

光学学报

基于三维卷积神经网络与超像素分割的高光谱分类

国强*, 彭龙

哈尔滨工程大学物理与光电工程学院, 黑龙江 哈尔滨 150001

摘要 高光谱遥感数据具有详细的地物光谱与空间信息。针对高光谱数据空间信息在以往分类方法中未得到充分利用而导致鲁棒性与分类精度较低的问题,提出了一种改进的超像素分割与三维卷积神经网络分类方法。该方法首先通过超像素分割与模糊聚类对高光谱遥感数据进行区域分割,再使用三维卷积神经网络对得到的区域分割结果与高光谱数据形成的空-谱联合数据进行训练与分类。通过对空间区域进行划分融合,所提方法提升空间信息在分类中的作用,减小“同物异谱”现象对分类的影响,同时引入三维卷积神经网络对空-谱联合数据进行训练与分类,提升了高光谱分类精度。所提方法在 Pavia University 和 Salinas 数据集的总体准确率为 97.53% 和 98.48%,与各对照实验相比,具有更为良好的分类效果,验证了所提方法的有效性。

关键词 图像处理; 高光谱数据; 超像素分割; 模糊聚类; 三维卷积神经网络

中图分类号 TP751

文献标志码 A

doi: 10.3788/AOS202141.2210001

Hyperspectral Classification Based on 3D Convolutional Neural Network and Super Pixel Segmentation

Guo Qiang*, Peng Long

College of Physics and Optoelectronics Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China

Abstract Data from hyperspectral remote sensing have provided detailed spectral and spatial information regarding ground objects. To solve the problems of low robustness and classification accuracy due to the underutilization of spatial information of hyperspectral data in previous classification methods, this paper proposes a classification method based on improved superpixel segmentation and 3D convolution neural network. First, the hyperspectral remote sensing data are segmented via superpixel segmentation and fuzzy clustering; then, the spatial-spectral joint data formed by the regional segmentation results and hyperspectral data are trained and classified using a 3D convolution neural network. The proposed method improves the role of spatial information in classification by dividing and fusing spatial regions, reduces the impact of the phenomenon of “same objects different spectra” on classification, and introduces a 3D convolution neural network to train and classify the spatial-spectral joint data, improving hyperspectral classification accuracy. In the Pavia University and Salinas datasets, the proposed method has an overall accuracy of 97.53% and 98.48%, respectively. When compared with the control experiments, the proposed method exhibits a better classification effect, which proves its efficacy.

Key words image processing; hyperspectral data; super pixel segmentation; fuzzy clustering; 3D convolutional neural network

OCIS codes 100.2960; 100.4996; 110.4234

1 引言

高光谱遥感数据是指相应传感器采集的波段数

目为 100 以上、分辨率超过 $10^{-2}\lambda$ 的数据,包含详细的地物光谱和空间信息。因高光谱遥感数据的特点,高光谱遥感及其分析处理技术已在地理与地质

收稿日期: 2021-03-01; 修回日期: 2021-04-05; 录用日期: 2021-05-31

基金项目: 国家重点研发计划战略性国际科技创新合作重点专项(2018YFE0206500)、国家自然科学基金(62071140)

通信作者: *958542705@qq.com

测绘^[1]、军事目标识别^[2]、农业产量估计^[3-5]、灾害估计^[6]、林业资源监控^[7]与环境保护^[8-9]等领域得到了应用。

高光谱遥感数据分类一直是高光谱方向的研究热点,传统的高光谱分类算法有 K 邻近算法^[10]、最大似然分类法^[11]和支持向量机(SVM)^[12]等。目前高光谱分类算法主要运用光谱维度信息对地物进行分类,由于“同物异谱”等现象,限制了高光谱分类精度与适用性。随着高光谱技术的进一步发展,包含的光谱与空间信息愈加丰富,对高光谱的空间信息的提取与利用显得尤为重要。在对高光谱进行空间信息提取之前,常需要进行主信息提取,常用的信息提取算法有主成分分析(PCA)^[13]、多尺度分析(MDS)^[14]、最小噪声分离(MNF)^[15]、独立主成分分析(ICA)^[16]等。

超像素分割是图像分割的常用技术,形成的超像素单元不被窗口限制,分割区域贴合地物分布规律,适合以图块为输入数据的分类模型。如 Fang 等^[17]于 2015 年提出的基于分水岭超像素分割和图模型的遥感图像分类框架,其通过一种数理融合方法推导图模型的节点。Zhang 等^[18]于 2018 年提出的基于超像素分割和条件随机场模型的卷积神经网络(CNN)模型,利用高分二号卫星数据验证了该模型的有效性。然而上述算法主要对多光谱的遥感影像进行处理,在对像素进行合并时,受限于聚类中心数目的影响,导致形成的超像素对区域的分割效果有限,无法对复杂场景的高光谱区域进行有效分割与合并。

为了解决上述问题,本文提出了一种适用于高光谱遥感图像的超像素分割方法。首先对高光谱预处理得到的主信息分量进行超像素分割,再利用模糊聚类的方法对同质区域的超像素进行区域融合,得到带有空间特征信息的区域分割结果。同时引入三维卷积神经网络框架对超像素分割与原始高光谱数据构成的联合数据进行训练和分类,增加分类器的普适性和鲁棒性,以提升高光谱分类精度。

2 所提方法与基本原理

2.1 基于模糊聚类的超像素分割

超像素分割能够根据像元及其分布信息进行区域划分,划分得到的区域可以作为同质空间特征并进行后续利用。针对高光谱,超像素分割能依据其地物空间分布规律对高光谱图像进行同质区域分割,为分类框架提供地物的空间特征信息。线性迭代聚类超像素分割算法是一种效果较好的超像素分割算法,可以根据设置的聚类中心完成对像元的迭

代聚合。设原始高光谱图像的像元数目为 N_{pixel} ,超像素聚类中心数目为 L_{pixel} ,则相邻种子点的距离为 $S = \sqrt{N_{\text{pixel}}/L_{\text{pixel}}}$ 。对聚类中心的 $n \times n$ 区域进行梯度值计算,将梯度值最小的像元作为聚类中心,同时对 $2S \times 2S$ 区域的所有像元进行距离度量,通过对颜色空间和空间距离进行计算迭代,优化聚类中心位置与超像素分割的结果。生成的超像素结果虽能对同质像元进行空间分割,但是同质的超像素无法进行进一步区域融合。为了解决上述问题,提出一种模糊聚类超像素融合算法。该算法利用模糊 C-均值聚类(FCM)对得到的超像素根据其颜色空间进行超像素区域合并。基于改进 FCM 的超像素分割算法的目标函数为

$$J = \sum_{l=1}^N \sum_{k=1}^C S_l u_{kl}^m \left\| \left(\frac{1}{S_l} \sum_{p \in R_l} \mathbf{h}_e \right) - \mathbf{c}_k \right\|^2, \quad (1)$$

式中: l 代表超像素分割区域数; S_l 代表第 l 个超像素区域 R_l 所含像元数目; N 代表输入图像经过线性迭代聚类后的超像素区域数目; C 为聚类初始数目; m 为设定的加权系数,其设定了聚类隶属度矩阵 u_{kl} 的重要程度,一般取 2; \mathbf{h}_e 为图像的像元。隶属度矩阵元素 u_{kl}^m 与聚类中心 \mathbf{c}_k 的定义分别为

$$u_{kl}^m = \frac{\left\| \left(\frac{1}{S_l} \sum_{p \in R_l} \mathbf{h}_e \right) - \mathbf{c}_k \right\|^{\frac{1}{2(m-1)}}}{\sum_{v=1}^C \left\| \left(\frac{1}{S_l} \sum_{p \in R_l} \mathbf{h}_e \right) - \mathbf{c}_v \right\|^{\frac{1}{2(m-1)}}}, \quad (2)$$

$$\mathbf{c}_k = \frac{\sum_{l=1}^N u_{kl}^m \left(\sum_{p \in R_l} \mathbf{h}_e \right)}{\sum_{l=1}^N S_l u_{kl}^m}. \quad (3)$$

2.2 三维卷积神经网络

深度学习是图像模式识别、图像分类、数据挖掘和特征挖掘的主要技术手段,并已经在工程上得到应用。CNN 作为代表性的网络之一,在图像分类与识别分析中都表现出了较好效果。CNN 按照卷积核尺寸与图像处理方式可以分为 1D-CNN、2D-CNN 和 3D-CNN。在高光谱分类中,最先得到应用的是 1D-CNN,其利用单独像元的光谱维度信息进行特征提取与分类器训练,虽然 1D-CNN 较以往分类器自适应性较强,但依旧无法利用高光谱中的空间信息,限制了其分类精度。

从 2D-CNN 发展而来的 3D-CNN 结构继承了 2D-CNN 的隐藏特征提取能力,还可以对时域特征、深度特征等第三维特征进行自学习提取与处理。3D-CNN 可以对高光谱的光谱信息与空间信息的深

层特征进行提取。若使用高光谱与区域分割结果形成的联合数据对 3D-CNN 进行训练,能对多个波段信息进行特征提取,还可以对高光谱内部的隐藏特征与超像素分割得到的空间特征进行学习利用,进一步减少网络的训练时间,提升鲁棒性与分类精度。

3D-CNN 主要由卷积层、池化层和分类器组成,其中卷积层对数据进行卷积得到特征,再通过池化层将特征图进一步压缩,经过多层卷积池化操作后,能够得到高抽象特征。池化层还可以减少参数量,节省计算时间,提升网络效率和模型的鲁棒性。使

用的池化操作均为最大池化,图 1 为所采用的 3D-CNN 模型结构图。采用的网络结构由 8 个卷积层、5 个最大池化层和 3 个全连接层组成。各卷积层中卷积核个数分别设置为 64,128,256,256,512,512,512,512。每个卷积层都由 ReLU 非线性修正单元函数进行激活。选用 $3 \times 3 \times 3$ 维度的卷积核进行卷积操作,同时 padding 和 stride 参数均设定为 $1 \times 1 \times 1$,最大程度地保留高光谱图像的空间特征和光谱特征。在设置池化层参数时,除第一层外,均设置为 2 倍步长,以对图像特征进行压缩提取。

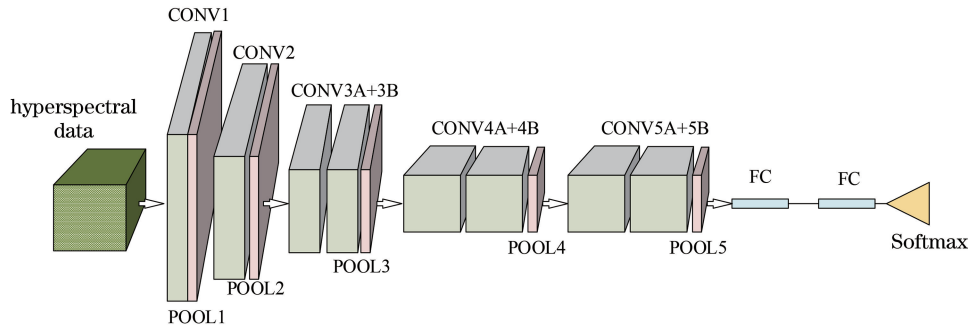


图 1 3D-CNN 结构

Fig. 1 Structure of 3D-CNN

Softmax 分类器中待分类的类别数目为 K ,则 Softmax 层的输出的计算公式为

$$a_g^L = \frac{e^{z_g^L}}{\sum_k e^{z_k^L}}, \quad (4)$$

式中: a_g^L 表示第 L 层的第 g 个神经元输出; z_g^L 表示第 L 层的输入。

$$z_g^L = \sum_k w_{gk}^L a_k^{L-1} + b_g^L, \quad (5)$$

式中: a_k^{L-1} 为全连接层的输出; w_{gk}^L 为输出的权重参数; b_g^L 为偏置; L 为 Softmax 层数。Softmax 的输出为最终的概率值,表示属于第 g 类的概率,对于 L 层每一个神经元均输出一个概率值,表示神经元所属每个类别的可能性。

神经网络的参数训练常用误差反向传播算法,该算法能将误差梯度作为参数反向传播到各个隐含层。每个隐含层以本层的误差梯度作为调整参数的依据,对参数进行调整,提升网络的拟合程度。根据预测类别标签与实际标签之间的误差、偏导、链式法则和反向传播对神经网络每一层的连接权重进行更新。在卷积层中,通过权值共享,对各个层的参数进行更新。

$$\frac{\partial E}{\partial w_{ab}} = \sum_{i=0}^{N'-m'} \sum_{g=0}^{N'-m'} \frac{\partial E}{\partial x_{ig}^{l'}} \frac{\partial x_{ig}^{l'}}{\partial w_{ab}} = \sum_{i=0}^{N'-m'} \sum_{g=0}^{N'-m'} \frac{\partial E}{\partial x_{ig}^{l'}} y_{(i+a)(g+b)}^{l'-1}, \quad (6)$$

式中: N' 为第 l' 个卷积层的输入尺寸; m' 为卷积核尺寸。 $\partial E / \partial x_{ig}^{l'}$ 的计算过程为

$$\frac{\partial E}{\partial x_{ig}^{l'}} = \frac{\partial E}{\partial y_{ig}^{l'}} \cdot \frac{\partial y_{ig}^{l'}}{\partial x_{ig}^{l'}} = \frac{\partial E}{\partial y_{ig}^{l'}} \cdot \frac{\partial}{\partial x_{ig}^{l'}} [\sigma(x_{ig}^{l'})] = \frac{\partial E}{\partial y_{ig}^{l'}} \sigma'(x_{ig}^{l'}), \quad (7)$$

式中: σ 为 ReLU 激活函数,可以计算出误差对权重的偏导,进而对权重进行更新。

2.3 方法流程与具体实现

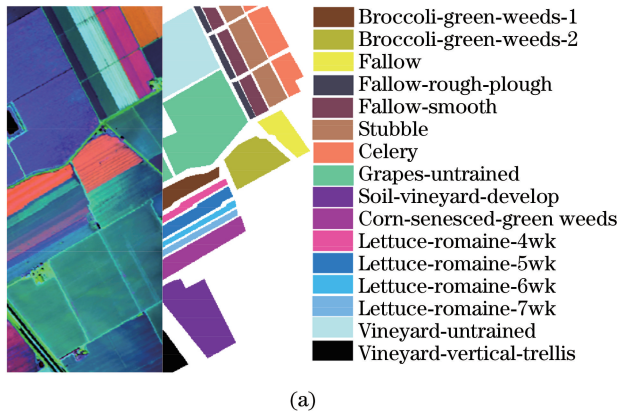
因高光谱各个波段信息的冗余与复杂性等原因,在进行超像素分割之前需对高光谱数据进行主要信息提取。所提方法的实现流程为:采用 PCA 算法对高光谱遥感图像进行处理,可以得到以特征值为排序的高光谱 PCA 成分,其前三成分所含信息占比超过 90%;再对 PCA 前三成分进行超像素分割,并对分割结果进行模糊聚类,以进一步得到高融合度的图像分割图,强化高光谱的内部空间分割结果;在对超像素进行合并的同时,模糊聚类还能够对超像素所属的地物种类进行简要分类,能够检验超像素分割算法的有效性。使用 3D-CNN 作为分类框架,3D-CNN 使用高光谱数据与超像素分割结果形成的联合数据进行训练,能够利用高光谱的光谱信息与空间信息完成高光谱

分类。为了充分利用空间邻域信息与光谱信息,采用切片的方式进行训练,切片的大小为 19×19 。按照随机取样的方式输入各种类数据对 3D-CNN 进行训练,将剩余数据作为测试集,测试分类框架的分类精度。

3 实验结果分析与讨论

3.1 实验数据

为了验证所提方法的有效性,采用 Salinas 和 Pavia University 数据集验证所提方法的有效性。



Salinas 数据集于 1992 年在美国加州采集,包含标记样本数目 54129 个。数据尺寸为 512×217 像素,有效波段有 204 个。Salinas 数据集的伪彩色图与真值图如图 2(a) 所示。Pavia University 高光谱数据集于 2013 年在意大利帕维亚大学采集,包含 9 个类别,主要涵盖建筑物、植物作物和沙砾等,共标注样本 42776 个。数据尺寸为 610×340 像素,有效波段有 103 个。Pavia University 数据集的伪彩色图与真值图如图 2(b) 所示。数据集为高光谱分类常用的数据集,具有一定的代表性。

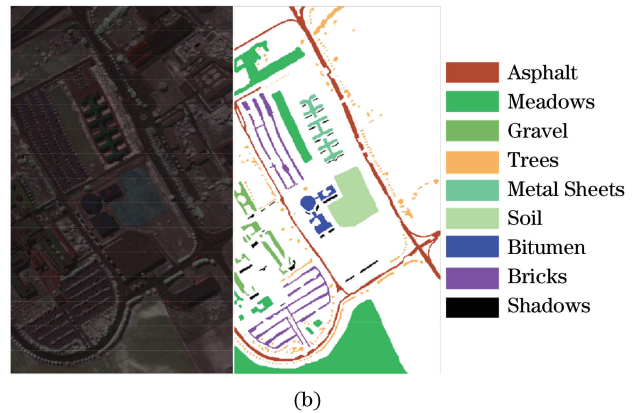


图 2 伪彩色图与真值图。(a) Salinas 数据集;(b) Pavia University 数据集

Fig. 2 False color image and ground truth. (a) Salinas data set; (b) Pavia University data set

3.2 实验设置

实验设置了 3 组对照实验,分别为 SVM、3D-CNN 和 LBP-3D-CNN。实验训练样本比例与所提方法一致,均随机抽取 10% 数据作为训练集,剩余数据作为测试集,验证方法的有效性。除 SVM 外,均抽取切片邻域大小为 19×19 的高光谱切片进行网络训练。同时为了验证改进超像素分割算法的有效性性与参数设置的合理性,采用 3 种对比方法验证超像素分割对分类提升精度的效果,验证分类框架

的有效性。同时为了验证超像素参数对分类精度的影响,设置了 5 组聚类中心为 300, 500, 1000, 1500, 2000 的实验,验证参数设置对区域划分结果的影响。

3.3 实验结果与分析

为验证超像素分割方法的有效性,选用地物分布较为复杂的 Pavia University 数据集展示超像素分割与聚类结果。图 3~5 是 Pavia University 数据集的 PCA 前三成分的超像素分割与聚类结果

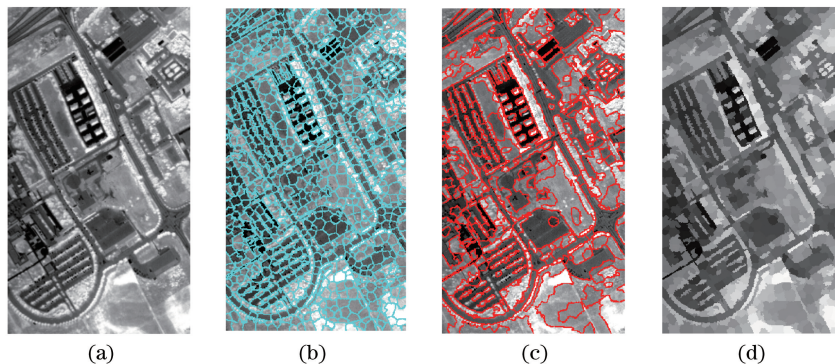


图 3 PCA1 分割与聚类图。(a) PCA 第一成分;(b)超像素分割结果;(c)合并结果;(d)聚类结果

Fig. 3 PCA1 segmentation and clustering graph. (a) PCA1; (b) super pixel segmentation result; (c) merge result; (d) clustering result

图,可以看出,当聚类中心为 1000 时,生成的超像素能够贴合地物空间分布规律。根据图 3(d)、图 4(d)、图 5(d)超像素分割的聚类结果可以看出,区域合并效果较好,相同地物的超像素得到了进一步融合,对各类地物的空间分布进行较为完整的区域分割。

为验证聚类中心设置是否合理,在图 6 中展示了 Pavia University 高光谱数据集的 PCA 第一主成分在聚类中心数目为 300, 500, 1000, 1500, 2000 时的超像素分割与聚类结果。




图 4 PCA2 分割与聚类图。(a) PCA 第二成分;(b)超像素分割结果;(c)合并结果;(d)聚类结果

Fig. 4 PCA2 segmentation and clustering graph. (a) PCA2; (b) super pixel segmentation result; (c) merge result; (d) clustering result

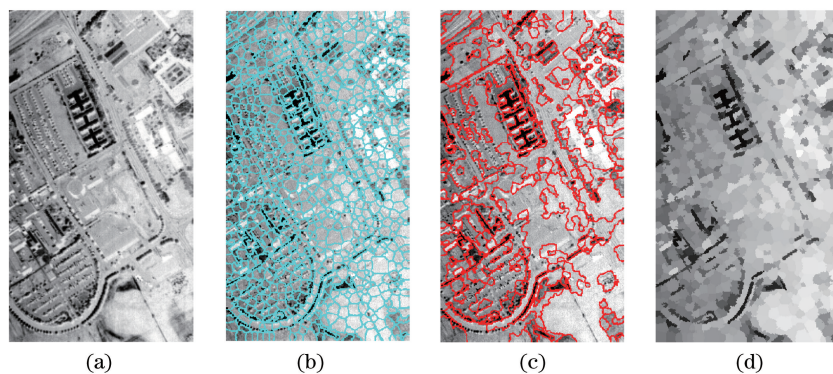


图 5 PCA3 分割与聚类图。(a) PCA 第三成分;(b)超像素分割结果;(c)合并结果;(d)聚类结果

Fig. 5 PCA3 segmentation and clustering graph. (a) PCA3; (b) super pixel segmentation result; (c) merge result; (d) clustering result

为了验证选取的超像素分割参数是否合理,对 Pavia University 数据集与 Salinas 数据集高光谱的 PCA 前三成分进行了 5 组不同数目的超像素分割与聚类,将得到的结果和原始高光谱组成的联合数据输入 3D-CNN 框架进行训练实验,验证聚类中心数量对分类的影响,实验结果如表 1 和表 2 所示。表 1 和表 2 分别展示了 5 种聚类中心的总体精度(OA)、平均精度(AA)和 Kappa 系数。当聚类中心数目为 1000 时,所提方法在各参数和两数据集中均取得了精度较

高的分类结果。当聚类中心数目较低时,所提方法的分类精度较低,随着聚类中心数目的增加,分类精度得到了明显提升,但聚类中心数目超过 1000 以上时出现了精度略微下降的情况。这是因为当聚类中心设置较少时,同质空间合并时,所提方法将别的种类像元错误地合并到当前超像素,影响了分类精度。当超像素分割聚类中心数目过多时,聚类结果变得更加离散细小,同质区域过度分离,也一定程度影响了分类的稳定性与精度。




图 6 不同聚类中心数目下,PCA1 超像素区域合并结果。(a)(b) 300;(c)(d) 500;(e)(f) 1000;(g)(h) 1500;(i)(j) 2000
 Fig. 6 PCA1 super pixel region merging results under different number of clustering centers. (a)(b) 300; (c)(d) 500; (e)(f) 1000; (g)(h) 1500; (i)(j) 2000

表 1 Pavia University 数据集的不同聚类中心分类精度

Table 1 Classification accuracy of different clustering centers in Pavia University data set

Parameter	Center 300	Center 500	Center 1000	Center 1500	Center 2000
OA / %	86.14	92.63	97.53	97.59	96.96
AA / %	82.65	89.06	96.36	96.53	95.28
Kappa / %	83.26	91.27	96.67	95.42	93.74

表 2 Salinas 数据集的不同聚类中心分类精度

Table 2 Classification accuracy of different clustering centers in Salinas data set

Cluster center	Center 300	Center 500	Center 1000	Center 1500	Center 2000
OA / %	91.34	94.63	98.48	98.59	97.92
AA / %	90.68	93.25	97.79	97.60	97.46
Kappa / %	90.61	92.61	95.61	95.48	94.80

为进一步验证超像素分割与 3D-CNN 联合框架对高光谱分类的有效性,选取了 SVM、3D-CNN、LBP-3D-CNN 三种分类算法验证所提方法的有效性。其中局部二值化(LBP)是一种空间纹理特征,可以对高光谱的地物分布信息进行提取。为展示所提分类框架 SP-3D-CNN 对各类地物的分类能力,选取了地物分布较为复杂的 Pavia University 数据集展示各类地物的详细分类结果,结果如表 3 所示。

实验结果表明:相比于 LBP-3D-CNN 和 SP-3D-CNN,SVM 采用直接输入高光谱数据的方式进行训练参数,对高光谱的分类精度较低,这是因为 SVM 无法利用高光谱的空间特征信息,同物异谱现象对分类精度产生了一定的影响;直接输入高光谱

信息的 3D-CNN 相较于 SVM,OA 提升了 6.13 个百分点,AA 提升了 8.18 个百分点,验证了所提 3D-CNN 分类框架的有效性。从 3D-CNN 的网络特性可知,3D-CNN 可以同时提取高光谱的光谱特征与空间特征,同时相较于 SVM 的训练方式,CNN 训练方式提取的特征更加抽象,代表性也更强,这也是 3D-CNN 分类精度高的深层次原因。相较于直接输入高光谱数据的 3D-CNN 的分类框架,LBP-3D-CNN 也取得了较为良好的分类结果,这是因为高光谱数据具有的空间一致性使得空-谱联合数据可以为分类提供更多的信息,而 LBP 可以提取出高光谱的空间纹理信息,增加了 3D-CNN 可以利用的有效数据量并提高了参数训练效率。但相比于 SP-3D-

CNN, LBP-3D-CNN 分类精度较低, 从信息角度进行分析, 超像素分割与聚类可以对全局的区域信息进行整合与提取, 而 LBP 只能提供局部的空间纹理

信息, 一定程度限制了分类的精度。所提 SP-3D-CNN 在大多数地物分类中均取得了较高的分类精度, 并得到了最高的 OA, AA 和 Kappa 系数。

表 3 Pavia University 数据集各方法分类精度对比

Table 3 Comparison of classification accuracy of different methods in Pavia University data set unit: %

Category	SVM	3D-CNN	LBP-3D-CNN	SP-3D-CNN
Asphalt	87.43	90.22	97.47	97.41
Meadows	95.80	97.95	97.11	99.65
Gravel	59.03	62.09	94.30	91.49
Trees	84.57	94.34	95.69	96.64
Metal Sheets	98.03	98.80	94.90	98.70
Soil	53.67	85.92	97.74	96.89
Bitumen	65.31	74.39	95.07	94.52
Bricks	77.59	85.58	94.13	94.10
Shadows	80.87	86.60	95.62	97.86
OA	84.16	90.29	96.19	97.53
AA	78.03	86.21	95.78	96.36
Kappa	78.57	88.39	95.70	96.67

利用超像素分割对空间区域合并得到的特征信息辅助 3D-CNN 进行分类, 将得到的超像素分割结果与原始高光谱结合, 输入到 3D-CNN 进行学习训练。基于模糊聚类的超像素分割方法能够对图像按空间分布信息进行区域分割与划分, 得到高光谱带有空间划分结果的区域划分特征图, 其余高光谱数据形成联合数据, 强化了高光谱的空间信息, 并提升了分类框架的训练效率与分类性能, 相较于 3D-CNN, SP-3D-CNN 的 OA 与 AA 分别提升了 7.24 个百分点和 10.15 个百分点。

4 结 论

为充分挖掘和利用高光谱遥感数据中的光谱和空间信息, 提出了一种改进的超像素分割方法, 该方法通过模糊聚类方法对同质超像素进行融合, 得到带有空间特征的区域分割结果; 同时为了充分利用高光谱的空间特征, 提出了一种 SP-3D-CNN 分类框架, 对高光谱数据与超像素分割结果形成的联合数据进行训练和完成分类。结果表明, 所提超像素分割算法能够有效地对高光谱进行区域分割与空间特征提取, 并且使用的 3D-CNN 能够对高光谱数据实现高精度分类, 充分利用了高光谱的空间特征与光谱特征, 提升了分类框架的精度与鲁棒性。

考虑到未来可能会出现更为有效的神经网络结构与训练方式, 未来的主要研究将集中在神经网络的设计与高光谱其他空间特征信息的合理提取上,

以实现训练代价更低的分类器模型。

参 考 文 献

- [1] Kruse F A, Boardman J W, Huntington J F. Comparison of airborne hyperspectral data and EO-1 Hyperion for mineral mapping [J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(6): 1388-1400.
- [2] Prasad S, Bruce L M. Limitations of principal components analysis for hyperspectral target recognition[J]. IEEE Geoscience and Remote Sensing Letters, 2008, 5(4): 625-629.
- [3] Thenkabail P S, Smith R B, de Pauw E. Hyperspectral vegetation indices and their relationships with agricultural crop characteristics [J]. Remote Sensing of Environment, 2000, 71(2): 158-182.
- [4] Rao L B, Pang T, Ji R S, et al. Firmness detection for apples based on hyperspectral imaging technology combined with stack autoencoder-extreme learning machine method [J]. Laser & Optoelectronics Progress, 2019, 56(11): 113001.
饶利波, 庞涛, 纪然仕, 等. 基于高光谱成像技术结合堆栈自动编码器-极限学习机方法的苹果硬度检测 [J]. 激光与光电子学进展, 2019, 56(11): 113001.
- [5] Liu L X, He D, Li M Z, et al. Identification of Xinjiang jujube varieties based on hyperspectral technique and machine learning [J]. Chinese Journal of Lasers, 2020, 47(11): 1111002.
刘立新, 何迪, 李梦珠, 等. 基于高光谱技术与机器学习的新疆红枣品种鉴别 [J]. 中国激光, 2020, 47(11): 1111002.

- [6] Xiang L B, Wang Z H, Liu X B, et al. Hyperspectral imager of the environment and disaster monitoring small satellite [J]. *Remote Sensing Technology and Application*, 2009, 24(3): 257-262, 250.
相里斌, 王忠厚, 刘学斌, 等. “环境与灾害监测预报小卫星” 高光谱成像仪 [J]. *遥感技术与应用*, 2009, 24(3): 257-262, 250.
- [7] Jusoff K. Precision forestry using airborne hyperspectral imaging sensor [J]. *Journal of Agricultural Science*, 2009, 1(1): 142-147.
- [8] Zhao S H, Zhang F, Wang Q, et al. Application of hyper-spectral remote sensing technology in environmental protection [J]. *Spectroscopy and Spectral Analysis*, 2013, 33(12): 3343-3348.
赵少华, 张峰, 王桥, 等. 高光谱遥感技术在国家环保领域中的应用 [J]. *光谱学与光谱分析*, 2013, 33(12): 3343-3348.
- [9] Zhao Q D, Ge X Y, Ding J L, et al. Combination of fractional order differential and machine learning algorithm for spectral estimation of soil organic carbon content [J]. *Laser & Optoelectronics Progress*, 2020, 57(15): 153001.
赵启东, 葛翔宇, 丁建丽, 等. 结合分数阶微分技术与机器学习算法的土壤有机碳含量光谱估测 [J]. *激光与光电子学进展*, 2020, 57(15): 153001.
- [10] Zhu B, Jiang L, Jin F H, et al. Walnut shell and meat differentiation using fluorescence hyperspectral imagery with ICA-kNN optimal wavelength selection [J]. *Sensing and Instrumentation for Food Quality and Safety*, 2007, 1(3): 123-131.
- [11] Shafri H Z M, Suhaili A, Mansor S. The performance of maximum likelihood, spectral angle mapper, neural network and decision tree classifiers in hyperspectral image analysis [J]. *Journal of Computer Science*, 2007, 3(6): 419-423.
- [12] Chi M M, Feng R, Bruzzone L. Classification of hyperspectral remote-sensing data with primal SVM for small-sized training dataset problem [J]. *Advances in Space Research*, 2008, 41(11): 1793-1799.
- [13] Farrell M D, Mersereau R M. On the impact of PCA dimension reduction for hyperspectral detection of difficult targets [J]. *IEEE Geoscience and Remote Sensing Letters*, 2005, 2(2): 192-195.
- [14] Jiao B L, Fan C L, Wang Z H. Multidimensional scaling used for image classification based on binary partition trees [J]. *Computer Engineering and Applications*, 2015, 51(15): 179-182, 192.
焦斌亮, 范成龙, 王朝晖. 基于二叉划分树的多维尺度分析图像分类算法 [J]. *计算机工程与应用*, 2015, 51(15): 179-182, 192.
- [15] Amato U, Cavalli R M, Palombo A, et al. Experimental approach to the selection of the components in the minimum noise fraction [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(1): 153-160.
- [16] Wang J, Chang C I. Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(6): 1586-1600.
- [17] Fang L Y, Li S T, Kang X D, et al. Spectral - spatial classification of hyperspectral images with a superpixel-based discriminative sparse model [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(8): 4186-4201.
- [18] Zhang L, Li H, Shen P Y, et al. Improving semantic image segmentation with a probabilistic superpixel-based dense conditional random field [J]. *IEEE Access*, 2018, 6: 15297-15310.