

百种中国杰出学术期刊

# 遥感学报

Yaogan Xuebao

第 24 卷 第 8 期 2020 年 8 月

目 次

## 研究进展

海洋一号 C 星光学载荷对海面溢油的识别能力分析 ..... 沈亚峰, 刘建强, 丁静, 焦俊男, 孙绍杰, 陆应诚 (933)

## 综述

日光诱导叶绿素荧光辐射传输模型研究进展 ..... 詹春晖, 章钊颖, 张永光 (945)

地表反射率地形校正物理模型与效果评价方法研究进展 .....  
..... 林兴稳, 闻建光, 吴胜标, 郝大磊, 肖青, 柳钦火 (958)

## 博士论坛

遥感估算地表蒸散发真实性检验研究进展 ..... 张圆,  
贾贞贞, 刘绍民, 徐自为, 徐同仁, 姚云军, 马燕飞, 宋立生, 李相, 胡晓, 王泽宇, 郭枝虾, 周纪 (975)  
联合局部二值模式的 CNN 高光谱图像分类 ..... 魏祥坡, 余旭初, 张鹏强, 职露, 杨帆 (1000)

## 技术方法

ASTER GDEM V2 的南极冰川高程误差校正及精度分析 .....  
..... 陈昊楠, 许诗枫, 黄艳, 王淑杰, 舒松, 余柏菡, 吴健平 (1010)

风云二号多通道卫星数据对流单体检测 ..... 刘佳, 罗向阳 (1023)

## 遥感应用

FY-3B/MWRI 与 GCOM-W1/AMSR-2 亮温数据在北极地区的交叉定标 .....  
..... 唐晓彤, 陈海花, 管磊, 李乐乐 (1032)

泛北极地区多年冻土活动层厚度演变 ..... 蔡红艳, 韩冬锐, 杨林生, 陈慕琳, 杨小唤 (1045)

本期责任编辑: 李薇

《遥感学报》网络版: [www.jors.cn](http://www.jors.cn)

《遥感学报》微信公众号及官网



订阅号



官网

# JOURNAL OF REMOTE SENSING (Chinese)

(Vol. 24 No.8 August, 2020)

## CONTENTS

### Research Progress

HY-1C COCTS and CZI observation of marine oil spills in the South China Sea .....  
..... *SHEN Yafeng, LIU Jianqiang, DING Jing, JIAO Junnan, SUN Shaojie, LU Yingcheng* (944)

### Review

Recent advances in the radiative transfer models of sun-induced chlorophyll fluorescence .....  
..... *ZHAN Chunhui, ZHANG Zhaoying, ZHANG Yongguang* (957)

Advances in topographic correction methods for optical remote sensing imageries .....  
..... *LIN Xingwen, WEN Jianguang, WU Shengbiao, HAO Dalei, XIAO Qing, LIU Qinhuo* (974)

### Doctor's Voice

Advances in validation of remotely sensed land surface evapotranspiration .....  
..... *ZHANG Yuan, JIA Zhenzhen, LIU Shaomin, XU Ziwei, XU Tongren,*  
*YAO Yunjun, MA Yanfei, SONG Lisheng, LI Xiang, HU Xiao, WANG Zeyu, GUO Zhixia, ZHOU Ji* (998)

CNN with local binary patterns for hyperspectral images classification .....  
..... *WEI Xiangpo, YU Xuchu, ZHANG Pengqiang, ZHI Lu, YANG Fan* (1008)

### Technology and Methodology

Vertical accuracy correction and analysis of ASTER GDEM V2 over Antarctic Glacier .....  
..... *CHEN Haonan, XU Shifeng, HUANG Yan, WANG Shujie, SHU Song, YU Bailang, WU Jianping* (1022)

Detection of convective cells using multi-channel satellite data from FY-2 ..... *LIU Jia, LUO Xiangyang* (1031)

### Remote Sensing Applications

Intercalibration of FY-3B/MWRI and GCOM-W1/AMSR-2 brightness temperature over the Arctic .....  
..... *TANG Xiaotong, CHEN Haihua, GUAN Lei, LI Lele* (1044)

Spatiotemporal change in permafrost active layer thickness in the Pan-Arctic region .....  
..... *CAI Hongyan, HAN Dongrui, YANG Linsheng, CHEN Mulin, YANG Xiaohuan* (1057)

# 联合局部二值模式的 CNN 高光谱图像分类

魏祥坡, 余旭初, 张鹏强, 职露, 杨帆

信息工程大学, 郑州 450001

**摘要:** 卷积神经网络 CNN (Convolutional Neural Networks) 具有强大的特征提取能力, 应用于高光谱图像特征提取取得了良好的效果, 双通道 CNN 模型能够分别提取高光谱图像的光谱特征和空间特征, 并实现了特征的决策级融合。局部二值模式 LBP (Local Binary Patterns) 是一种简单但有效的空间特征描述算子, 能够减轻 CNN 特征提取的压力并提高分类精度。为了充分利用 CNN 的特征提取能力及 LBP 特征的判别能力, 提出一种双通道 CNN 和 LBP 相结合的高光谱图像分类方法, 首先, 采用 1 维 CNN (1D-CNN) 模型处理原始高光谱数据提取深层光谱特征, 同时采用另一个 1D-CNN 模型处理 LBP 特征数据进一步提取深层空间特征, 然后, 将两个 CNN 模型的全连接层进行连接, 实现深层光谱特征和空间特征的融合, 并将融合特征输入到分类层中完成分类。实验结果表明, 该方法在 Indian Pines 数据、Pavia University 数据及 Salinas 数据上能够分别取得 98.54%、99.73%、99.56% 的分类精度, 甚至在有限数量的训练样本条件下也能取得较好的分类效果。

**关键词:** 遥感, 高光谱图像, 分类, 卷积神经网络, 深度学习, 局部二值模式

**引用格式:** 魏祥坡, 余旭初, 张鹏强, 职露, 杨帆. 2020. 联合局部二值模式的 CNN 高光谱图像分类. 遥感学报, 24(8): 1000-1009  
Wei X P, Yu X C, Zhang P Q, Zhi L and Yang F. 2020. CNN with local binary patterns for hyperspectral images classification. Journal of Remote Sensing(Chinese), 24(8): 1000-1009[DOI:10.11834/jrs.20208333]

## 1 引言

高光谱图像具有较高的光谱分辨率, 能够获取地物近似连续的波谱曲线, 得到地物的诊断性光谱特征, 从而提高了地物的识别能力, 高光谱图像分类作为高光谱遥感图像应用的重要方面, 已经广泛应用于植被调查、环境监测、矿物填图、精细农业等领域 (Bioucas-Dias 等, 2013), 取得了良好效果。然而, 由于高光谱图像存在复杂的空间光谱结构, 高维特性及相邻波段间较强的相关性, 高光谱图像分类仍存在较多困难。

因此, 如何从复杂图像结构中提取判别特征成为高光谱图像分类的研究难点。传统高光谱图像分类方法利用基于线性变换的特征提取方法, 如线性判别分析, 主成分分析等, 能够通过计算变换矩阵从光谱空间提取判别能力更强的特征。然而, 由于复杂的空间光谱结构, 高光谱图像内部呈现非线性结构, 利用非线性特征提取方法, 如多项式判别分析, 核方法等, 能够提取出更具

有判别力的非线性特征。

高光谱图像中存在同物异谱及同谱异物现象, 导致仅仅利用光谱信息不能实现精确分类。高光谱图像空间域上的邻近像元往往有着相似的光谱特征和相近的类别标签, 在特征提取和分类过程中加入空间信息能够有效降低分类的不确定性, 提高分类精度 (Plaza 等, 2009)。形态学特征 MP (Morphological Profiles) 能够通过多种数学形态学操作来提取图像的空间信息 (Pesaresi 和 Benediktsson, 2001)。混合核方法 CK (Composite Kernel,) 利用光谱特征和空间特征分别计算不同的核函数组成混合核, 也能有效实现光谱-空间特征分类 (Li 等, 2013)。另外, 马尔可夫随机场 MRF (Markov Random Fields) 通过对初始分类结果进行后处理, 加入空间信息, 能够有效优化分类结果 (Moser 和 Serpico, 2013)。然而, 这些方法存在特征简单、泛化性差等缺点, 不能有效提取图像的空间信息 (Shu 等, 2018)。

局部二值模式 LBP (Local Binary Pattern) 是

收稿日期: 2018-08-14; 预印本: 2018-11-07

基金项目: 河南省科技攻关计划项目(编号: 152102210014)

第一作者简介: 魏祥坡, 1991年生, 男, 博士研究生, 研究方向为遥感图像处理与分析。E-mail: 13526635671@163.com

一种简单但有效的纹理信息描述算子, 应用于人脸识别及纹理分类等取得了良好的效果 (张雯和王文伟, 2015; 冀中和聂林红, 2016)。LBP 用于高光谱图像空间特征提取及分类也取得了很好的效果, 叶珍和白璘 (2017) 通过对降维后的高光谱图像利用 LBP 提取空间特征, 采用稀疏表示和支持向量机对提取的特征进行分类, 能够有效提高分类精度。LBP 与混合核极限学习机联合也能有效实现光谱特征与空间特征的结合 (职露等, 2018)。另外, 将 LBP 提取的特征用于分类, 计算地物所属类别概率, 与 MRF 及超像素分割等后处理策略结合也能有效实现光谱—空间特征分类 (Ye 等, 2017; Jia 等, 2018)。

近年来, 深度学习凭借其分层学习框架在非线形特征提取方面取得了优异的效果。堆栈式自编码器 SAE (Stack Autoencoder) 和深度置信网络 DBN (Deep Belief Network) 最早用于高光谱图像光谱—空间特征提取和分类 (Chen 等, 2014, 2015), 但需要将 3 维数据转换为 1 维输入向量, 损失了空间信息。卷积神经网络 (CNN) 通过加入非线性激活函数, 能够有效提取非线性光谱—空间特征 (Chen 等, 2016), 双通道 CNN (DC-CNN) (Dual-channel CNN) 模型是一种分别提取光谱特征及空间特征的方法, 利用 1 维 CNN (1D-CNN) 和 2 维 CNN (2D-CNN) 分别提取深层光谱特征和深层空间特征, 不仅有效提取了图像中的特征而且实现了光谱特征和空间特征的决策级融合 (Zhang 等, 2017)。

LBP 提取的特征具有较强的判别能力, 与 CNN 结合能够减轻 CNN 特征提取的压力 (Chen 等, 2017), 为了充分利用 CNN 的特征提取能力和 LBP 提取特征的判别能力, 本文提出了一种双通道 CNN 与 LBP 相结合的高光谱图像分类方法, 定义为 LBP Dual-Channel CNN, LBP-DC-CNN。原始图像数据通过 1D-CNN 提取深层光谱特征, LBP 提取的特征通过 1D-CNN 进一步提取深层空间特征, 并连接两个模型的全连接层, 实现深层光谱特征和深层空间特征的融合, 最后将融合特征输入到分类层中完成高光谱图像的分类。通过与 SVM、CNN、2D-CNN、LBP-1D-CNN 及 DC-CNN 等方法在 3 组高光谱数据上进行分类对比试验, 验证本文方法设计的合理性, 并对比了不同方法的分类精度及在不同数量的训练样本情况下的精度变化。

## 2 基本原理

### 2.1 局部二值模式 LBP

LBP 是一种有效的局部空间特征非参数描述算子, 具有旋转不变性及平移不变性。对任一图像中给定像素  $(x_c, y_c)$ , 中心像素  $(x_c, y_c)$  与其 8 邻域像素灰度值进行比较后得到一个有序的二值集合, 定义为 LBP, 其中二值制码表示为 8 位二进制数的十进制形式:

$$\text{LBP}(x_c, y_c) = \sum_{n=0}^7 S(i_n - i_c) 2^n \quad (1)$$

式中,  $i_c$  表示中心像素  $(x_c, y_c)$  的灰度值,  $i_n$  表示中心像素 8 邻域内的像素灰度值。LBP 二值制码对任何单调的灰度变换具有不变性, 即变换前后保持局部邻域的二进制码不变。

$$S(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2)$$

图 1 为 8 邻域的 LBP 计算示例, 图 1 (a) 给出了  $3 \times 3$  窗口, 邻域像素灰度值与中心像素灰度值取差值, 如果大于零则为 1, 否则为零, 得到二值集, 其对应的二值编码为  $(\text{LBP})_2 = 10011100$ 。图 1 (c) 为二进制码的编码集, 相当于二进制码的加权系数集, 对应的 LBP 编码为  $(\text{LBP}) = 4+8+16+128 = 156$ 。

87	75	126	0	0	1	1	2	4
99	95	141	1		1	8		16
91	91	100	0	0	1	32	64	128
(a) 灰度图			(b) 二值集			(c) 编码集		
(a) Gray-scale map			(b) Binary value set			(c) Code set		

图 1 LBP 计算示例

Fig.1 Example of LBP calculation

LBP 编码仅和中心像素与邻域像素的灰度值之差有关, 共有 256 种模式, 反映了不同的纹理模式信息, LBP 编码通过将图像中任一像素的灰度值映射为 LBP 编码, 经直方图统计可以得到图像的 LBP 直方图描述图像的局部空间特征。

### 2.2 CNN 模型

CNN 模型通过对每个像素的邻域进行卷积及

池化操作，提取图像的深层特征。最初的深度CNN模型应用于2维图像，在图像分类领域取得了优于传统机器学习分类算法的结果，引发了CNN模型的研究热潮。

1D-CNN与2D-CNN基本原理相同，其主要区别在于卷积滤波和池化操作的维度，1D-CNN的卷积层中为1维卷积核（Hu等，2015），1维卷积滤波作用于1维的特征向量，计算公式如下

$$v_{l,j}^x = f\left(\sum_m \sum_{h=0}^{H_l-1} k_{l,j,m}^h v_{(l-1),m}^{(x+h)} + b_{l,j}\right) \quad (3)$$

式中， $v_{l,j}^x$ 为第 $l$ 层第 $j$ 个特征图中位置 $x$ 处的值； $f(\cdot)$ 为激活函数； $k_{l,j,m}^h$ 表示第 $l$ 层第 $j$ 个卷积核位置 $h$ 处的值，该卷积核与上一层输出的第 $m$ 个特征图相连； $H_l$ 表示卷积核的长度； $b_{l,j}$ 为偏置项。1维卷积滤波的原理如图2所示。

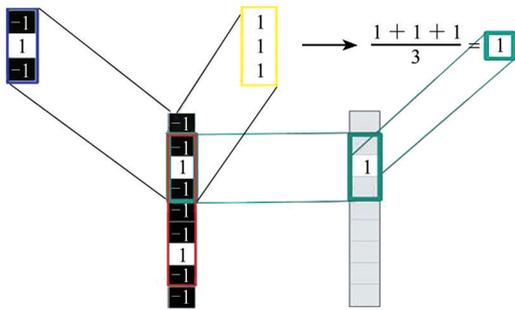


图2 1维卷积滤波原理示意图

Fig.2 Illustration of one-dimensional convolutional filters

池化层中的池化操作包括平均池化和最大池化等类型，往往出现在卷积层之后，作用于卷积层输出的特征图，可以减小特征图的尺寸，减少

参数数量。全连接层则是将提取的特征图转换输入到分类层中，完成分类操作。

### 2.3 基于LBP-DC-CNN的高光谱图像分类

基于LBP-DC-CNN的高光谱图像分类主要包括3部分：原始图像数据利用1D-CNN模型提取深层光谱特征，LBP提取的特征利用1D-CNN模型进一步提取深层空间特征，连接两个CNN模型的全连接层实现特征融合完成分类。1D-CNN模型包括两个卷积层和一个全连接层（网络模型调参将在3.2节讨论），如图3所示，1D-CNN模型处理图像上某个像元（点）的1维特征向量，第1个卷积层包含 $m$ 个大小为 $a$ 的卷积核，第2个卷积层包含 $2m$ 个大小为 $a$ 的卷积核，全连接层长度为 $n$ ，两个模型的全连接层分别作为深层光谱特征和深层空间特征，连接两个模型的全连接层实现特征融合，并将融合特征输入到Softmax分类层中完成分类。

ReLU函数作为卷积层的激活函数，能够解决传统的Sigmoid、Tanh等激活函数容易出现的梯度消失问题，而且收敛速度较快（Krizhevsky等，2012）。模型的优化函数采用Adam函数，能够较好地解决非凸优化及高维空间的数据处理问题（Kingma和Ba，2014）。Softmax函数作为分类层的分类函数有着计算简单、分类性能良好的优点。研究表明，在卷积层中 $3 \times 3$ 大小的卷积窗口能够获得较好的效果（Simonyan和Zisserman，2014），因此确定卷积核的大小为3。卷积操作的步长为1，能够尽可能捕捉图像的细节信息，全连接层的长度设为128。

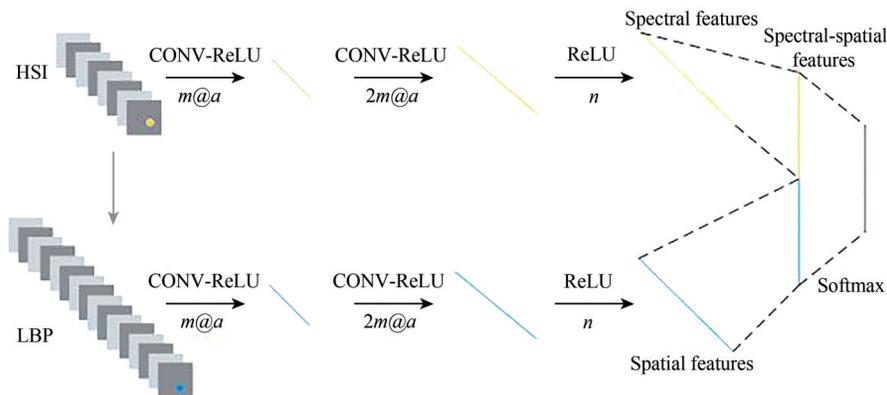


图3 LBP-DC-CNN原理示意图

Fig.3 Illustration of LBP-DC-CNN classification method

### 3 实验结果与分析

#### 3.1 实验数据

为了验证本文方法的合理性及有效性, 采用3组高光谱图像数据进行验证实验。实验是在PC机上实施, 配置为 Intel Core i7-4720HQ @ 2.6 GHz、Nvidia GeForce GTX 965M 和 16 GB 内存。Indian Pines 数据是由美国 AVIRIS 成像光谱仪获取的印第安纳州西北部某林区的图像, 图像大小 145 像素×145 像素, 去除水汽吸收波段后共 200 个波段, 图像中共有 16 类地物, 在实验中剔除真实样本数量较少的类别, 仅保留 9 类地物 (Li 等, 2017), 实验中训练样本和测试样本的数量如表 1 所示。Pavia University 数据是由德国 ROSIS 成像光谱仪获取的意大利帕维亚大学图像, 图像大小 610 像素×340 像素, 去除水汽吸收波段后共 103 波段, 空间分辨率 1.3 m, 图像共有 9 类地物, 其训练样本和测试样本数量如表 2 所示。Salinas 数据是由 AVIRIS 成像光谱仪获取的加利福尼亚州 Salinas 山谷地区附近的高光谱图像, 图像大小 512 像素×217 像素, 去除水汽吸收波段后共有 204 个波段, 空间分辨率 3.7 m。图像中共包含 16 类地物, 其训练样本和测试样本数量如表 3 所示。

表 1 Indian Pines 数据样本数量

Table 1 Number of samples used in Indian Pines

序号	类别	训练样本	测试样本
1	Corn-notill	200	1228
2	Corn-mintill	200	630
3	Grass-pasture	200	283
4	Grass-trees	200	530
5	Hay-windowed	200	278
6	Soybean-notill	200	772
7	Soybean-mintill	200	2255
8	Soybean-clean	200	393
9	Woods	200	1065
总和		1800	7434

#### 3.2 网络模型调参

在 CNN 模型中有很多重要的网络参数, 能够直接影响模型的性能, 比如学习率, 卷积核数量, 网络层数等。学习率能够决定反向传播过程的收敛速度, 影响模型训练效果。根据已有研究, 在实验中将 Indian Pines 数据、Pavia University 数据及

Salinas 数据对应的 CNN 模型的学习率分别设置为 0.001、0.01 及 0.001。

表 2 Pavia University 数据样本数量

Table 2 Number of samples used in Pavia University

序号	类别	训练样本	测试样本
1	Asphalt	200	6431
2	Meadows	200	18449
3	Gravel	200	1899
4	Trees	200	2864
5	Sheets	200	1145
6	Bare Soil	200	4829
7	Bitumen	200	1130
8	Bricks	200	3482
9	Shadows	200	747
总和		1800	40976

表 3 Salinas 数据样本数量

Table 3 Number of samples used in Salinas

序号	类别	训练样本	测试样本
1	Brocoli_weeds_1	200	1809
2	Brocoli_weeds_2	200	3526
3	Fallow	200	1776
4	Fallow_rough_plow	200	1194
5	Fallow_smooth	200	2478
6	Stubble	200	3759
7	Celery	200	3379
8	Grapes_untrained	200	11071
9	Soil_vinyard_develop	200	6003
10	Corn_senesced_weeds	200	3078
11	Lettuce_romaine_4wk	200	868
12	Lettuce_romaine_5wk	200	1727
13	Lettuce_romaine_6wk	200	716
14	Lettuce_romaine_7wk	200	870
15	Vinyard_untrained	200	7068
16	Vinyard_vertical_trellis	200	1607
总和		3200	50929

(1) 卷积核数量。首先测试不同的卷积核数量对模型性能的影响, 卷积核数量决定了卷积层输出特征图的数量, 首先设定 1D-CNN 模型包含两个卷积层、两个最大池化层和 1 个全连接层, 分别测试第 1 个卷积层卷积核数量为 4、8、16、32 时模型分类精度, 3 组数据的分类结果如表 4 所示, 表中加粗数字表示最佳精度。从表 4 中可以看出卷积核数量对分类精度的影响并不大, 因此在实验中分别针对 Indian Pines 数据、Pavia University

数据及 Salinas 数据对应的 CNN 模型, 分别设置其第一卷积层的卷积核数量为 16、8 和 16。

表 4 不同卷积核数量的分类精度

Table 4 Overall accuracies of different conv filters

数据	卷积核数量			
	4	8	16	32
IN	98.32	98.20	<b>98.35</b>	98.33
PU	98.92	<b>99.09</b>	99.02	98.74
SA	98.63	98.82	<b>98.89</b>	98.67

注: 加粗数字表示最佳精度, IN (Indian Pines), PU (Pavia University), SA (Salinas)。

(2) 网络层数。其次测试不同的网络层数对分类精度的影响, 首先设定 3 组数据对应的模型第 1 卷积层的卷积核数量后, 分别测试网络层数为 3、5、7、9 时模型分类精度及时间, 除最后一层为全连接层外, 模型中均为卷积层和池化层交叉, 3 组数据的分类结果如表 5 所示。从表 5 中可以看出, 由于深层神经网络更容易出现梯度消失问题, 随着网络层数的增加, 分类精度缓慢下降, 因此针对 Indian Pines 数据、Pavia University 数据及 Salinas 数据对应的 CNN 模型, 分别设置其网络层数为 3、3 和 3。

表 5 不同网络层数的分类精度

Table 5 Overall accuracies of different network depth

数据	网络层数			
	3	5	7	9
IN	<b>98.46</b>	98.35	98.17	97.88
PU	<b>99.21</b>	99.09	97.59	96.33
SA	<b>99.16</b>	98.89	98.32	97.18

注: 加粗数字表示最佳精度, IN (Indian Pines), PU (Pavia University), SA (Salinas)。

(3) 最大池化层。最后测试最大池化层对分类精度的影响, 对应 Indian Pines 数据、Pavia University 数据及 Salinas 数据的 CNN 模型的网络参数, 第一卷积层卷积核数量分别为 16、8 和 16, 网络层数均为 3。测试网络模型中是否包含最大池化层对分类精度的影响。实验结果如表 6 所示, 表中加粗数字表示最佳精度。可以看出, 不含最大池化层的 CNN 模型能够提高分类精度, 因此 LBP-DC-CNN 中 1D-CNN 模型的结构为两个卷积层和一个全连接层。

表 6 有无最大池化层的分类精度

Table 6 Overall accuracies with or without max pooling layer

数据	有最大池化层	无最大池化层
IN	98.46	<b>98.54</b>
PU	99.21	<b>99.73</b>
SA	99.16	<b>99.56</b>

注: 加粗数字表示最佳精度, IN (Indian Pines), PU (Pavia University), SA (Salinas)。

### 3.3 实验结果与分析

为了更好地评价 LBP-DC-CNN 方法的分类性能, 将 LBP-DC-CNN 与多个分类方法进行对比, 传统支持向量机 (SVM) 分类器, 采用 RBF 核函数, 并设置核参数  $\lambda$  和惩罚系数  $c$  分别为 2 和 16。CNN 模型 (Hu 等, 2015) 以及 2D-CNN 模型也作为对比方法, 其中 2D-CNN 模型的输入邻域大小设置为  $9 \times 9$ 。为了验证双通道 CNN 模型的优势, 将基于 LBP 与 1D-CNN 的分类方法作为对比, 即 LBP-1D-CNN。同时, 为了验证 LBP 提取特征的判别能力, DC-CNN (Zhang 等, 2017) 也用作对比方法。在分类过程中, 每个分类器的训练样本数量均为 200。评价指标采用单个地物的分类精度及总体精度 OA (Overall Accuracy), 总体精度可以由正确分类的地物样本的数量总和除以测试样本数量总和, 产生的百分位数加以表示。

表 7—表 9 列出了 3 组实验数据的分类精度, 表中加粗数字为同一行中的最高值, 可以看出 LBP-DC-CNN 的分类精度要明显优于对比方法。通过对比分析, 可以得出以下结论:

(1) LBP-DC-CNN 方法能够取得比 LBP-CNN 和 DC-CNN 更高的分类精度, 证明了 CNN 模型的特征提取能力和 LBP 提取特征的判别能力。LBP-DC-CNN 方法比 DC-CNN 方法分类精度更高, 证明了 LBP 提取的特征比 2D-CNN 提取的空间特征更有优势; LBP-DC-CNN 方法比 LBP-CNN 方法分类精度更高, 验证了双通道 CNN 模型的合理性。

(2) LBP-DC-CNN 方法的总体精度明显优于各个对比方法的总体精度。针对 Indian Pines 数据, LBP-DC-CNN 的总体精度达到 98.54%, 相比 DC-CNN 提高 2%, 相比 LBP-CNN 提高 4%; 针对 Pavia University 数据, LBP-DC-CNN 的总体精度达

到99.73%, 相比DC-CNN提高1%, 相比LBP-CNN提高4%; 针对Salinas数据, LBP-DC-CNN的总体精度达到99.56%, 相比DC-CNN提高2%, 相比LBP-CNN提高5%。

表7 Indian Pines数据单类地物分类精度及总体精度  
Table 7 Class-specific accuracy and overall accuracy of the Indian Pines data

								/%
序号	类别	SVM	CNN	2D-CNN	LBP-CNN	DC-CNN	LBP-DC-CNN	
1	Corn-notill	83.61	78.58	80.18	90.89	97.06	<b>98.53</b>	
2	Corn-mintill	87.23	85.23	91.56	97.22	96.63	<b>98.43</b>	
3	Grass-pasture	98.34	95.75	99.37	95.85	95.65	<b>100.0</b>	
4	Grass-trees	99.73	99.81	99.17	98.76	<b>99.86</b>	97.95	
5	Hay-windowed	100.0	99.64	100.0	100.0	100.0	100.0	
6	Soybean-notill	88.17	89.63	94.23	93.93	93.72	<b>99.28</b>	
7	Soybean-mintill	76.58	81.55	86.68	91.20	94.70	<b>97.92</b>	
8	Soybean-clean	94.94	95.42	95.27	96.62	<b>97.13</b>	96.63	
9	Woods	98.89	98.59	98.89	99.28	<b>99.45</b>	99.37	
OA		88.26	86.44	91.47	94.74	96.68	<b>98.54</b>	

注: 加粗数字表示最佳精度。

表8 Pavia University数据单类地物分类精度及总体精度  
Table 8 Class-specific accuracy and overall accuracy of the Pavia University data

								/%
序号	类别	SVM	CNN	2D-CNN	LBP-CNN	DC-CNN	LBP-DC-CNN	
1	Asphalt	86.46	88.38	91.25	90.24	95.75	<b>99.09</b>	
2	Meadows	90.17	91.27	95.06	97.25	<b>99.86</b>	99.79	
3	Gravel	85.04	85.88	94.56	97.42	99.29	<b>99.52</b>	
4	Trees	96.64	97.24	98.75	89.55	98.83	<b>99.80</b>	
5	Sheets	99.78	99.91	100.0	99.70	100.0	100.0	
6	Bare Soil	94.89	96.41	95.16	99.22	96.84	<b>100.0</b>	
7	Bitumen	95.19	93.62	97.06	99.32	<b>99.92</b>	99.69	
8	Bricks	85.36	87.45	92.36	97.55	99.48	<b>99.83</b>	
9	Shadows	99.89	99.57	99.68	99.68	100.0	100.0	
OA		90.62	92.27	94.82	95.92	98.74	<b>99.73</b>	

注: 加粗数字表示最佳精度。

表9 Salinas数据单类地物分类精度及总体精度  
Table 9 Class-specific accuracy and overall accuracy of the Salinas data

								/%
序号	类别	SVM	CNN	2D-CNN	LBP-CNN	DC-CNN	LBP-DC-CNN	
1	Brocoli_weeds_1	99.60	97.34	99.80	99.70	98.16	<b>100.0</b>	
2	Brocoli_weeds_2	<b>100.0</b>	99.29	98.04	98.52	99.25	99.30	
3	Fallow	99.65	96.51	98.58	100.0	99.69	100.0	
4	Fallow_rough_plow	99.64	99.66	<b>100.0</b>	99.86	99.57	99.93	
5	Fallow_smooth	98.39	96.97	99.51	97.91	95.37	<b>99.81</b>	
6	Stubble	99.70	99.60	99.97	97.32	100.0	100.0	
7	Celery	<b>99.72</b>	99.49	99.11	96.14	97.51	99.69	
8	Grapes_untrained	84.38	72.25	76.80	82.15	92.32	<b>98.70</b>	
9	Soil_vinyard_develop	99.65	97.53	99.60	98.31	99.77	<b>99.98</b>	
10	Corn_senesced_weeds	96.74	91.29	95.39	92.46	96.37	<b>99.72</b>	
11	Lettuce_romaine_4wk	98.31	97.58	100.0	98.22	100.0	100.0	
12	Lettuce_romaine_5wk	99.95	100.0	100.0	97.24	99.95	100.0	
13	Lettuce_romaine_6wk	99.24	99.02	100.0	99.24	100.0	100.0	
14	Lettuce_romaine_7wk	98.88	95.05	99.35	97.10	99.25	<b>99.53</b>	
15	Vinyard_untrained	74.59	76.83	90.81	98.25	98.25	<b>99.52</b>	
16	Vinyard_vertical_trellis	99.39	98.94	99.83	100.0	98.78	100.0	
OA		92.85	89.28	93.31	94.52	97.33	<b>99.56</b>	

注: 加粗数字表示最佳精度。

(3) LBP-DC-CNN方法也能明显提高多种地物的单类分类精度, LBP提取的特征比2D-CNN模型提取的空间特征具有更强的判别能力。如Indian Pines数据中的Corn-notill、Soybean-mintill, Pavia University数据中的Asphalt、Bricks, Salinas数据中的Grapes\_untrained、Vinyard\_untrained等地物。

图4—图6为4组实验数据地面真实样本图及各个对比方法得到的分类结果图, 这些结果图与

表7—表9中的分类精度分别对应，可以看出LBP-DC-CNN方法所得分类结果图要比LBP-CNN和DC-CNN所得分类结果图中的噪声更少、更平滑，如图6中Grapes\_untrained地物区域。

图7为各个对比方法在不同数量训练样本条件

下的分类精度，由于高光谱图像中标记样本数量较少，训练样本数量对分类精度的影响较大，如图7所示，每类训练样本的数量为50、100、150和200，LBP-DC-CNN方法在有限数量的训练样本条件下也能取得更好的分类精度。

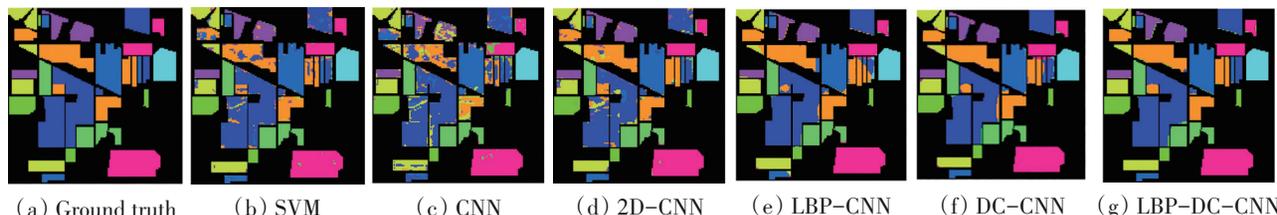


图4 Indian Pines数据分类结果图

Fig.4 Thematic maps resulting from classification for Indian Pines dataset

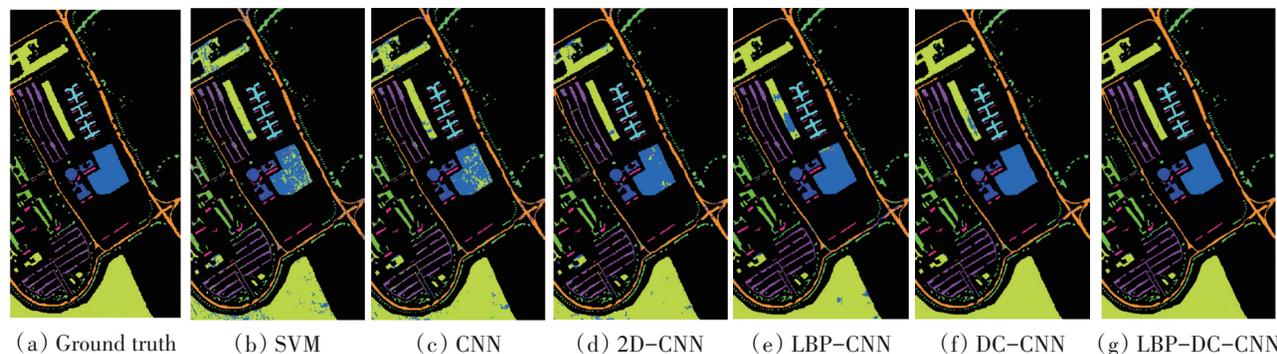


图5 Pavia University数据分类结果图

Fig.5 Thematic maps resulting from classification for Pavia University dataset

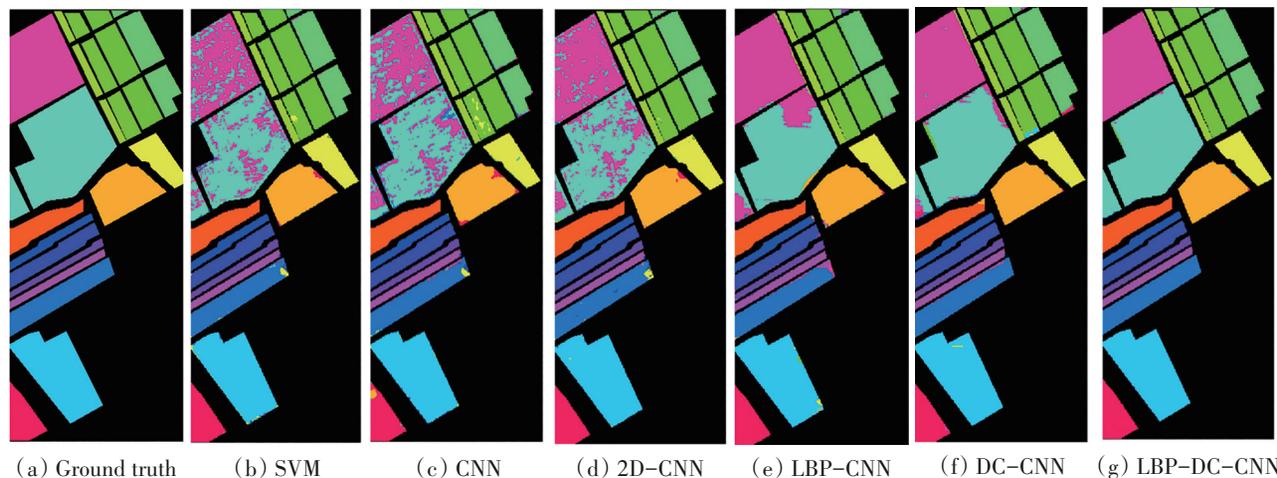


图6 Salinas数据分类结果图

Fig.6 Thematic maps resulting from classification for Salinas data

表10列出了CNN、2D-CNN、LBP-CNN、DC-CNN及LBP-DC-CNN的训练测试时间，从表10中可以看出，由于DC-CNN需要同时处理2维数据和1维数据，还要连接不同的模型，因此训练时间

相比2D-CNN要增长很多，而LBP提取的特征数据比原始图像数据量要大，LBP-CNN的训练时间也很长。LBP-DC-CNN要处理LBP提取的特征数据和原始图像数据，因此训练时间最长。

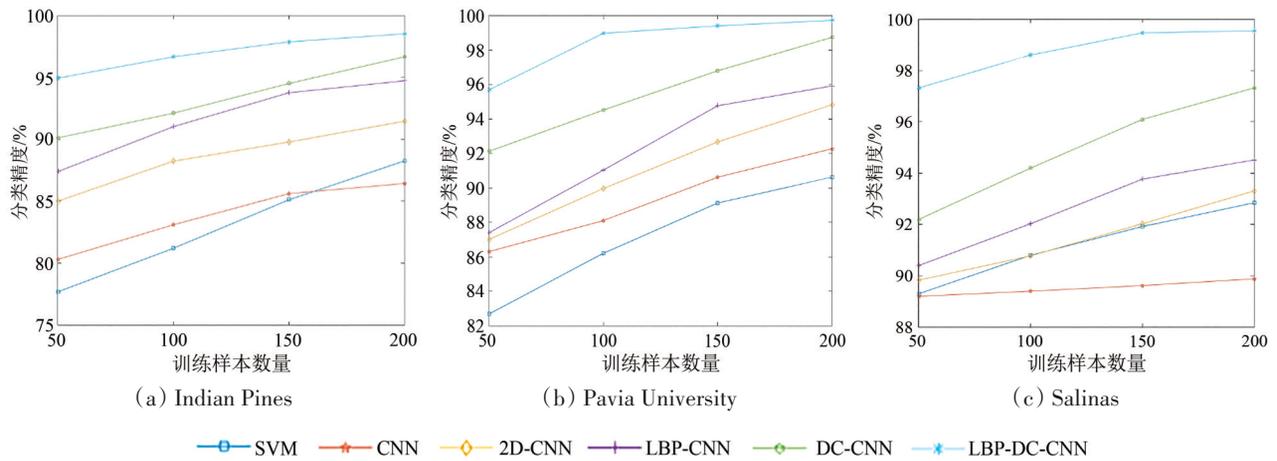


Fig.7 Classification accuracy with different number of training samples per class

表 10 不同方法的训练测试时间

Table 10 Training and testing times for different methods

		/s				
数据	类别	CNN	2D-CNN	LBP-CNN	DC-CNN	LBP-DC-CNN
IN	训练	113.7	257.5	955.4	868.3	1545.8
	测试	0.46	0.72	1.66	1.59	4.63
PU	训练	102.1	236.3	592.4	519.6	708.67
	测试	1.03	2.34	5.14	4.26	13.46
SA	训练	378.6	778.78	1653.4	1439.2	2381.5
	测试	7.67	15.98	26.56	21.05	34.68

注: IN (Indian Pines), PU (Pavia University), SA (Salinas)。

## 4 结 论

本文提出了基于LBP-DC-CNN的高光谱图像分类方法, LBP-DC-CNN结合了双通道CNN模型和LBP, 能够充分利用CNN的特征提取能力和LBP提取特征的判别能力。为了能够更好的处理LBP提取的特征, 将双通道CNN模型改进为两个1D-CNN模型的组合, LBP-DC-CNN利用1D-CNN模型处理原始高光谱图像数据, 提取深层光谱信息, 同时利用1D-CNN模型处理LBP提取的特征数据, 进一步提取深层空间特征, 两个模型的全连接层作为提取的深层光谱特征和空间特征, 通过连接两个模型的全连接层实现深层光谱特征和深层空间特征的融合, 最后将融合特征输入到分类层中完成分类。此外, 本文分析了不同的网络模型参数对分类精度的影响, 验证了本文方法在

不同数量的训练样本条件下的分类精度。实验表明, 本文方法能够有效改善高光谱图像的分类精度, 在有限数量训练样本条件下仍能取得较好的分类精度。本文方法通过利用CNN模型, 实现了高光谱图像中深层光谱特征和空间特征的融合, 充分利用了高光谱图像中蕴含的各种信息, 有利于CNN在高光谱图像分类中的应用。在后续的研究中, 可以进一步研究如何更好地利用CNN模型提取高光谱图像中的各种判别特征, 促进CNN在高光谱图像分类中的应用。

## 参考文献 (References)

- Bioucas-Dias J M, Plaza A, Camps-Valls G, Scheunders P, Nasrabadi N and Chanussot J. 2013. Hyperspectral remote sensing data analysis and future challenges. *IEEE Geoscience and Remote Sensing Magazine*, 1(2): 6-36 [DOI: 10.1109/MGRS.2013.2244672]
- 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]
- Chen Y S, Zhu L, Ghamisi P, Jia X P, Li G Y and Tang L. 2017. Hyperspectral images classification with Gabor filtering and convolu-

- tional neural network. *IEEE Geoscience and Remote Sensing Letters*, 14(12): 2355-2359 [DOI: 10.1109/LGRS.2017.2764915]
- 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(2015): 258619 [DOI: 10.1155/2015/258619]
- Ji Z and Nie L H. 2016. Texture image classification with noise-tolerant local binary pattern. *Journal of Computer Research and Development*, 53(5): 1128-1135 (冀中, 聂林红. 2016. 基于抗噪声局部二值模式的纹理图像分类. *计算机研究与发展*, 53(5): 1128-1135) [DOI: 10.7544/issn1000-1239.2016.20148320]
- Jia S, Deng B, Zhu J S, Jia X P and Li Q Q. 2018. Local binary pattern-based hyperspectral image classification with superpixel guidance. *IEEE Transactions on Geoscience and Remote Sensing*, 56(2): 749-759 [DOI: 10.1109/TGRS.2017.2754511]
- Kingma D P and Ba J. 2014. Adam: a method for stochastic optimization. *arXiv preprint arXiv: 1412.6980*
- Krizhevsky A, Sutskever I and Hinton G E. 2012. ImageNet classification with deep convolutional neural networks//*Proceedings of the 25th International Conference on Neural Information Processing Systems*. Lake Tahoe, Nevada: Curran Associates Inc.: 1097-1105
- Li J, Marpu P R, Plaza A, Bioucas-Dias J M and Benediktsson J A. 2013. Generalized composite kernel framework for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 51(9): 4816-4829 [DOI: 10.1109/TGRS.2012.2230268]
- Li W, Wu G D, Zhang F and Du Q. 2017. 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]
- Moser G and Serpico S B. 2013. Combining support vector machines and Markov random fields in an integrated framework for contextual image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 51(5): 2734-2752 [DOI: 10.1109/TGRS.2012.2211882]
- Pesaresi M and Benediktsson J A. 2001. A new approach for the morphological segmentation of high-resolution satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(2): 309-320 [DOI: 10.1109/36.905239].
- Plaza A, Plaza J and Martín G. 2009. Incorporation of spatial constraints into spectral mixture analysis of remotely sensed hyperspectral data//*Proceedings of 2009 IEEE International Workshop on Machine Learning for Signal Processing*. Grenoble: IEEE: 1-6 [DOI: 10.1109/MLSP.2009.5306202]
- Shu L, McIsaac K and Osinski G R. 2018. Learning spatial-spectral features for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9): 5138-5147 [DOI: 10.1109/TGRS.2018.2809912]
- Simonyan K and Zisserman A. 2014. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv: 1409.1556*
- Ye Z and Bai L. 2017. Hyperspectral image classification based on principal component analysis and local binary patterns. *Laser and Optoelectronics Progress*, 54(11): 111006.1-111006.10 (叶珍, 白璘. 2017. 基于主成分分析与局部二值模式的高光谱图像分类. *激光与光电子学进展*, 54(11): 111006.1-111006.10) [DOI: 10.3788/LOP54.111006]
- Ye Z, Fowler J E and Bai L. 2017. Spatial-spectral hyperspectral classification using local binary patterns and Markov random fields. *Journal of Applied Remote Sensing*, 11(3): 035002 [DOI: 10.1117/1.JRS.11.035002]
- Zhang H K, Li Y, Zhang Y Z and Shen Q. 2017. Spectral-spatial classification of hyperspectral imagery using a dual-channel convolutional neural network. *Remote Sensing Letters*, 8(5): 438-447 [DOI: 10.1080/2150704X.2017.1280200]
- Zhang W and Wang W W. 2015. Face recognition based on local binary pattern and deep learning. *Journal of Computer Applications*, 35(5): 1474-1478 (张雯, 王文伟. 2015. 基于局部二值模式和深度学习的人脸识别. *计算机应用*, 35(5): 1474-1478) [DOI: 10.11772/j.issn.1001-9081.2015.05.1474]
- Zhi L, Yu X C and Fu Q Y. 2018. Hyperspectral imagery spatial-spectral classification combining local binary patterns. *Journal of Geomatics Science and Technology*, 35(1): 65-69, 76 (职露, 余旭初, 付琼莹. 2018. 联合局部二值模式的高光谱影像空-谱分类方法. *测绘科学技术学报*, 35(1): 65-69, 76) [DOI: 10.3969/j.issn.1673-6338.2018.01.013]

## CNN with local binary patterns for hyperspectral images classification

WEI Xiangpo, YU Xuchu, ZHANG Pengqiang, ZHI Lu, YANG Fan

*Information Engineering University, Zhengzhou 450001, China*

**Abstract:** The classification of hyperspectral image remains a challenging task because of the complexity of spectral and spatial structures, high dimensionality, and strong correlation between adjacent bands. The combination of spatial and spectral information can provide significant advantage in terms of reducing the uncertainty of the samples because the same object has different spectrums and objects with

the same spectrum in a hyperspectral image. The Local Binary Pattern (LBP) has also been introduced for spatial-domain feature extraction and classification of hyperspectral images as a simple but powerful texture descriptor. More recently, deep learning has been proven to be a preferable way to extract nonlinear high-level features because of its hierarchical learning framework. The combination of LBP features and the CNNs can lessen the workload of CNNs because of the discrimination capacity of LBP features. In this paper, a novel classification method combining DC - CNN and LBP features, called LBP Dual-Channel CNN (LBP - DC - CNN), is proposed.

In LBP - DC - CNN, original hyperspectral data and LBP features are processed in a DC - CNN framework. On the one hand, original hyperspectral data is fed into a 1D - CNN model to extract original spectral features. On the other hand, LBP features are fed into an identical 1D - CNN model to extract hierarchical spatial features further. Next, the fully connected layers of the two 1D - CNN models in the DC - CNN framework is concatenated into a fused layer, thus completing the fusion of spectral features and spatial features. Finally, the fused layer is fed into a softmax layer to conduct classification.

Result: Experiments were conducted on the Indian Pines dataset, Pavia University dataset, and Salinas dataset to verify the performance of LBP - DC - CNN compared with conventional methods. The results are as follows:

(1) The OAs of LBP - DC - CNN are better than those of LBP - CNN and DC - CNN, which validate the feature extraction capacity of the CNNs and the advantage of LBP features. LBP - DC - CNN provides better accuracy than that of DC - CNN, which is an advantage of LBP features compared with the spatial features extracted by 2D - CNN model. In addition, the accuracy of LBP - DC - CNN is better than that of LBP - CNN, which validates the reasonability and discriminative power of the dual-channel CNN framework.

(2) The OA of LBP - DC - CNN is apparently superior to those of compared methods, which makes DC - CNN and LBP features advantageous. For the Indian Pines data, LBP - DC - CNN (i.e., 98.54 %) yields approximately 2% higher accuracy than the DC - CNN (i.e., 96.68%) and approximately 4% higher accuracy than the LBP - CNN (i.e., 94.74 %). For the University of Pavia data, LBP - DC - CNN (i.e., 99.73 %) yields approximately 1 % higher accuracy than the DC - CNN (i.e., 98.74 %) and approximately 4 % higher accuracy than the LBP-CNN (i.e., 95.92 %). For the Salinas data, LBP - DC - CNN (i.e., 99.56 %) yields approximately 2 % higher accuracy than the DC - CNN (i.e., 97.33 %) and approximately 5 % higher accuracy than the LBP - CNN (i.e., 94.52 %).

(3) LBP - DC - CNN can improve the class-specific accuracy of some ground materials, such as Corn-notill and Soybean-mintill in the Indian Pines data, Asphalt and Bricks in the University of Pavia data, and Grapes\_untrained and Vinyard\_untrained in the Salinas data. LBP features are more discriminative than spatial features extracted by 2D - CNN.

**Key words:** remote sensing, hyperspectral image, classification, CNN, deep learning, LBP

**Supported by** Scientific and Technological Project in Henan Province (No. 152102210014)