方法. 中国图象图形学报, 26(08): 2009-2020) [DOI:10.11834/jig.210103]

高光谱图像小样本分类的卷积神经网络方法

吴鸿昊¹, 王立国^{1,2*}, 石瑶¹

1. 哈尔滨工程大学信息与通信工程学院, 哈尔滨 150001; 2. 大连民族大学信息与通信工程学院, 大连 116600

摘要: **目的** 与传统分类方法相比, 基于深度学习的高光谱图像分类方法能够提取出高光谱图像更深层次的特征。针对现有深度学习的分类方法网络结构简单、特征提取不够充分的问题, 提出一种堆叠像元空间变换信息的数据扩充方法, 用于解决训练样本不足的问题, 并提出一种基于不同尺度的双通道3维卷积神经网络的高光谱图像分类模型, 来提取高光谱图像的本质空谱特征。**方法** 通过对高光谱图像的每一像元及其邻域像元进行旋转、行列变换等操作, 丰富中心像元的潜在空间信息, 达到数据集扩充的作用。将扩充之后的像素块输入到不同尺度的双通道3维卷积神经网络学习训练集的深层特征, 实现更高精度的分类。**结果** 5次重复实验后取平均的结果表明, 在随机选取了10%训练样本并通过8倍数据扩充的情况下, Indian Pines数据集实现了98.34%的总体分类精度, Pavia University数据集总体分类精度达到99.63%, 同时对比了不同算法的运行时间, 在保证分类精度的前提下, 本文算法的运行时间短于对比算法, 保证了分类模型的稳定性、高效性。**结论** 本文提出的基于双通道卷积神经网络的高光谱图像分类模型, 既解决了训练样本不足的问题, 又综合了高光谱图像的光谱特征和空间特征, 提高了高光谱图像的分类精度。

关键词: 高光谱图像; 有监督分类; 空谱结合; 卷积神经网络(CNN); 深度学习; 数据扩充

Convolution neural network method for small-sample classification of hyperspectral images

Wu Honghao¹, Wang Ligu^{1,2*}, Shi Yao¹

1. College of Information and Communications Engineering, Harbin Engineering University, Harbin 150001, China;
2. College of Information and Communication Engineering, Dalian Minzu University, Dalian 116600, China

Abstract: **Objective** Classification is a major research task in hyperspectral remote sensing image processing. Extracting appropriate features from hyperspectral remote sensing images is a prerequisite to ensure the accuracy and effectiveness of classification. Traditional feature extraction methods can only extract single, shallow spectral or spatial features and have difficulty extracting deep spatial-spectral features. This limitation results in poor classification accuracy. Compared with traditional classification methods, hyperspectral image classification method based on deep learning model can extract deeper features of hyperspectral image. However, the existing deep learning methods can classify hyperspectral images but have low classification accuracy because of their simple network structure and insufficient feature extraction. Moreover, the parameters of deep network are hundreds of thousands of millions, which need a large number of labeled training samples

收稿日期: 2021-02-21; 修回日期: 2021-04-23; 预印本日期: 2021-04-30

* 通信作者: 王立国 wangliguo@hrbeu.edu.cn

基金项目: 国家自然科学基金项目(62071084)

Supported by: National Natural Science Foundation of China(62071084)

and longer time to complete the model training. However, manual annotation of hyperspectral images is a time-consuming and laborious project, and only a few labeled samples can usually be used. Therefore, constructing a depth network model for hyperspectral image classification with a small number of training samples is a key research problem. A data expansion method of stacking pixel spatial transformation information is proposed to address the problems of simple network structure and insufficient feature extraction of existing classification methods based on deep learning. A hyperspectral image classification model based on different scales of dual-channel 3D convolutional neural network is also proposed to extract the essential spatial features of hyperspectral image.

Method On the one hand, the stacking space transform information method is used to expand the training samples for solving the problem of insufficient training samples in the process of hyperspectral image classification. On the other hand, the dual-channel convolutional neural network is used, and its overall structure is composed of preprocessing, data expansion, and dual-channel convolutional neural network (DC-CNN). First, the hyperspectral image is preprocessed to transform the pixels into 3×3 and 5×5 pixel blocks containing certain spatial information as the unit to be processed. Then, the unit to be processed uses the data expansion method of stacking spatial transformation information to expand the data. The expanded dataset is transformed into shape to meet the input dimension of dual-channel convolutional neural network. Then, the pixel blocks of different sizes are input into the branch convolution of different scales of DC-CNN, and they are combined with the spatial spectrum features extracted from the two channels for training to improve the generalization ability of the network. The spatial-spectral features of hyperspectral images can be more comprehensively and fully extracted using different convolution branches to process different sizes of pixel blocks. The information loss caused by dimension reduction can be reduced, and the classification accuracy can be improved. The method of stack space transform information enriches the potential space information of the center pixel and expands the dataset by rotating each pixel and its adjacent pixels, row column transform, and other operations. The expanded pixel blocks are input into dual-channel 3D convolutional neural networks with different scales to learn the deep features of the training set and achieve higher accuracy classification. Three popular hyperspectral image classification methods are selected and compared with this method to verify its effectiveness. The three methods are 2D convolutional neural network (2D-CNN), 3D convolutional neural network (3D-CNN), and siamese neural network (SNN). The network structure of 3D-CNN is the same as that of 3×3 branches of DC-CNN, which can be considered a single-channel network model of DC-CNN.

Result Experimental results show that the Indian Pines and Pavia University datasets achieve 98.34% and 99.63% of the overall classification accuracy, respectively. The running time of different algorithms is also compared. The running time of the proposed algorithm is relatively shorter than that of the comparison algorithm, and this feature ensures the efficiency of the classification model. In addition, this study analyzes the influence of different convolution layers on the classification performance. It verifies that the convolution neural network composed of five convolution layers has the strongest feature extraction ability for hyperspectral images. The proposed method also has good classification performance on two groups of real hyperspectral image datasets. Specifically, the proposed method has certain generalization ability and advantages in running time. In this study, dual-channel convolution neural network is used to complete the deep spatial-spectral feature fusion of hyperspectral image, which fully extracts the hidden information of hyperspectral image and is conducive to the application of deep learning model in hyperspectral image classification. In the follow-up research, we can further explore the effect of multichannel convolution neural network, such as three- and four-channel convolution neural networks in hyperspectral image classification. The application of deep learning method in hyperspectral image can also be promoted.

Conclusion The performance of hyperspectral image classification model with limited training samples is not ideal. Thus, this study proposes a data expansion method of stacking pixel neighborhood spatial information and designs a hyperspectral image classification method based on dual-channel convolutional neural network, which is called DC-CNN. The data expansion method of stacking pixel neighborhood spatial information conducts spatial rotation and transformation on different scale pixel blocks to expand the number of training samples and obtain the hidden spatial information of the center pixel. This method solves the problem of insufficient training samples of depth model and insufficient spatial information extraction of hyperspectral image in feature extraction process. It inputs pixel blocks of different scales through DC-CNN network framework to comprehensively extract more abundant spatial information, completes the deep spatial-spectral information extraction, and inputs the fused spatial spectral features into softmax classifier to achieve more accurate classification.

Key words: hyperspectral image; supervised classification; spatial spectrum combination; convolutional neural network (CNN); deep learning; data expansion

0 引言

分类是高光谱遥感图像的一个研究热点。高光谱遥感图像是通过搭载在不同空间平台上的高光谱传感器,在电磁波谱的紫外、可见光、近红外和中红外区域,以数十至数百个连续且细分的光谱波段对目标区域同时成像得到的,其光谱分辨率很高,甚至能够达到纳米数量级(王立国等,2018)。因此高光谱遥感图像在获得地表图像信息的同时,也获得其光谱信息,做到光谱与图像的结合。高光谱图像与普通遥感图像相比,具有更加丰富的空间信息和光谱信息。

对高光谱遥感图像提取合适的特征是确保分类的准确性以及有效性的一个前提。但是由于高光谱图像具有高维、信息冗余等特性,会使得其在高维特征空间出现 Hughes(杜培军等,2016)现象,降低分类精度。针对这个问题,通常在进行分类之前会对高光谱图像进行降维处理,降维方法包括文献(Licciardi等,2012;Villa等,2011;Bandos等,2009)的方法等。传统的特征提取方法往往只能提取出单一的、浅层的光谱特征或者空间特征,很难提取深层的空谱结合特征,造成分类精度不够理想。神经网络以及深度学习的方法迅速发展,深度网络模型在数据从前向后传播以及误差反向传播的过程中可以慢慢地学习到数据更加全面的、深层次的综合特征。这些更深的特征对于提高高光谱遥感图像的分类精度有很重要的作用。

Chen等人(2014)使用由多层稀疏自编码器(stacked auto encoder, SAE)组成的深度网络来获得高光谱遥感图像的深度特征,并根据图像分割理论获得了像素级的分类结果。深度置信网络(deep belief networks, DBN)也应用到高光谱遥感图像分类(Chen等,2015)中。尽管这些深度学习模型可以有效地提取出高光谱遥感图像的深层次特征,并且有较好的分类精度,但是,一旦将输入转换为1维向量,模型就会失去高光谱图像的空间特征,造成了信息量的浪费,影响分类精度(齐永锋等,2020)。卷积神经网络(convolutional neural network, CNN)也

在高光谱图像分类领域取得了很好的效果。Hu等人(2015)最早使用1维卷积神经网络对高光谱图像进行分类,该方法仅仅使用了高光谱图像的光谱特征。Chen等人(2016)、Li等人(2017b)使用了2维卷积神经网络来处理高光谱图像,能够很好地结合高光谱图像中的光谱信息和空间信息。Yang等人(2018)首次使用双通道卷积神经网络来处理高光谱遥感图像。其网络模型使用1D-CNN来提取光谱特征,2D-CNN来提取空间特征。综合两种特征进行分类,取得了很好的效果。同年,孪生神经网络(siamese neural network, SNN)也被应用于高光谱图像分类(Zhao等,2018)。SNN的结构也为双通道,并且两个通道通过权值共享来实现“孪生”,然后通过具有给定标签的线性全连接层来学习两个深层特征之间的绝对差异,实现分类。3维卷积神经网络也逐渐应用到了高光谱图像分类中(Li等,2017a;He等,2017;李冠东等,2019)。使用该方法无需对高光谱图像进行复杂的预处理,可以使高光谱图像保持原有的结构,并提取出需要的空谱信息进行分类,能够最大化地提高分类精度。

以上方法虽然可以对高光谱图像进行分类,但是由于其网络结构简单,特征提取不够充分,导致分类精度不高。并且,深度网络中动辄几十万、上百万的参数量需要大量有标签的训练样本以及更长的训练时间来完成模型的训练。但是对高光谱图像进行人工标注是一个费时费力的工程,通常只有很少的有标注样本可以使用。因此,如何在少量训练样本的情况下,构造深度网络模型对高光谱图像进行分类是一个重点研究问题。针对这些问题,本文结合高光谱图像和深度学习模型的特点,提出一种堆叠空间变换信息的数据扩充方法,并构造一种双通道卷积神经网络(dual-channel convolutional neural network, DC-CNN)来进行高光谱图像分类。一方面,通过堆叠空间变换信息方法对训练样本进行扩充,以解决深度学习模型在进行高光谱图像分类过程中的训练样本不足的问题。另一方面,使用双通道卷积神经网络,让不同的卷积支路处理不同大小的像素块,可以更加全面、充分地提取高光谱图像的空谱

特征,提高分类精度。

1 基本原理

1.1 堆叠空间变换信息的数据扩充方法

虽然使用深度学习方法进行高光谱图像分类可以提取高光谱图像更全面、更深层的特征,但是这些方法均在有足够多的训练样本来训练网络的前提下才能取得令人满意的结果。而高光谱图像的训练样本有限,这在一定程度上限制了深度学习模型的学习能力,使其很难提取出高光谱图像中的典型特征,从而影响高光谱图像的分类精度。为了解决这一问题,本文提出一种堆叠空间变换信息的数据扩充方法,该方法通过中心像素点及其邻域像素进行空间旋转或行列变换操作,扩展每一中心像素点的周边像素可能出现的情况,丰富中心像素点的空间信息。既可以达到扩充数据集的目的,又可以使深度学习模型从扩充之后的训练样本中学习到更加多样的空间信息,更加充分地提取“空谱结合”特征,实现更加准确的分类。该方法步骤如下:

1) 对于任意像元选择合适的邻域大小(3×3 或 5×5),并对每个像元进行编号,中心像元编号为 1 保持不变。如果像元位于图像边缘位置,则在没有邻近像元的位置补 0。如图 1 所示,选择大小为 3×3 的像素块。

2	3	4
5	1	6
7	8	9

图 1 3×3 像素块示意图

Fig. 1 3×3 pixel block diagram

2) 中心像元保持不变,对邻域像元进行顺时针旋转、逆时针旋转、行列平移变换等操作进行数据扩充。每旋转或变换一次,则增加 1 个与中心像元对应的样本。以顺时针旋转为例,如图 2 所示。

2	3	4
5	1	6
7	8	9



5	2	3
7	1	4
8	9	6

图 2 像素块旋转示意图

Fig. 2 Schematic diagram of pixel block rotation

3) 重复步骤 2), 经过多次旋转或变换, 可以扩充得到更多的样本。如图 3 为通过顺时针旋转完成 8 倍数据扩充。

2	3	4
5	1	6
7	8	9

5	2	3
7	1	4
8	9	6

7	5	2
8	1	3
9	6	4

6	9	8
4	1	7
3	2	5

9	8	7
6	1	5
4	3	2

8	7	5
9	1	2
6	4	3

4	6	9
3	1	8
2	5	7

3	4	6
2	1	9
5	7	8

图 3 通过旋转完成 8 倍数据扩充

Fig. 3 Completes 8-fold data expansion by clockwise rotation

1.2 双通道卷积神经网络

为了利用中心像元邻域范围内更多的空间信息,同时为了提取高光谱图像的光谱特征以及空间特征,设计了双通道卷积神经网络 DC-CNN。选择不同尺度的空间像素块作为 DC-CNN 的输入。DC-CNN 的不同支路分别处理不同尺度的像素块,最后再进行综合处理、分类。

1.2.1 卷积神经网络

典型的卷积神经网络包括卷积层(Conv)、激活函数层、池化层(max pooling)、全连接层(full connection, FC)以及输出层。本文使用的激活函数为线性整流单元(rectified linear unit, ReLU),输出层使用的 softmax 函数。具体流程如图 4 所示。为了加速网络训练和抑制过拟合现象的发生,图中增加了批归一化(batch normalization, BN)层。




图 4 卷积神经网络基本结构

Fig. 4 Basic structure of convolutional neural network

1) 输入到卷积层的数据可以是未经处理的原图像,也可以是经过预处理之后的图像或者像元。数据经过卷积层进行卷积运算,从而得到输出特征图。

假设输入的图像为 X , 则卷积层输出的特征

图为

$$\mathbf{H} = \mathbf{X} \otimes \mathbf{w} + b \quad (1)$$

式中, $\mathbf{w}$ 表示权值, b 表示偏置, $\otimes$ 表示卷积符号, $\mathbf{H}$ 为输出的特征图。

2) BN 层的作用是调整各层的激活值分布, 使其具有适当的广度, 让学习模型能够顺利地进行学习。BN 层有以下优点:

- (1) 可以使学习更快进行;
- (2) 对于初始值的依赖降低;
- (3) 可以很好地抑制过拟合问题。

BN 层以学习时的样本批处理大小 (*Batchsize*) 为单位进行正规化, 使其数据分布为: 均值为 0、方差为 1。当 *Batchsize* = m 时, 其数学表达式为

$$\mu_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i \quad (2)$$

$$\sigma_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad (3)$$

$$\hat{x}_i \leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \quad (4)$$

式中, μ_B, σ_B^2 是 m 个输入数据的集合 $\mathbf{B} = \{x_1, x_2, \dots, x_m\}$ 的均值和方差, ε 是一个微小值, 防止除数为 0。通过式(4)将输入数据的分布变换为均值为 0、方差为 1 的数据 $\{\hat{x}_1, \hat{x}_2, \dots, \hat{x}_m\}$ 。

接着对正规化后的数据进行缩放和平移, 得到新的分布 $\{y_1, y_2, \dots, y_m\}$:

$$y_i \leftarrow \gamma \hat{x}_i + \beta \quad (5)$$

式中, γ 和 β 是需要学习的参数。

将整个 BN 过程整理为

$$y_i = BN(x_i) = \gamma \cdot \left(\frac{x_i - \mu(x_i)}{\sqrt{\sigma(x_i)^2 + \varepsilon}} \right) + \beta \quad (6)$$

3) 激活函数层的作用是将线性模型转变为可以逼近任意函数的非线性模型。本文使用的激活函数为 ReLU (rectified linear unit) 函数, 表达式为

$$ReLU(x) = \begin{cases} x & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (7)$$

使用 ReLU 函数的好处有:

- (1) 可以减少计算量;
- (2) 抑制梯度消失的情况;
- (3) 缓解过拟合问题。

4) 池化 (pooling) 包括最大值池化 (max pooling) 和平均池化 (average pooling), 它们的主要作用都是进行下采样, 另外也是对特征进行降维处理, 降

低网络复杂度, 减少计算量, 减小过拟合, 同时还能提高模型的容错率。最大值池化是通过定义一个空间邻域窗口, 并从窗口内的修正特征图中取出最大的像素值。而平均池化则是对空间邻域窗口内的修正特征图求平均像素值。二者中最大值池化被证明效果更好, 因此本文采用最大值池化。

5) 全连接层 (FC) 在卷积神经网络中的作用主要是整合卷积层提取到的抽象特征, 使其起到分类器的作用。

6) 最后的输出层使用的是 softmax 函数。softmax 函数可以将全连接层输出的特征进行归一化处理后再进行输出, 即

$$P_i = \frac{e^{y_i}}{\sum_{j=1}^T e^{y_j}}, \quad i = 1, 2, \dots, T \quad (8)$$

式中, $\mathbf{Y}$ 为 $\mathbf{X}$ 经过全连接层后的输出。

对于高光谱像元来说, 其所属类别可以表示为

$$class(\mathbf{X}) = \arg \max_{i=1, 2, \dots, T} P_i \quad (9)$$

1.2.2 双通道卷积神经网络 DC-CNN

单层的卷积神经网络的特征提取能力有限, 在这种不充分的特征提取的情况下对高光谱图像进行分类往往不能得到令人满意的结果。为了获得更深层次的、更充分的空间特征以及光谱特征, 需要增加卷积神经网络的层数, 加深其网络深度。但是随着网络深度的增加, 其计算时间也会大幅度增加。因此, 为了获取高光谱像元的更加真实、完善的空间特征以及光谱特征, 同时在保证其计算时间的基础上, 设计了双通道卷积神经网络。不同通道处理不同尺度的像素块, 针对中心像元获取更加充分的空谱特征, 最后进行综合处理。其中像素块分别为 3×3 和 5×5 两种尺度。为了方便描述, 将由一层卷积层、一层 BN 层以及一层激活函数层组成的结构称为一个卷积单元 (convolution unit), 如图 5。详细的 DC-CNN 网络结构如图 6 所示。




图5 卷积单元

Fig.5 Convolution unit




图6 DC-CNN 网络结构

Fig. 6 DC-CNN network structure

图6中, X, Y, b, c 分别代表输入高光谱像元、输出类属概率、高光谱图像波段数、高光谱图像类别数。 n 代表高光谱像元在经过前面一系列网络降维作用后的波段数, 计算过程为

$$n = \left\lfloor \frac{b - 44}{12} \right\rfloor \quad (10)$$

式中, $\lfloor \cdot \rfloor$ 表示取整, 该网络的损失函数为交叉熵误差函数, 即

$$Loss = -\frac{1}{N} \sum_n \sum_k t_{nk} \log y_{nk} \quad (11)$$

式中, 假设数据有 N 个, t_{nk}, y_{nk} 表示第 n 个数据的第 k 个元素的值 (y_{nk} 是神经网络的输出, t_{nk} 是监督数据)。

1.2.3 总体结构

综上, 本文提出了基于 DC-CNN 的高光谱图像分类方法, 实现了对高光谱像元更深层次的空谱结合特征的提取以及分类。如图7所示, 其总体结构由预处理、数据扩充和 DC-CNN 这3部分组成。




图7 本文方法总体结构

Fig. 7 Overall structure of the proposed method

首先将高光谱图像经过预处理使像元变换成包含一定空间信息的尺度为 3×3 以及 5×5 的像素块 (理论上像素块可以采用其他尺度, 并且可以推知, 尺度越大分类精度也会越高, 同时复杂度也会越高。出于对实验设备性能以及兼顾精度与复杂度的考虑, 本文选取了 3×3 和 5×5 的像素块) 作为待处理单元, 然后对待处理单元使用堆叠空间变换信息的

数据扩充方法进行数据扩充, 将扩充之后的数据集进行形状变换, 使其满足双通道卷积神经网络的输入维度。之后将不同大小的像素块分别输入到 DC-CNN 的不同尺度的支路卷积, 结合两个通道提取到的空谱特征进行训练, 以提高网络的泛化能力。

需要注意的是数据扩充方法只在训练过程中使用, 在测试过程中无需使用该方法。

2 实验数据及仿真分析

2.1 实验数据集介绍

实验使用的高光谱图像数据集为 Indian Pines 和 Pavia University 两个具有代表性的数据集来检验 DC-CNN 的分类性能。其中 Indian Pines 数据集中地物类别均为庄稼,不同类别之间的光谱曲线较为相似,而且样本分布并不均匀。又因其空间分辨率约为 20 m,所以有较多的混合像元,会对分类造成难度。而 Pavia University 数据集中的地物类别包括树、沥青道路和牧场等,光谱曲线区分更加明显,其空间分辨率为 1.3 m,所以混合像元较少,更容易正确分类。如表 1 所示,这两个数据集在使用的高光谱传感器、空间分辨率、波段数和数据集大小、样本种类等方面有较大差异,这样更能体现出本文方法的分类性能和泛化能力。

表 1 高光谱图像数据集
Table 1 Hyperspectral image dataset

	Indian Pines	Pavia University
成像光谱仪	AVIRIS	ROSIS
光谱范围/nm	400 ~ 2 500	430 ~ 860
波段数	200	103
像元数/像素	145 × 145	610 × 340
空间分辨率/m	20	1.3
样本数	10 249	42 776
地物类别数	16	9

2.2 实验环境及参数设置

本文实验的计算机具体配置为 Intel(R) Core (TM) i7-4710MQ CPU @ 2.50 GHz 处理器,8 GB 运行内存,NVIDIA GeForce GTX 965 M 显卡,4 GB 显存。软件环境为在 Windows7 下的 Python 3.8.3 和 tensorflow-gpu 2.3.0。

实验中模型的网络结构的参数设置如图 6 所示,对于不同的数据集除了输入、输出层需要在维度上进行必要的改动之外,其余参数保持不变,卷积步长皆为 1。在网络训练过程中,使用自适应学习速率的随机梯度下降优化方法 Adam (Kingma 和 Ba, 2015) 更新误差,其初始学习速率设置为 0.001,一次动量为 0.9,二次动量为 0.999。由于实验设备限

制,模型的批处理大小设置为 128,并且使用堆叠空间变换信息的数据扩充方法对训练样本进行 8 倍扩充。训练集和测试集分配的样本比例为 10% 和 90%,该数据集的划分是对每一类样本随机打散后按照比例进行抽取,保证了样本的随机性。并且,本文所有实验数据均为在随机划分数据集的情况下重复进行 5 次的实验结果的平均值。

为了对分类结果进行定量的对比、评价,需要引入一些评价指标。常用的评价指标有:总体分类精度 (overall accuracy, OA)、平均分类精度 (average accuracy, AA) 和 Kappa 系数。下面对这 3 个评价指标进行一些简单介绍。

1) 总体分类精度统计了正确分类样本的总数,可以直观地展示分类结果。计算为

$$OA = \frac{1}{N} \sum_{i=1}^c m_{ii} \quad (12)$$

2) 平均分类精度是统计每一类被正确分类的样本与该类样本总数的比值的均值。计算为

$$AA = \frac{1}{c} \sum_{i=1}^c \frac{m_{ii}}{N_i} \quad (13)$$

3) Kappa 系数也是一种基于混淆矩阵的计算精度的方法。计算为

$$Kappa = \frac{N \times \sum_{i=1}^c m_{ii} - \sum_{i=1}^c N \times m_{ii}}{N^2 - \sum_{i=1}^c N \times m_{ii}} \quad (14)$$

式中, c 表示总的类别数量, N_i 表示第 i 类的样本数量, N 表示样本总数量。 m 是一个大小为 $c \times c$ 的混淆矩阵,是由分类结果和地表真实值进行比较计算得出的。 m_{ij} 表示第 j 类被识别成第 i 的样本数。

2.3 实验仿真

为了验证本文方法的有效性,选取了目前国际上流行的 3 种高光谱图像分类方法与本文方法进行对比。这 3 种方法分别是 2D 卷积神经网络 (2D-CNN) (Makantasis 等, 2015)、3D 卷积神经网络 (3D-CNN) (李冠东 等, 2019) 和孪生神经网络 (SNN) (Zhao 等, 2018),在这些方法对应的文献中都通过仿真实验验证了这 3 种方法在一定程度上表现出良好的分类性能,因此本文选取这 3 种方法作为对比实验,并且对于每种算法除训练样本及测试样本数量与原文不同之外,其他参数保持不变。另外,本文设计了一种堆叠空间变换信息的数据扩充方法,在很少训练样本的情况下可以获得更充分的空间信

息,有利于网络模型学习更丰富的特征。为了验证该方法的有效性,将额外对比使用该方法的 DC-CNN 与不用该方法的 DC-CNN (no data expansion) 在相同的数据集下的分类性能的差异。

2.3.1 Indian Pines 数据集

Indian Pines 数据集的地表真实值以及不同分类算法在 Indian Pines 数据集的分类结果在经过可视化处理后如图 8 所示。对每种算法的分类精度进行计算,整理如表 2。从图 8 中可以看出,2D-CNN (图 8(b))的方法虽然在整体上对各个类别有所区分,但是产生许多“斑点”,这是因为 2D-CNN 不能

很好地结合高光谱的空间信息和光谱信息。而 3D-CNN(图 8(c))的方法由于更好地结合了高光谱图像的空谱信息,因此“斑点”现象明显减少。通过 SNN(图 8(e))与图 8 (a)的对比,可以看出此时已经有了很好的分类效果,错分现象明显减少,这是由深层残差网络的深层次特征提取所带来的改进。通过与其他方法对比,可以清晰地看出,本文 DC-CNN (图 8(f))方法错误点极少,最大程度上完成了对原高光谱图像的分类。而在图 8 (d)中,因为没有加入堆叠空间变换信息的数据扩充方法,导致模型对高光谱图像的空间信息的提取并不充分,因此误差稍大。




图 8 Indian Pines 高光谱图像不同方法的分类结果

Fig. 8 Results of classification for Indian Pines dataset

((a) ground truth; (b) 2D-CNN; (c) 3D-CNN; (d) DC-CNN (no data expansion); (e) SNN; (f) DC-CNN)

表 2 Indian Pines 高光谱遥感影像数据集分类精度

Table 2 Classification accuracy of Indian Pines hyperspectral remote sensing image dataset

类别	样本总数	训练样本	测试样本	对比方法分类精度/%				
				2D-CNN	3D-CNN	DC-CNN (no data expansion)	SNN	DC-CNN
Alfalfa	46	5	41	93.47	95.65	97.83	97.83	97.83
Corn-notill	1 428	143	1 285	69.38	95.73	87.75	96.92	98.46
Cornmintill	830	83	747	94.58	87.35	93.73	96.27	97.23
Corn	237	24	213	70.89	97.47	94.94	99.58	100.0
Grass-pasture	483	49	434	31.47	95.65	97.52	96.48	98.14
Grass-trees	730	73	657	95.34	99.59	99.45	99.73	99.32
Grass-pasture-mowed	28	3	25	96.43	78.57	96.43	96.43	96.43
Hay-windrowed	478	48	430	96.65	98.33	95.61	99.80	100.0
Oats	20	2	18	95.00	95.00	100.0	100.0	100.0
Soybean-notill	972	98	874	80.25	91.56	97.53	96.81	99.28
xSoybean-mintill	2 455	246	2 209	96.54	94.13	94.95	95.76	97.31
Soybean-clean	593	60	533	88.36	89.88	98.65	99.16	98.82
Wheat	205	21	184	99.51	99.51	100.0	100.0	100.0
Woods	1 265	127	1 138	99.05	98.58	98.34	99.68	98.18
Buildings-Grass-Trees-Drives	386	39	347	95.85	85.23	90.93	96.89	98.70
Stone-Steel-Towers	93	10	83	100.0	100.0	98.92	98.92	100.0
总体分类精度 OA/%				87.19	94.39	95.22	97.51	98.34
平均分类精度 AA/%				89.52	93.06	93.47	96.63	97.88
Kappa				0.853 3	0.936 0	0.945 6	0.971 6	0.981 1

通过对比不同算法对每种类别的分类精度可以发现,在训练样本较少的 Alfalfa、Grass-pasture-mowed 和 Oats 等小样本类别中,DC-CNN 都表现出了比 2D-CNN、3D-CNN 更优秀的分类性能,而面对 Alfalfa 样本在数据扩充前后分类精度不变的情况可能是由于总体样本数量过少导致的,属于正常情况。在 Corn、Hay-windrowed 等类别中更是达到了 100% 的分类精度,比其他算法都要优秀。而且,DC-CNN 方法提高总体分类精度、平均分类精度和 Kappa 系数的幅度比较明显。与 2D-CNN 相比,总体分类精度提高了 11.15%,平均分类精度提高了 8.36%,Kappa 系数提高了 0.127 8。与分类效果较为理想的 SNN 相比,总体分类精度提高了 0.83%,平均分类精度提高了 1.25%,Kappa 系数提高了 0.009 5。另外,使用堆叠空间变换信息的数据扩充方法比不使用该方法,在总体分类精度上有 3.12% 的提升,在平均分类精度上有 4.41% 的提升,Kappa 系数也提升了 0.035 5。这些实验结果充分表明了 DC-CNN 在高光谱图像分类中的有效性及准确性。也表明了堆叠空间变换信息的数据扩充方法的有效性。

2.3.2 Pavia University 数据集

图 9 展示了 Pavia University 数据集的地表真实值以及不同算法在 Pavia University 数据集下的分类结果的可视化图像。其对应的评价指标如表 3 所示。通过图 9(f) 与图 9(b)、图 9(c) 与图 9(e) 的对

比可以清晰地看出,图 9(b)、图 9(c) 和图 9(e) 都有明显的错分现象,在许多位置表现出混乱、驳杂的分类结果,而图 9(f) 中整体更加平滑,没有明显的“斑点”现象,错分点少,表现出了良好的分类结果。这说明在 Pavia University 数据集上,相比其他分类方法,DC-CNN 方法有更加精确的分类性能。并且由图 9(d) 与图 9(f) 的对比可知,在加入堆叠空间变换信息的数据扩充方法的情况下确实会对模型的性能有所提升,又一次验证了堆叠空间变换信息的数据扩充方法的有效性。通过表 3,对比 Gravel、Bare Soil 和 Bitumen 等光谱曲线区分更加明显的类别的分类结果可以看出,DC-CNN 方法有着比其他方法更高的分类精度,这是因为 DC-CNN 方法深度结合高光谱图像的空谱特征,实现了更加准确的分类。而且,本文方法对 Pavia University 数据集分类的总体分类精度达到了 99.63%,比 SNN 方法提高了 3.43%,比 DC-CNN(no data expansion) 提高了 5.36%;平均分类精度达到了 99.59%,比 SNN 方法提高了 4.20%,比 DC-CNN(no data expansion) 提高了 5.43%;Kappa 系数达到了 0.995 1,比 SNN 方法提高了 0.033 5,比 DC-CNN(no data expansion) 提高了 0.070 7。相比于 2D-CNN 和 3D-CNN,本文方法提升更加显著。由此可见,在处理高光谱图像分类的问题中,本文方法相比于其他方法有更加高效、准确的分类性能。




图 9 Pavia University 高光谱图像不同方法的分类结果

Fig. 9 The results of classification for Pavia University datasets

((a) ground truth; (b) 2D-CNN; (c) 3D-CNN; (d) DC-CNN(no data expansion); (e) SNN; (f) DC-CNN)

2.3.3 运行时间对比

表 4 和表 5 统计了不同深度学习模型在不同数据集下的训练时间以及测试时间。通过横向对比可以明确,样本数越多的数据集计算时间越长。通过

纵向对比可以看出,本文方法在训练过程中耗时较长,这是由训练过程中的数据扩充造成的。而在测试过程中,本文方法在不同数据集上的运行时间要短于 SNN 方法,表明本文方法在训练模型确定后有

表 3 Pavia University 高光谱遥感影像数据集分类精度
Table 3 Classification accuracy of hyperspectral remote sensing image dataset of Pavia University

类别	样本总数	训练样本	测试样本	对比方法分类精度/%				
				2D-CNN	3D-CNN	DC-CNN (no data expansion)	SNN	DC-CNN
Asphalt	6 631	664	5 967	96.55	94.12	98.40	96.02	99.89
Meadows	18 649	1 865	16 784	82.72	97.58	95.87	98.32	99.62
Gravel	2 099	210	1 889	65.51	65.13	73.56	85.56	98.19
Trees	3 064	307	2 757	98.47	95.40	94.97	96.17	99.97
Painted metal sheels	1 345	135	1 210	100.0	99.11	100.0	100.0	100.0
Bare Soil	5 029	503	4 526	97.40	77.85	92.01	94.45	99.88
Bitumen	1 330	133	1 197	95.41	82.03	88.65	90.60	98.57
Self-Blocking Bricks	3 682	369	3 313	58.80	88.92	91.77	94.24	99.59
Shadows	947	95	852	99.26	97.89	99.26	98.94	100.0
总体分类精度 OA/%				86.12	91.80	94.27	96.20	99.63
平均分类精度 AA/%				87.88	92.01	94.16	95.39	99.59
Kappa				0.820 3	0.890 6	0.924 4	0.959 6	0.995 1

表 4 各算法训练时间对比
Table 4 Comparison of training time of each algorithm /h

方法	Indian Pines	Pavia University
2D-CNN	1.2	1.5
3D-CNN	1.8	2.5
DC-CNN (no data expansion)	3	4
SNN	6	7
DC-CNN	12.5	16.5

表 5 各算法测试时间对比
Table 5 Test time comparison of each algorithm /s

方法	Indian Pines	Pavia University
2D-CNN	2.64	5.22
3D-CNN	3.31	7.58
DC-CNN (no data expansion)	8.11	12.27
SNN	24.63	31.97
DC-CNN	9.24	12.84

更高效的分类效果。

2.3.4 不同卷积层数对实验的影响

在深度卷积神经网络模型中,卷积层的数量是一个重要参数,会直接影响模型的分类性能。为确定双通道卷积神经网络在不同数量的卷积层的情况下对高光谱图像分类性能的影响,在 Indian Pines 数据集和 Pavia University 数据集上也分别进行了不同数量的卷积层的实验。模型在不同卷积层数时对高光谱图像分类的总体分类精度的折线图如图 10 所示。由图 10 可知,当卷积层数小于 5 时,总体分类精度随着卷积层数的增加而升高,在卷积层数为 5 时总体分类精度达到最大值,当卷积层数大于 5 时,总体分类精度又随之下降。造成这种现象的原因可




图 10 卷积层数对分类结果的影响
Fig. 10 Influence of convolution layers on classification results

能是卷积层数少的网络提取高光谱图像的复杂深层特征的能力较差,导致精度不高;而卷积层数过多导致网络过于复杂,造成过拟合问题使得精度下降。因此,5层卷积层的双通道卷积神经网络的分类性能最优,故模型设定为5层卷积层。

3 结 论

本文针对训练样本数量有限的高光谱图像分类模型性能不理想的问题,提出了一种堆叠像元邻域空间信息的数据扩充方法,并设计了一种基于双通道卷积神经网络的高光谱图像分类方法,称为DC-CNN。堆叠像元邻域空间信息的数据扩充方法通过对不同尺度像素块进行空间旋转、变换,以扩充训练样本的数量,以及获取中心像元隐藏的空间信息。该方法同时解决了深度模型训练样本不足的问题和特征提取过程中高光谱图像的空间信息提取不充分的情况。再通过DC-CNN网络框架输入不同尺度的像素块,来综合提取更加丰富的空间信息,完成深层的空谱信息提取,最后将融合之后的空谱特征输入到softmax分类器,从而实现更加准确的分类。

此外,本文分析了不同卷积层数对分类性能的影响,验证了由5层卷积层组成的卷积神经网络对高光谱图像的特征提取能力最强。实验表明,本文方法在两组差异较大的真实高光谱图像数据集上均表现出良好的分类性能,说明本文方法具有一定的泛化能力,并在运行时间上有一定优势。本文利用双通道卷积神经网络完成了对高光谱图像的深层次的空谱特征的融合,充分提取了高光谱图像中的潜藏信息,有利于深度学习模型在高光谱图像分类中的应用。在后续的研究中,可以进一步探索多通道卷积神经网络,如三通道、四通道卷积神经网络在高光谱图像分类问题中的效果,促进深度学习方法在高光谱图像中的应用。

参考文献 (References)

- Bandos T V, Bruzzone L and Camps-Valls G. 2009. Classification of hyperspectral images with regularized linear discriminant analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3): 862-873 [DOI: 10.1109/TGRS.2008.2005729]
- Chen Y S, Jiang H L, Li C Y, Jia X P and Ghamisi P. 2016. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 54(10): 6232-6251 [DOI: 10.1109/TGRS.2016.2584107]
- Chen Y S, Lin Z H, Zhao X, Wang G and Gu Y F. 2014. Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6): 2094-2107 [DOI: 10.1109/JSTARS.2014.2329330]
- Chen Y S, Zhao X and Jia X P. 2015. Spectral-spatial classification of hyperspectral data based on deep belief network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6): 2381-2392 [DOI: 10.1109/JSTARS.2015.2388577]
- Du P J, Xia J S, Xue Z H, Tan K, Su H J and Bao R. 2016. Review of hyperspectral remote sensing image classification. *Journal of Remote Sensing*, 20(2): 236-256 (杜培军, 夏俊士, 薛朝辉, 谭琨, 苏红军, 鲍蕊. 2016. 高光谱遥感影像分类研究进展. *遥感学报*, 20(2): 236-256) [DOI: 10.11834/jrs.20165022]
- He M Y, Li B and Chen H H. 2017. Multi-scale 3D deep convolutional neural network for hyperspectral image classification//*Proceedings of 2017 IEEE International Conference on Image Processing (ICIP)*. Beijing, China: IEEE: 57-61 [DOI: 10.1109/ICIP.2017.8297014]
- Hu W, Huang Y Y, Wei L, Zhang F and Li H C. 2015. Deep convolutional neural networks for hyperspectral image classification. *Journal of Sensors*, 2015: #258619 [DOI: 10.1155/2015/258619]
- Kingma D P and Ba J. 2015. Adam: a method for stochastic optimization//*Proceedings of the 3rd International Conference on Learning Representations*. San Diego, USA: [s. n.]: 58-73
- Li G D, Zhang C J, Gao F and Zhang X Y. 2019. Doubleconvpool-structured 3D-CNN for hyperspectral remote sensing image classification. *Journal of Image and Graphics*, 24(4): 639-654 (李冠东, 张春菊, 高飞, 张雪英. 2019. 双卷积池化结构的3D-CNN高光谱遥感影像分类方法. *中国图象图形学报*, 24(4): 639-654) [DOI: 10.11834/jig.180422]
- Li W, Wu G D, Zhang F and Du Q. 2017b. Hyperspectral image classification using deep pixel-pair features. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2): 844-853 [DOI: 10.1109/TGRS.2016.2616355]
- Li Y, Zhang H K and Shen Q. 2017a. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network. *Remote Sensing*, 9(1): #67 [DOI: 10.1080/2150704X.2017.1280200]
- Licciardi G, Marpu P R, Chanussot J and Benediktsson J A. 2012. Linear versus nonlinear PCA for the classification of hyperspectral data based on the extended morphological profiles. *IEEE Geoscience and Remote Sensing Letters*, 9(3): 447-451 [DOI: 10.1109/LGRS.2011.2172185]
- Makantasis K, Karantzalos K, Doulamis A and Doulamis N. 2015. Deep supervised learning for hyperspectral data classification through convolutional neural networks//2015 IEEE International Geoscience

and Remote Sensing Symposium (IGARSS). Milan, Italy: IEEE: 4959-4962 [DOI: 10.1109/IGARSS.2015.7326945]

Qi Y F, Chen J, Huo Y L and Li F Y. 2020. Hyperspectral image classification algorithm based on multiscale convolutional neural network. *Infrared Technology*, 42(9): 855-862 (齐永锋, 陈静, 火元莲, 李发勇. 2020. 基于多尺度卷积神经网络的高光谱图像分类算法. *红外技术*, 42(9): 855-862)

Villa A, Benediktsson J A, Chanussot J and Jutten C. 2011. Hyperspectral image classification with independent component discriminant analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 49(12): 4865-4876 [DOI: 10.1109/TGRS.2011.2153861]

Wang L G, Zhao L and Liu D F. 2018. A review on the application of SVM in hyperspectral image processing. *Journal of Harbin Engineering University*, 39(6): 973-983 (王立国, 赵亮, 刘丹凤. 2018. SVM 在高光谱图像处理中的应用综述. *哈尔滨工程大学学报*, 39(6): 973-983) [DOI: 10.11990/jheu.201704074]

Yang G F, Gewali U B, Ientilucci E, Gartley M and Monteiro S T. 2018. Dual-channel densenet for hyperspectral image classification//2018 IEEE International Geoscience and Remote Sensing Symposium. Valencia, Spain: IEEE: 2595-2598 [DOI: 10.1109/IGARSS.2018.8517520]

Zhao S Z, Li W, Du Q and Ran Q. 2018. Hyperspectral classification based on Siamese neural network using spectral-spatial feature//2018 IEEE International Geoscience and Remote Sensing Symposium. Valencia, Spain: IEEE: 2567-2570 [DOI: 10.1109/IGARSS.2018.8519286]

作者简介



吴鸿昊, 1999 年生, 男, 硕士研究生, 主要研究方向为高光谱数据处理技术。

E-mail: 1067909839@qq.com



王立国, 通信作者, 男, 教授, 博士生导师, 主要研究方向为高光谱数据处理技术、机器学习理论。

E-mail: wangliguo@hrbeu.edu.cn

石瑶, 女, 博士研究生, 主要研究方向为机器学习和遥感图像处理。E-mail: shiyao@hrbeu.edu.cn