

面向高光谱图像分类的局部 Gabor 卷积神经网络



王燕 王丽

兰州理工大学计算机与通信学院 兰州 730050

摘要 针对高光谱图像特征利用不足的问题,提出了一种新的基于空谱联合特征的高光谱图像分类方法。该方法首先利用主成分分析(Principal Component Analysis,PCA)和线性判别分析(Linear Discriminant Analysis,LDA)对高光谱图像进行组合降维;其次引入 Gabor 核,设计了一种基于 Gabor 核的卷积(Local Gabor Convolutional,LGC)层;最后基于 LGC 层设计了一个新的卷积神经网络(Local Gabor Convolutional Neural Network,LGCNN)进行分类。在 Indian Pines 和 Salinas Scene 数据集上对所提方法进行验证,并将其与其他经典分类方法进行比较。实验结果表明,该方法不仅能大幅度减少可学习的参数,降低模型复杂度,而且具备较好的分类性能,其总体精度达到 99%,平均分类精度达到 98%以上,Kappa 系数达到 98%以上。

关键词: 高光谱图像分类;Gabor 滤波;空间-光谱信息;卷积神经网络;深度学习

中图分类号 TP751.1

Local Gabor Convolutional Neural Network for Hyperspectral Image Classification

WANG Yan and WANG Li

College of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China

Abstract In order to solve the problem of insufficient utilization of hyperspectral image features, a new classification method based on spatial-spectral features was proposed. Firstly, principal component analysis (PCA) and linear discriminant analysis (LDA) are used to reduce the dimension of hyperspectral images. Secondly, the Gabor kernel is introduced to design a Local Gabor Convolution (LGC) layer based on the local Gabor kernel. Finally, a new convolutional neural network (LGCNN) is designed based on the LGC layer for classification. The proposed method is validated on Indian Pines and Salinas scene datasets and compared with other classical classification methods. Experiment results show that this method not only saves the learning parameters greatly, reduces the complexity of the model, but also shows good classification performance. Its overall accuracy can reach 99%, the average classification accuracy can reach more than 98%, and the Kappa coefficient can reach more than 98%.

Keywords Hyperspectral image classification, Gabor filtering, Spatial-spectral information, Convolutional neural network, Deep learning

1 引言

由于高光谱图像可被表示为三维立体形式,且可以详尽地描述物体的光谱信息和空间信息,因此有效地利用空谱联合特征进行分类^[1-3]具有十分重要的意义。然而,高光谱图像在描述了丰富的地物细节信息的同时,也使得数据高度相关,导致数据大量冗余,增加了计算的复杂度。因此,减少光谱数据间的冗余量、降低数据维度并提取高光谱图像的空谱联合特征,成为了高光谱图像分类的首要任务^[4-6]。

早期,支持向量机(Support Vector Machine,SVM)^[7-9]作为一种很好的分类器,被广泛应用于高光谱图像分类中。之后,随着深度学习的快速发展,各种基于深度学习的模型被相

继提出。文献[10]提出了一个5层的深度卷积神经网络用于提取高光谱图像的光谱特征,其表现出了较好的分类性能。文献[11]提出了基于主成分分析和卷积神经网络的模型,该模型利用卷积神经网络来提取图像的空谱特征,表现出了较好的分类性能。文献[12]提出的基于 Gabor 滤波和卷积神经网络的模型,通过引入空间信息来缓解过拟合现象。文献[13]提出了一种新的数据降维方法,并设计了两个卷积神经网络模型,其在保留所有光谱带的同时降低了数据维度,从而降低了计算的复杂度,并且表现出了较好的分类效果。尽管基于深度学习的方法在高光谱图像分类方面都取得了一定成果,但是基于深度模型的方法通常存在过拟合现象。这是因为基于深度模型的方法需要大量带标签的数据来训练大量的

收稿日期:2019-05-27 返修日期:2019-09-06 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:甘肃省重点研发计划(18YF1GA060)

This work was supported by the Key R&D Project of Gansu Province (18YF1GA060).

通信作者:王燕(wangyan@lut.cn)

学习参数,而高光谱图像标签的收集是其分类技术面临的瓶颈问题。因此,我们需要一种新的卷积方式来发挥卷积神经网络的巨大优势,并减少可学习的参数,从而缓解对训练样本数据量的需求,最终提高分类性能。

为了解决上述问题,本文提出了一种新的基于空谱联合特征的高光谱图像分类方法。首先,应用主成分分析和线性判别分析对高光谱图像进行组合降维,使类内距离最小化而类间距离最大化,从而有效地消除数据冗余并保留主要信息,保证了降维后的数据具有最佳区分度。然后,引入 Gabor 核,设计了一种基于 Gabor 核的卷积层。该层包括一组预先定义的稀疏 Gabor 滤波、一个非线性激活函数和一组可学习的线性权重。由于 Gabor 具有方向选择性,LGC 层能提取各个方向的空间纹理特征。最后,受 ResNet^[14] 的启发,基于 LGC 层设计了一个新的卷积神经网络 LGCNN 用于高光谱图像分类。所提方法的模型框架如图 1 所示。LGCNN 可以大幅度减少可学习的参数,拥有更低的模型复杂度,因此可缓解过拟合现象,并且在受限的样本下表现出较好的分类性能。




图 1 LGCNN 框架

Fig. 1 Framework of LGCNN

2 局部 Gabor 卷积神经网络的构建

2.1 高光谱图像的预处理

PCA 是最常用的一种高光谱图像降维方法,但在处理高维大样本数据时不能表现出较好的类别区分度。LDA 算法可以增大类间与类内的距离比,但是该算法必须保证类内距离矩阵的非奇异性^[15],而经过 PCA 降维后的数据刚好满足该需求。因此,本文首先应用 PCA 算法对原始数据进行处理,消除数据的冗余度;然后应用 LDA 算法对经过 PCA 算法处理后的数据进行二次投影降维处理,该过程减少了保证类内距离矩阵非奇异的额外运算。经过 2 次降维处理的数据既保留了主要信息,又增大了类间与类内的距离比,提高了样本区分度,从而提升了分类器的分类精度^[16]。本文将高光谱图像数据降至 3 维。

2.2 局部 Gabor 卷积层的构建

1) Gabor 滤波

Gabor 滤波与人类视觉系统中简单细胞的视觉刺激响应非常相似,它在提取目标的局部空间和频率域信息方面具有良好的特性;并且对图像的边缘敏感,具有良好的方向选择性和尺度选择性;同时,对光照变化不敏感,具有良好的光照适应性。

二维 Gabor 滤波器由一个三角函数与高斯函数叠加得到,包含实部和虚部。其数学表达式如下:

$$g_{\lambda,\theta,\psi,\sigma,\gamma}(x,y) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right) \quad (1)$$

实数部分为:

$$g_{\lambda,\theta,\psi,\sigma,\gamma}(x,y) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(2\pi\frac{x'}{\lambda} + \psi\right) \quad (2)$$

虚数部分为:

$$g_{\lambda,\theta,\psi,\sigma,\gamma}(x,y) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \sin\left(2\pi\frac{x'}{\lambda} + \psi\right) \quad (3)$$

其中, (x,y) 为空间坐标, $x' = x \cos \theta + y \sin \theta$, $y' = -x \sin \theta + y \cos \theta$, λ 为波长, θ 为 Gabor 核的方向角度, ψ 为相位偏移, σ 为高斯函数的标准差, γ 为空间的长宽比。

2) LGC 卷积层

LGC 层包括一组预先定义的稀疏 Gabor 滤波、一个非线性激活函数和一组可学习的线性权重。由于 Gabor 具有方向选择性,LGC 层能提取各个方向的空间纹理特征。如图 2 所示,LGC 层实际上由两个卷积层构成,第一层对输入的图像进行卷积操作,其卷积核是预先定义的一组固定的稀疏 Gabor 核,并且该层的权重是固定的,在训练的过程中是不可学习的。卷积后的特征图谱由非线性激活函数进行映射,本文所用的激活函数为 Relu。第二层对映射后的特征进行线性加权组合,形成最终的特征图谱,并将其作为下一层的输入。这一步由 1×1 的卷积核对映射后的特征进行卷积操作实现,且该层权重在训练的过程中是可学习的。本文忽略 bias,因此 LGC 层对多通道输入 x_i 的响应的广义的数学表达式如式(4)所示。

$$x'_{i+1} = \sum_{i=1}^m \sigma(\sum_s b'_i * x'_i) \cdot v_{i,i} \quad (4)$$

其中, s 为输入通道; t 为输出通道; b'_i 为预先定义的固定的稀疏 Gabor 卷积滤波器, $i \in m$; x'_i 为输入图像; σ 为非线性激活函数; $v_{i,i}$ 为可学习的权重。




图 2 LGC 层

Fig. 2 LGC Layer

本文中,LGC 层的第一层卷积核是预先定义的一组固定的稀疏 Gabor 核,这里经实验调整,将 Gabor 核函数的标准差设置为 10,空间比设置为 0.5,相位偏移设置为 0。通过设置不同的方向角和波长,由式(1)算出相应的 Gabor 权值进行实验,因此 Gabor 核的权值随着方向角和波长的改变而变化。

在拥有同样大小的卷积核尺寸、同等数量的输入通道和输出通道的情况下,与标准的卷积层相比,LGC 层拥有更少的可学习的参数。假设输入数据的通道数为 p ,输出通道数为 q ,卷积核的尺寸为 $n \times m$,根据卷积机制,标准的卷积层需

要 $p \times n \times m \times q$ 个可学习的参数,而 LGC 层需要 $p \times n \times m \times \omega$ 个固定的参数和 $\omega \times q$ 个可学习的参数。其中, ω 为中间层的输出通道数, $\omega \times q$ 对应卷积核尺寸为 1×1 的卷积操作。标准卷积层与 LGC 层可学习的参数比为:

$$\frac{p \times n \times m \times q}{\omega \times q} = \frac{p \times n \times m}{\omega} \quad (5)$$

假设 $p = \omega$, 则 LGC 层至少可减少 $n \times m$ 个可学习的参数。由此可见, LGC 层在提取图像特征的同时,大大减少了可学习的参数,从而降低了模型的复杂度。

2.3 LGCNN 的具体结构

LGCNN 的具体结构如表 1 所列。该网络由一个 3×3 的卷积层、一个 convolutional block 和一个 identity block 组成。其中, convolutional block 是由 Gabor 核大小依次为 3×3 , 1×1 和 3×3 的 3 个 LGC 层和 shortcut 连接组成, shortcut 连接中存在一个 Gabor 核大小为 3×3 的 LGC 层; identity block 是由 Gabor 核大小依次为 3×3 , 1×1 和 3×3 的 3 个 LGC 层和 shortcut 连接组成。最后连接 Global average-pooling 层, 该层计算每个特征像素点的均值, 并将结果向量直接输入 softmax 进行分类。Global average-pooling 层能代替全连接层, 减少可学习的参数^[17], 从而降低模型的复杂度。在网络训练的早期, 学习速度通常会迅速下降, 出现梯度消失的问题, 为缓解该现象, LGCNN 中有残差块的连接。在网络的主路增加一个 shortcut, 可使得残差块更好地学习自身函数。因此, 有 shortcut 连接的网络整体训练速度足够快, 并且不存在梯度消失的问题。

表 1 LGCNN 的结构

Table 1 Architecture of LGCNN

Layer No.	Name	Configuration	Stride
1	Conv+Relu	$3 \times 3 \times 32$	2
2	Max-pooling	3×3	2
3	LGC+Relu	$3 \times 3 \times 64$	1
4	LGC+Relu	$1 \times 1 \times 64$	1
5	LGC	$3 \times 3 \times 256$	1
6	2. out \rightarrow LGC	$3 \times 3 \times 256$	1
7	Add(5. out, 6. out) + Relu	N/A	N/A
8	LGC+Relu	$3 \times 3 \times 64$	1
9	LGC+Relu	$1 \times 1 \times 64$	1
10	LGC	$3 \times 3 \times 256$	1
11	Add(7. out, 10. out) + Relu	N/A	N/A
12	Average-pooling	3×3	N/A
13	Softmax	classes	N/A

3 实验及结果

3.1 实验数据集及实验细节

Indian Pines 是由 AVIRIS 传感器收集的印第安纳州西北部印第安纳农林高光谱试验地的图像集, 该图像集由 145×145 个像素组成, 有 220 个光谱带, 覆盖可见光和近红外光谱, 光谱范围为 $0.2 \sim 2.4 \mu\text{m}$, 空间分辨率很高。实验前, 移除其中 20 个噪声波段, 最终剩余 16 类地物。表 2 列出了该数据集包含的类别及样本数量, 图 3 给出了其假彩色图像和地面基准图。




图 3 Indian Pines 数据集(电子版为彩色)

Fig. 3 Indian Pines data sets

表 2 Indian Pines 数据集的类别及样本数(电子版为彩色)

Table 2 Categories and number of Indian Pines datasets

	Class	Num. of samples
1	Alfalfa	46
2	Corn-notill	1428
3	Corn-mintill	830
4	Corn	237
5	Grass-pasture	483
6	Grass-trees	730
7	Grass-pasture-mowed	28
8	Hay-windrowed	478
9	Oats	20
10	Soybean-notill	972
11	Soybean-mintill	2455
12	Soybean-clean	593
13	Wheat	205
14	Woods	1265
15	Buildings-Grass-Trees-Drives	386
16	Stone-Steel-Towers	93
	total	10249

Salinas scene 是由 AVIRIS 传感器收集的加利福尼亚萨利纳斯山谷的图像, 该数据集共有 512×217 个像素点, 含 224 个波段。实验前去掉噪声波段, 最后剩余 204 个波段, 空间分辨率为 3.7m 。该数据集共包括 16 类地物, 表 3 给出了其具体类别和数目, 图 4 给出了其假彩色图像和地面基准图。




图 4 Salinas scene 数据集(电子版为彩色)

Fig. 4 Salinas scene data sets

表3 Salinas scene 数据集的类别及样本数(电子版为彩色)

Table 3 Categories and number of Salinas scene datasets

Class	Num. of samples	
1	Broccoli_green_weeds_1	1977
2	Broccoli_green_weeds_2	3726
3	Fallow	1976
4	Fallow_rough_plow	1394
5	Fallow_smooth	2678
6	Stubble	3959
7	Celery	3579
8	Grapes_untrained	11213
9	Soil_vinyard_develop	6197
10	Corn_senesced_green_weeds	3278
11	Lettuce_romaine_4wk	1058
12	Lettuce_romaine_5wk	1908
13	Lettuce_romaine_6wk	909
14	Lettuce_romaine_7wk	1061
15	Vinyard_untrained	7164
16	Vinyard_vertical_trellis	1737
total		53875

实验中,经调整将 batch size 设为 32, epoch 设为 50。LGC 层分别采用不同数量的 Gabor 核,并设置稀疏度为 0.5。采用 Relu 函数作为激活函数,以提高计算效率并加快函数收敛速度。设置学习率为 1×10^{-3} ,并采用文献[18]的学习速率衰减表。本文分别从 Indian Pines 和 Salinas scene 数据集中随机选取 800 个样本作为训练数据,选取 200 个样本作为测试数据,重复实验 10 次并取其平均值。本文采用 Overall Accuracy(OA)、Average Accuracy(AA)和 Kappa 系数来评价分类性能。其中,OA 用于评价所有样本的分类正确率;AA 是平均分类精度,其大小反映了对应分类方法对小样本所对应的类别的分类结果的好坏;Kappa 系数是一种一致性检验准则,通过该准则可以得到某种分类方法与完全随机分类相比所减少的错误的比例,它可以客观有效地给出对应分类方法的分类性能。

3.2 实验结果及分析

本文实验 PC 机的配置为 Intel(R)Core(TM)i5-4200,主频为 2.30Hz 的 CPU,内存为 8GB,具体程序由 Pycharm2016 编写,网络框架为 Keras。

3.2.1 Gabor 核在不同方向和波长下的实验性能

表 4 列出了 Gabor 核方向固定(方向角度为 0),且波长为 5,10,15,20 的情况下,本文模型的分类性能。

表 4 在固定角度、不同波长的情况下本文模型的分类性能

Table 4 Classification performance under fixed direction and different wavelengths

波长	Indian Pines			Salinas scene		
	OA/%	AA/%	Kappa $\times 100$	OA/%	AA/%	Kappa $\times 100$
5	92.00	87.68	85.21	94.00	91.88	93.29
10	89.00	87.34	84.57	98.00	96.56	97.75
15	91.00	86.00	89.42	98.00	96.35	97.76
20	94.00	93.85	91.98	97.00	97.26	96.71

可以看出,对于 Indian Pines 数据集,当波长从 5 增加至 20 时,本文模型的 OA 增加了 2%,AA 增加了 6.17%,Kappa 系数也大幅提升。对于 Salinas scene 数据集,当波长为 10 和 15 时,本文模型的性能最佳,其 OA 高达 98%;Kappa 系数与其他波长值下的性能相比,至少高出 1.04。

表 5 列出了 Gabor 核波长固定(波长为 5),且方向为 0, $\pi/4$, $\pi/2$, $3\pi/4$ 的情况下,本文方法的分类性能。从可以看出,对于 Indian Pines 数据集,当方向为 $\pi/4$ 时,本文模型的 OA 高达 99%,AA 为 99.67%,Kappa 系数为 98.84,分类性能达到最优。对于 Salinas scene 数据集,当方向为 $\pi/2$ 时,本文模型的 OA 高达 99%,AA 为 98.85%,Kappa 系数为 98.33,相比其他方向,该方向提取的特征更好。

表 5 在波长固定、方向不同的情况下本文模型的分类性能

Table 5 Classification Performance under fixed wavelength and different directions

方向	Indian Pines			Salinas scene		
	OA/%	AA/%	Kappa $\times 100$	OA/%	AA/%	Kappa $\times 100$
0	84	85.35	81.30	94	91.88	93.29
$\pi/4$	99.00	99.67	98.84	82	76.51	79.30
$\pi/2$	93	93.56	91.99	99.00	98.85	98.33
$3\pi/4$	89	79.35	87.62	94	86.68	93.02

3.2.2 不同 Gabor 滤波器个数下的实验性能分析

图 5 给出了不同 Gabor 滤波器个数下本文方法分别在 Indian Pines 和 Salinas scene 数据集上的实验结果,其所对应的具体分类性能如表 6 所列。从图 5 可直观地看出,随着 Gabor 滤波器个数的增加,对于 Indian Pines 数据集,本文方法的分类性能也有所增加。当滤波个数为 512 时,LGCNN 分类性能最佳。对于 Salinas scene 数据集,当 Gabor 滤波器个数为 512 时,本文方法的分类效果最好。但是对于这两个数据集,当滤波个数为 1024 时,本文方法的分类性能反而下降。这是因为随着 Gabor 滤波器个数的增加,网络可学习的参数也有所增加,因此就需要大量的训练样本来训练可学习的参数,而本实验中用到的训练数据有限,不能很好地训练较多的可学习的参数。





图 5 不同 Gabor 滤波器个数下本文方法的分类性能
Fig. 5 Classification performance of proposed method under different Gabor filter numbers

表 6 本文方法在不同滤波器个数下的分类性能

Table 6 Classification performance of proposed method under different Gabor filter numbers

方向	Indian Pines			Salinas scene		
	OA/%	AA/%	Kappa $\times 100$	OA/%	AA/%	Kappa $\times 100$
128	93.00	81.29	92.02	96.00	86.91	95.30
256	94.00	89.81	93.15	98.00	98.06	97.87
512	99.00	99.67	98.84	99.00	98.85	98.33
1024	70.00	68.54	68.98	76.00	69.94	72.64

3.2.3 不同卷积层下的实验性能分析

表 7 给出了不同卷积层下模型所需要的可学习的参数个数。为方便计算参数个数,本文统一采用 512 个 Gabor 核,并且忽略 bias。从表中可以看出,根据卷积机制,相较于基于卷积层,基于 LGC 层的本文模型减少了 18 432 个可学习的参数。由此可见,基于 LGC 层的模型可大大减少可学习的参数,从而降低模型复杂度,节省内存空间。

表 7 不同卷积层下的参数对比

Table 7 Comparison of parameters under different convolutional layers

Layer	Convolution layer	LGC layer
1	864	864
2(convolution_block)	243 712	327 680
3(identity_block)	299 008	196 608
total	543 584	525 152

表 8 列出了不同卷积层下模型的实验结果。从表中可以看出,对于 Indian Pines 数据集,基于 LGC 层的 OA,AA 和 Kappa 系数分别比基于标准卷积层的相应指标高出 1%,2.48%和 1.1;对于 Salinas scene 数据集,基于 LGC 层的 OA,AA 和 Kappa 系数分别比基于标准卷积层的分类性能高出 1%,0.87%和 0.79。由此可见,基于 LGC 层的模型不仅大大减少了训练参数,还表现出了较好的分类性能。

表 8 基于不同卷积层的模型在 Indian Pines 和 Salinas scene 数据集上的实验性能

Table 8 Experimental performance of model based on different convolution layers on Indian Pines and Salinas scene datasets

卷积层	Indian Pines			Salinas scene		
	OA/%	AA/%	Kappa $\times 100$	OA/%	AA/%	Kappa $\times 100$
Convolution layer	98.00	97.19	97.74	98.00	97.98	97.54
LGC layer	99.00	99.67	98.84	99.00	98.85	98.33

图 6 是不同卷积层下模型的训练损失图。从图中可以看出,基于 LGC 层的模型在 Indian Pines 和 Salinas scene 数据集上的收敛速度比基于标准卷积层的收敛速度快。这是因为基于 LGC 层的模型仅需要少量的训练参数。




图 7 不同方法在 Indian Pines 上的分类图(电子版为彩色)

Fig. 7 Classification maps of Indian Pines by using different methods




图 6 不同数据集上的训练损失图

Fig. 6 Training loss on different datasets

3.2.4 不同方法下的实验性能比较

为了验证本文方法的正确性和有效性,将其与 RBF-SVM^[7],CNN^[10],PCA-CNN^[11],Gabor-CNN^[12],CNN-1^[13]和 CNN-2^[13]方法进行对比。为了保证实验的公平性,将所有对比网络中的超参数做设置相同,例如 epoch 为 50,batch size 为 32。实验分别从 Indian Pines 和 Salinas scene 数据集中随机选取 800 个样本作为训练数据,200 个样本作为测试数据,重复实验 10 次并取平均值。实验结果如表 9 所列。从表中可以看出,对于 Indian Pines 数据集,LGCNN 较其他方法中分类性能最好的 CNN-2^[13]方法,OA 高出 1%,AA 高出 2.48%,Kappa 系数高出 1.1。对于 Salinas scene 数据集,LGCNN 较其他方法中分类性能最好的 CNN-2^[13]方法,OA 高出 1%,AA 高出 0.87%,Kappa 系数高出 0.79。由此可见,本文提出的 LGCNN 方法具有较好的分类性能。

表 9 不同方法的实验性能对比

Table 9 Comparison of experimental performance of different methods

方法	Indian Pines			Salinas scene		
	OA/%	AA/%	Kappa $\times 100$	OA/%	AA/%	Kappa $\times 100$
RBF-SVM ^[7]	65.34	64.45	59.76	85.69	89.75	89.38
CNN ^[10]	95.00	90.62	94.19	95.00	92.16	94.31
PCA-CNN ^[11]	94.00	89.20	93.35	94.00	90.62	93.16
Gabor-CNN ^[12]	92.00	90.38	90.66	95.00	96.62	94.43
CNN-1 ^[13]	94.00	82.01	93.09	94.00	90.67	93.31
CNN-2 ^[13]	98.00	97.19	97.74	98.00	97.98	97.54
LGCNN	99.00	99.67	98.84	99.00	98.85	98.33

图 7、图 8 给出了不同方法在 Indian Pines 和 Salinas scene 数据集上的分类图谱。从图中可以看出,CNN,Gabor-CNN,CNN-1 和 CNN-2 方法的最终分类结果图中含有大量的斑点,并且存在小区域内错分的情况;而本文方法的分类结果图只含有非常少量的斑点,且在同质的小区域内相对平滑,并且大部分地物几乎完全被正确分类。由此可见,本文方法具有较好的分类效果。




图8 不同方法在 Salinas scene 上的分类图(电子版为彩色)

Fig. 8 Classification maps of Salinas scene by using different methods

结束语 本文提出了一种基于空谱联合特征的高光谱图像分类方法,该方法首先利用 PCA 和 LDA 对高光谱原始图像进行组合降维,在降低数据冗余度的同时保证了样本具有最佳区分度;然后引入 Gabor 核,设计了新的卷积层——LGC 层,该层充分发挥了 Gabor 核的优势,可以很好地提取图像的空间纹理特征,并能大幅度减少可学习的参数;最后基于 LGC 层设计了 LGCNN。实验表明,本文提出的方法不仅在有限的样本下表现出了较好的分类性能,而且与基于标准卷积层的模型相比,大大降低了模型复杂度,节省了内存空间。

虽然与其他方法相比,本文方法的分类性能较好,但是其中还存在许多不足之处,如怎样同时提取图像多个方向的空间纹理特征以更好地提高分类性能,这将成为下一步的研究重点。

参考文献

- [1] CHEN Y, XING Z, JIA X. Spectral-Spatial Classification of Hyperspectral Data Based on Deep Belief Network[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2015, 8(6): 2381-2392.
- [2] ZHAO W, DU S. Spectral-Spatial Feature Extraction for Hyperspectral Image Classification: A Dimension Reduction and Deep Learning Approach[J]. IEEE Transactions on Geoscience & Remote Sensing, 2016, 54(8): 4544-4554.
- [3] YI M. Hyperspectral Image Classification Based on Fusion of Spectral-Spatial Feature and Integrated Over-limit Learning Machine[J]. Journal of Surveying and Mapping, 2018, 47(9): 1238-1249.
- [4] BIOUCAS-DIAS J M, PLAZA A, CAMPS-VALLS G, et al. Hyperspectral Remote Sensing Data Analysis and Future Challenges[J]. IEEE Geoscience & Remote Sensing Magazine, 2013, 1(2): 6-36.
- [5] AMBIKAPATHI A M, CHAN T H, LIN C H, et al. Convex geometry based outlier-insensitive estimation of number of end-members in hyperspectral images[C]// 2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). IEEE, 2017.
- [6] WANG X T. Research on Dimensionality Reduction and Classification Algorithm of Hyperspectral Image [D]. Harbin Engineering University, 2018.
- [7] GHAMISI P, PLAZA J, CHEN Y, et al. Advanced Spectral Classifiers for Hyperspectral Images: A review[J]. IEEE Geoscience & Remote Sensing Magazine, 2017, 5(1): 8-32.
- [8] WANG L, ZHAO L, LIU D. A review of the application of SVM in hyperspectral image processing[J]. Journal of Harbin Engineering University, 2018, 39(6): 973-983.
- [9] LI T, ZHANG X. Hyperspectral image classification based on joint collaborative representation and SVM decision fusion[J]. Journal of Computer Applications, 2017, 34(6): 1913-1916.
- [10] WEI H, HUANG Y, LI W, et al. Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015, 2015(2): 1-12.
- [11] CHEN Y, JIANG H, LI C, et al. Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks[J]. IEEE Transactions on Geoscience & Remote Sensing, 2016, 54(10): 6232-6251.
- [12] CHEN Y, LIN Z, GHAMISI P, et al. Hyperspectral Images Classification With Gabor Filtering and Convolutional Neural Network[J]. IEEE Geoscience & Remote Sensing Letters, 2017, 14(12): 2355-2359.
- [13] SHU L, MCISAAC K, OSINSKI G R. Hyperspectral Image Classification With Stacking Spectral Patches and Convolutional Neural Networks[J]. IEEE Transactions on Geoscience & Remote Sensing, 2018, 56(10): 1-10.
- [14] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]// IEEE Conference on Computer Vision & Pattern Recognition, 2016.
- [15] LIU J, CHEN S, TAN X. A study on three linear discriminant analysis based methods in small sample size problem[J]. Pattern Recognition, 2008, 41(1): 102-116.
- [16] PARK B C, KIM T H, SIM K I, et al. Terahertz single conductance quantum and topological phase transitions in topological insulator Bi₂Se₃ ultrathin films[J]. Nature Communications, 2015, 6: 6552.
- [17] LIN M, CHEN Q, YAN S. Network In Network [J]. arXiv: 1312. 4400.
- [18] HE K, ZHANG X, REN S, et al. Identity Mappings in Deep Residual Networks[C]// IEEE Conference on Computer Vision (ECCV). 2016: 630-645.



WANG Yan, born in 1971, professor, is a member of China Computer Federation. Her main research interests include pattern recognition and artificial intelligence.