

三维卷积神经网络模型联合条件随机场优化的 高光谱遥感影像分类

李竺强^{1*}, 朱瑞飞^{1,2}, 高放¹, 孟祥玉³, 安源¹, 钟兴¹

¹ 长光卫星技术有限公司, 吉林省卫星遥感应用技术重点实验室, 吉林 长春 130000;

² 中国科学院长春光学精密机械与物理研究所, 吉林 长春 130033;

³ 吉林省国土资源调查规划研究院, 吉林 长春 130061

摘要 高光谱遥感影像分类通常基于地物光谱特征,但影像中同时还存在丰富的空间信息。空间信息的有效利用能显著提高图像分类效果。因其具有的特殊结构,卷积神经网络(CNN)已成功地应用在图像分类领域,对二维图像分类具有很好的效果。如何通过深度学习并结合空间光谱信息来提高分类性能是一个关键问题。结合高光谱影像中的空间特征与光谱信息,提出一种适合于高光谱像素级分类的深度学习三维卷积神经网络模型(3D-CNN),并在初始分类的基础上利用多标签条件随机场进行优化。选取三个通用公开高光谱数据集(Indian Pines 数据集、Pavia University 数据集、Pavia Center 数据集)进行测试,结果表明分类优化后精度得到很大提升,总体精度可达 98%,Kappa 系数达到 97.2%。

关键词 遥感; 高光谱影像; 空间-光谱信息; 三维卷积神经网络; 条件随机场

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/AOS201838.0828001

Hyperspectral Remote Sensing Image Classification Based on Three-Dimensional Convolution Neural Network Combined with Conditional Random Field Optimization

Li Zhuqiang^{1*}, Zhu Ruifei^{1,2}, Gao Fang¹, Meng Xiangyu³, An Yuan¹, Zhong Xing¹

¹ Chang Guang Satellite Technology Co. Ltd., Key Laboratory of Satellite Remote Sensing Application
Technology of Jilin Province, Changchun, Jilin 130000, China;

² Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences,
Changchun, Jilin 130033, China;

³ Jilin Provincial Land Survey & Planning Institute, Changchun, Jilin 130061, China

Abstract Hyperspectral remote sensing image classification is usually based on the spectral features of objects, but there are plenty of spatial informations in the images. The effective use of spatial information can significantly improve the image classification effect. Because of the special structure of convolution neural network (CNN), CNN has been successfully applied in the field of image classification, and has a good effect on the classification of two-dimensional images. How to improve classification performance through deep learning combined with spatial-spectral information is a key point. Combining the spatial features and spectral information of hyperspectral images, we have developed a three-dimensional convolution neural network model (3D-CNN) for hyperspectral pixel classification, and the multi labels conditional random field is optimized on the basis of the initial classification. Three general open hyperspectral datasets (Indian Pines dataset, Pavia University dataset, Pavia Center dataset) are selected for testing. Experiments show that the accuracy is greatly improved after the classification optimization, the overall accuracy can reach 98%, and the Kappa coefficient reaches 97.2%.

Key words remote sensing; hyperspectral image; spatial-spectral information; three-dimensional convolution neural network; condition random field

OCIS codes 280.4991; 110.4234; 100.2960; 100.4996

收稿日期: 2018-01-29; 修回日期: 2018-03-09; 录用日期: 2018-04-02

基金项目: 吉林省科技厅重点科技攻关项目(20170204034SF)、吉林省重点科技研发项目(20180201109GX)

* E-mail: skybelongtous@foxmail.com

1 引 言

随着空间信息科学和传感器技术的迅猛发展, 高光谱、高分辨率遥感影像等空间数据不断涌现, 遥感大数据时代已来临^[1-2]。高光谱遥感是指在可见光、近红外、中红外和热红外波段范围内, 获得很多窄的连续的光谱影像数据的技术。在获取遥感影像时, 不仅保留了地物的空间信息, 而且保留了对应地物的光谱信息。高光谱影像分类是遥感图像处理技术中的基本问题之一, 也是遥感图像场景理解的关键^[3-4]。目前, 高光谱遥感已广泛地应用到军事、农业^[5]、森林、海洋、地质、生态^[6]等相关领域。

传统的高光谱影像分类方法通常基于光谱信息, 利用基于距离度量的分类器, 如 K 邻近算法^[7]或最大似然法^[8]等。对于波段数量巨大的高光谱数据来说, 这些方法需要依赖大量样本来训练, 时间成本很大。研究表明, 机器学习、深度学习、计算机视觉和模式识别理论与方法已成为高光谱遥感影像分类的重要技术手段^[4]。条件随机算法作为图像处理中流行的能量优化算法, 在计算机视觉领域的图像分割、立体视觉、密集匹配等方向^[9-10]得到普遍应用, 也有学者^[11]通过分布式学习策略和平均场完成半监督条件随机场(CRF)的训练和推断。此类方法将图像分割与图的最小割问题相关联, 从图像分割角度出发完成非监督分类。针对影像特征维数高、样本量少的特点, 传统方法通过波段选择和特征提取进行主成分分析(PCA)降维处理, 将原始数据压缩到低维空间。近年来出现了三种新的解决方案: 一是适用于小样本、高维特征的分类器, 如支持向量机(SVM)分类器^[12]; 二是半监督分类^[13], 即将半监督学习引入到遥感影像分类中, 在已知类别标记的训练样本不足的情况下, 将未知类别的样本引入训练过程; 三是字典学习, 即受矢量量化思想启发, 利用稀疏表示模型, 将高光谱的每个光谱向量表示为字典中训练样本的稀疏线性组合, 再将其应用于高光谱图像的分类^[14-15]。

深度学习的再度崛起给图像分类带来新的机遇, 已在图像分类中有了一定应用。从一开始的卷积神经网络(CNN) LeNet, 到后来的 AlexNet、GoogleNet 深度神经网络模型, 使深度强化学习已成为人工智能的热点。Zhao 等^[16]利用深度学习多尺度二维 CNN(2D-CNN)对高光谱遥感影像进行深度表达并融合多波段光谱信息进行分类, 但需要

设计不同的特征提取尺度, 对于不同形状类型目标地物可能会使特征区混淆。2016 年, 刘大伟等^[17]利用深度学习的常用模型——深度信念网络对高分辨率影像进行分类, 相比传统的 SVM 方法更能够提高分类的准确度。Mou 等^[18]提出了一种利用递归神经网络(RNN)对高光谱影像分类的方法, 展示了深度递归网络在未来遥感影像分类中的巨大潜力。与 RNN 相比, 2D-CNN 最显著的优点是提供了一种直接从原始输入图像提取特征的方法。然而, 直接将 2D-CNN 应用于高光谱图像, 需要对网络中每个二维输入进行卷积, 每一个光谱波段都有一组需学习的卷积核。Mei 等^[19]发现, 大量的参数在训练过程中可能会带来模型过拟合问题, 造成模型泛化能力不足。

为同时利用高光谱影像丰富的光谱信息和空间信息, 本文提出一种适合于高光谱像素级分类的深度学习模型: 三维 CNN(3D-CNN)模型联合多标签条件随机场分类优化模型(3D-CNN-CRF)。3D-CNN 可同时对目标像素的空间领域像素与波段进行三维卷积。在分类结束后, 利用 3D-CNN 得到每个像素所属类别的概率, 结合多标签条件随机场完成全局优化, 最终使得像素类内间隔最小, 类外间隔最大, 得到高光谱像素分类标签在空间上局部连续全局最优。为验证算法的有效性, 在公共高光谱数据集(Indian Pines 数据集、Pavia University 数据集、Pavia Center 数据集)上进行实验验证, 统计分类后每类的准确率、总体精度以及 Kappa 系数。另外, 将此方法与 Zhan 等^[20]提出的 LDM-FL (large margin distribution machine and feature learning)方法、Hu 等^[21]改进的 CNN 方法(pCNN*)以及 2D-CNN 方法进行纵向与横向比较, 通过实验精度评价算法的分类性能。

2 实验方法

实验方法流程图如图 1 所示。在训练过程中, 首先从高光谱影像中构建空间-光谱训练数据集, 然后基于 3D-CNN 模型进行深度空间-光谱特征提取, 最后通过 Softmax 逻辑回归分类进行像素级分类。在测试过程中, 首先提取每个像元的空间-光谱立方体, 然后根据先前训练的模型权重对未知影像像元进行深度空间-光谱特征构建, 并通过先前的 Softmax 分类器进行预测, 得到每个像素所属类别的概率, 最后结合多标签条件随机场完成高光谱影像分类优化。

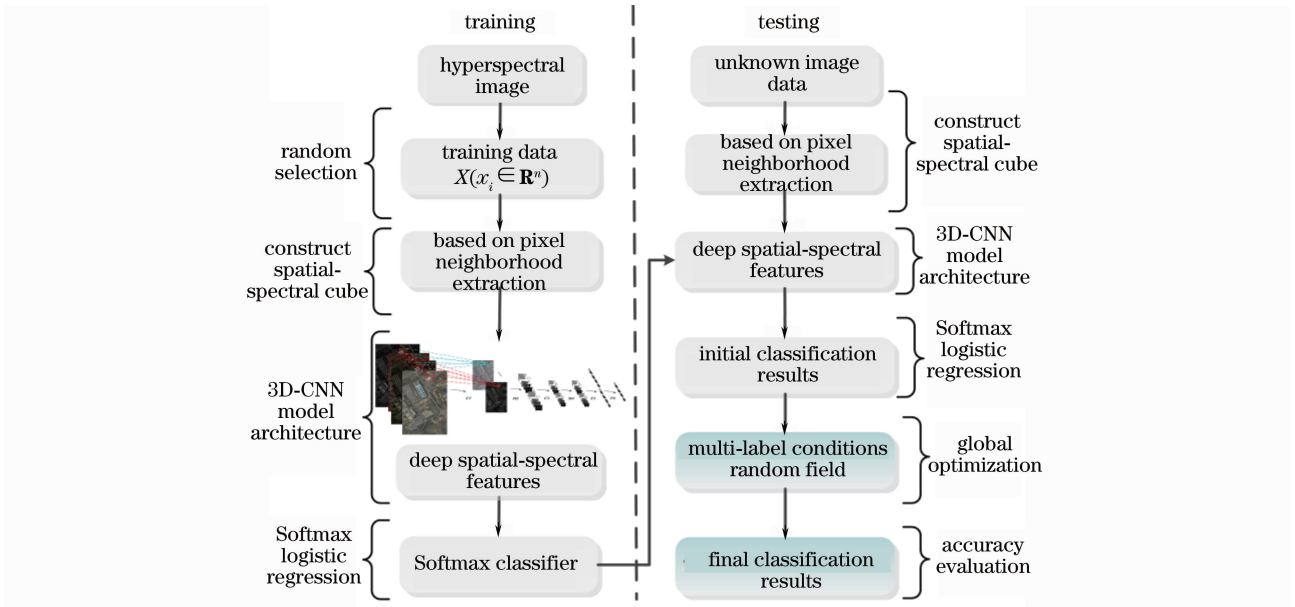


图 1 实验方法流程图

Fig. 1 Flow chart of experimental method

2.1 3D-CNN 构建

2D-CNN 是一种典型的神经网络结构,其权值共享结构可有效降低网络模型的复杂度和权值数量,在网络输入端是多维图像时其优势明显,使图像可直接作为网络输入,避免了传统识别算法中复杂的特征提取和数据重建过程。

图 2 为基于空间-光谱 3D-CNN 模型的高光谱影像分类架构,与 2D-CNN 不同的是在进行三维卷积处理时,由于网络输入端为三维数据,计算神经网络第 i

层第 j 个特征图在 (x, y, z) 点值 $h_{i,j}^{xyz}$ 的计算公式为

$$h_{i,j}^{xyz} = f \left[b_{i,j} + \sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{t=0}^{T_i-1} W_{i,j,m}^{p,q,t} \cdot h_{i-1,m}^{(x+p) \cdot (y+q) \cdot (z+t)} \right], \quad (1)$$

式中: m 表示第 $i-1$ 层中与当前特征图相连的特征图; P_i 与 Q_i 表示卷积核的长度和宽度; T_i 表示卷积核在光谱维度上的尺寸; $W_{i,j,m}^{p,q,t}$ 代表与 (p, q, t) 相连的第 m 个特征图的连接权值; $b_{i,j}$ 表示第 i 层第 j 个特征图的偏置。

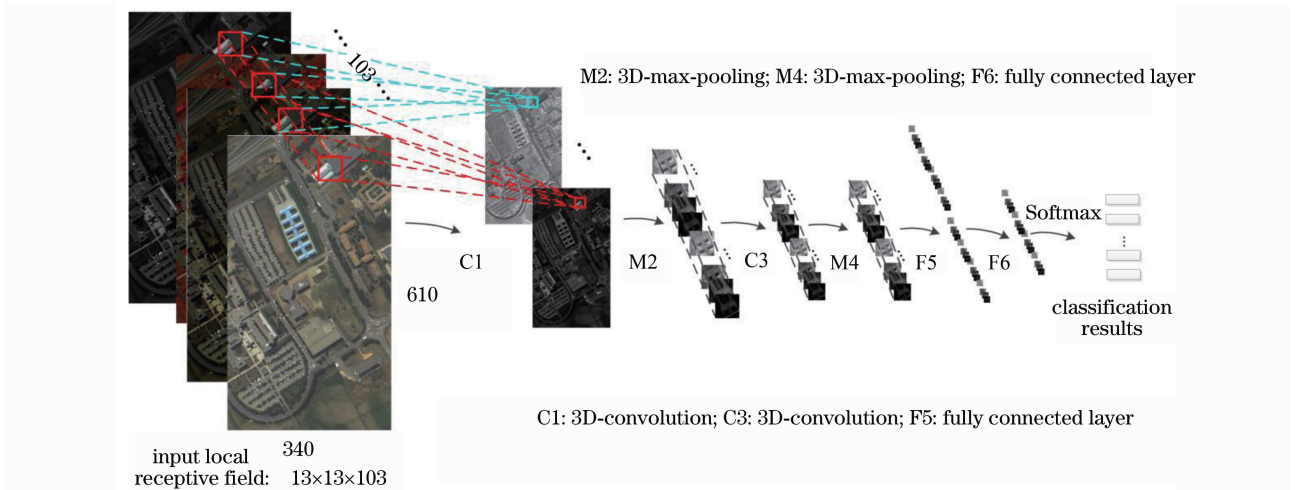


图 2 基于空间-光谱 3D-CNN 模型的高光谱影像分类架构

Fig. 2 Hyperspectral image classification framework based on spatial-spectral 3D-CNN model

基于空间-光谱信息的 3D-CNN 模型结构分类过程如下:

1) 空间-光谱数据构建: 以每个目标像元为中

心,提取大小为 $M \times M \times B$ 的空间-光谱立方体及其标签 l 作为本研究的训练样本。选取训练样本的原则为按比例随机抽取每类像元。 $M \times M$ 为空间

邻域大小,在深度学习中也称为空间感受野; B 为波段数目。

2)3D-CNN 特征提取:整个网络包括两个卷积层、两个最大池化层以及两个全连接层。首先,将步骤 1)提取的维度大小为 $M \times M \times B$ 的空间-光谱立方体作为网络输入。第一个 3D 卷积层 C1 包含 4 个三维卷积核,每个卷积核大小为 $(K_p^l \times K_q^l \times K_r^l)$,卷积步长为 $(s_p^l \times s_q^l \times s_r^l)$ 。经过第一次卷积过后得到 4 个三维卷积核大小为 $\left(\frac{M-K_p^l}{s_p^l}+1\right) \times \left(\frac{M-K_q^l}{s_q^l}+1\right) \times \left(\frac{B-K_r^l}{s_r^l}+1\right)$ 的空间立方体数据。其次进行三维最大池化层 M2 操作。由于局部视野的特征具有统计性,可通过最大池化得到最具代表性的特征。然后再进行第二个三维卷积和三维池化,可以有效地减少空间立方体的数据冗余,从而优化最后全连接层中的参数。最后连接两个全连接层 F5 与 F6 进行特征空间变换,将三维空间特征向量变换成 1×200 维向量,即 3D-CNN 算法所获取深度空间-光谱特征 F 。

3)基于 Softmax 逻辑回归分类:Softmax 分类器可被看作是一个单层的神经网络^[16],目的是找到每个类别的最佳特征组合。将得到的深度空间-光谱特征向量进行回归分类,即每个像元 p_i 属于类别 l 的概率为

$$P(y_i = l | \mathbf{F}_i; \boldsymbol{\theta}) = \frac{\exp(\boldsymbol{\theta}_l^T \mathbf{F}_i)}{\sum_{j=1}^L \exp(\boldsymbol{\theta}_j^T \mathbf{F}_i)}, \quad (2)$$

$$\min_{(\mathbf{W}, \mathbf{b}; \boldsymbol{\theta})} J(\mathbf{W}, \mathbf{b}; \boldsymbol{\theta}) = -\frac{1}{N} \left\{ \sum_{i=1}^N \sum_{l=1}^L \text{sign}(y_i = l) \times \lg[P(y_i = l | \mathbf{F}_i; \boldsymbol{\theta})] \right\}, \quad (3)$$

式中: \mathbf{F}_i 为第 i 个像元的深度空间-光谱特征; y_i 为第 i 个像元的类别标签; $\boldsymbol{\theta}$ 为一个大小为 $k \times (n+1)$ 的参数矩阵, L 为类别个数(同下文标签集合), n 为像元个数。在深度训练过程中,基于交叉熵构造目标函数,并利用最优梯度下降算法^[22]最小化 3D-CNN 的损失函数,如(3)式所示,以实现参数 \mathbf{W} 、 \mathbf{b} 、 $\boldsymbol{\theta}$ 的学习。分类结束后,将得到每个像元所属的标签 l 以及概率 $P(l | p_i)$ 。

2.2 多标签条件随机场优化

利用空间与光谱信息结合的深度学习端对端模型进行分类后,得到了影像中每个像元所属的类别,但由于遥感影像地物中的“空间同质性与异质性”问

题,像元错分现象仍不可避免。因此,将 3D-CNN 模型分类概率与地理空间相结合,提出多标签条件随机场算法,对分类结果进行全局优化。

定义一个无向图结构 $\mathbf{G} = (V, E)$ 来组织高光光谱影像像元, V 为像元节点, E 为一个节点与邻近节点之间的边集合,可通过 K 邻近(KNN)算法求得。从标签集合 $L = \{l_1, l_2, \dots, l_n\}$ 中对每一个像元 p_i 分配标签 l 。将条件随机场算法模型构建在之前的无向图中,目标是在全局节点 V 的标签 l^* 中找到最大后验概率(MAP),它等价于:

$$l^* = \underset{l \in L_n}{\operatorname{argmin}} Q(l), \quad (4)$$

式中: $Q(\cdot)$ 表示能量函数。

通过 3D-CNN 得到每个像元的初始分类概率,采用邻近空间一致性进行多标签条件随机场构建,获得一个全局性分类结果的优化,可高效利用 α - β swap 算法^[23-24]来解决多标签能量目标函数:

$$Q(L | V) = \sum_{i \in V} D_i(l_i) + \lambda \cdot \sum_{(i,j) \in E} V_{ij}(l_i, l_j), \quad (5)$$

$$D_i(l_i) = -\ln P(l_i | p_i), \quad (6)$$

式中: λ 为空间平滑系数; D_i 为数据项, l_i 为第 i 个像元所属的类, $D_i(l_i)$ 可以被写成如(6)式所示的对数形式; $P(l_i | p_i)$ 为标签 l_i 的概率; $V_{ij}(l_i, l_j)$ 为空间平滑项。 $P(l_i | p_i)$ 由 3D-CNN 分类框架逻辑回归得到,希望像元 p_i 属于标签 l_i 的概率是最大的,在这种情况下能量是最小的; $V_{ij}(l_i, l_j)$ 是像元 p_i 与像元 p_j 的传播被限制在一个 k 邻域系统内,构成一个 $N \times N$ 的稀疏矩阵,其中 N 为像元的数量,如图 3 所示。根据 KNN 计算出每个像元的 4 个邻近像元生成一个稀疏矩阵,矩阵中的代价值为 1,代表该两个像元节点是邻近关系。

$$V_{ij}(l_i, l_j) = \begin{cases} 0, & l_i = l_j \\ \omega_{ij} \cdot 1, & l_i \neq l_j \end{cases}, \quad (7)$$

$$\lambda = \exp\left[-\left(\frac{d_{ij}}{\sigma}\right)^2\right], \quad (8)$$

式中: ω_{ij} 为邻近两像元的空间反距离权重; d_{ij} 为两个点的欧氏距离; σ 为所有邻近距离的期望。(7)式对成对的潜在项 V_{ij} 惩罚使得邻近像元 p_i 与 p_j 避免空间标签的不连续($l_i \neq l_j$)。为了优化计算,当 k 取小于像元扩展摩尔邻域个数时(即 $k \leq 24$),每个邻近点的距离与期望距离近似相等,即 $\frac{d_{ij}}{\sigma} \approx 1$,即空间平滑系数 $\lambda \approx e^{-1}$ (e 为自然常数)。

如图 3 所示,蓝色像元和绿色像元分别表示两

类不同的地理空间,3、4、6、7 像元为结点 8 的 4 个邻近像元; $m+1, m+2, m+3, m+7$ 为 m 像元的 4 个邻近像元。生成 $N \times N$ 的稀疏矩阵作为

$E(L|V)$ 能量函数的平滑项。利用图的最小割实现算法收敛和能量递减,解决了像元空间上的分类混淆,得到的分类标签在空间上局部连续全局最优。




图 3 高光谱像元邻接稀疏矩阵示意图。(a) 像元邻接稀疏矩阵;(b) 图像 4 邻域模型($K=4$);(c) 图像 8 邻域模型($K=8$)
 Fig. 3 Illustration of hyperspectral pixel adjacent sparse matrix. (a) Pixel adjacent sparse matrix;
 (b) image four-neighbor model ($K=4$); (c) image eight-neighbor model ($K=8$)

3 实验与分析

为验证算法的有效性,选取公共高光谱数据集 (Indian Pine 数据集、Pavia University 数据集以及 Pavia Center 数据集) 对算法进行测试,将本文提出的 3D-CNN-CRF 算法与 LDM-FL^[17] 算法及改进 CNN^[18] 算法进行纵向比较,并将 3D-CNN-CRF 算法与 2D-CNN 及 3D-CNN 算法进行横向比较,利用类别精度 (CA)、总体精度 (OA) 和 Kappa 系数^[3] 作为算法精度评价指标。以 Pavia Center 数据集为例,分析不同光谱维度的选取对地物目标分类精度的影响。

3.1 数据集

公共高光谱数据集 Indian Pines、Pavia University 以及 Pavia Center (http://www.ehu.eu/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes) 具体细节如下:

1) Indian Pines 数据集: 大小为 $145 \text{ pixel} \times 145 \text{ pixel}$, 拥有 220 个波段。该数据集是 1992 年由机载可见光/红外成像光谱仪 (AVIRIS) 在美国印第

安纳州的一个农场拍摄的航空遥感数据,光谱范围为 $400 \sim 2500 \text{ nm}$, 光谱分辨率为 10 nm 。该场景包含 16 种地物类型,具有比较规则的几何形状,根据土壤湿度不同和耕种情况可细分为多种类别。

2) Pavia University 数据集: 大小为 $610 \text{ pixel} \times 340 \text{ pixel}$, 拥有 103 个波段。该数据集通过反射式成像光谱仪 (ROSIS) 在 Pavia 大学拍摄。该数据集的光谱范围为 $430 \sim 860 \text{ nm}$, 空间分辨率为 1.3 m 。该场景主要是校园建筑和环境,包含 9 种地物类型。

3) Pavia Center 数据集: 大小为 $1096 \text{ pixel} \times 715 \text{ pixel}$, 拥有 102 个波段。该数据集拍摄于一个密集的城市场景,并涵盖广泛地物类别。该数据集光谱范围为 $430 \sim 860 \text{ nm}$, 空间分辨率为 1.3 m , 包含 9 种地物类型。

3.2 参数设置

本文算法的参数主要为 3D-CNN 网络配置参数以及多标签条件随机场空间邻域数量 k 。表 1 中 k_{c1} 为第一个卷积层卷积核的大小; s_{c1} 为第一个卷积层的卷积步长; p_{c1} 为第一个池化层大小; k_{c2} 为第二

个卷积层卷积核大小; s_{c2} 为第二个卷积层的卷积步长; p_{c2} 为第二个池化层大小; f_{c1} 为第一个全连接层隐藏单元大小; f_{c2} 为第二个全连接层的隐藏单元大小; l_r 为学习速率大小; k_{crf} 为多标签条件随机场中

邻近像元数目; λ_{crf} 为多标签条件随机场空间平滑项系数。LDM-FL 算法的参数中, 降维参数 $k_{LDM} = 40$, LDM 分类器参数分别为 $\lambda_{1_LDM} = 1.25 \times 10^5$, $\lambda_{2_LDM} = 5 \times 10^4$, 惩罚参数 $C_{LDM} = 1 \times 10^6$ 。

表 1 不同算法相关参数设置

Table 1 Related parameter settings of different algorithms

Algorithm	Parameter										
	k_{c1}	s_{c1}	p_{c1}	k_{c2}	s_{c2}	p_{c2}	f_{c1}	f_{c2}	l_r	k_{crf}	λ_{crf}
2D-CNN	3×3	[1,1]	2×2	3×3	[1,2]	2×2	400	200	0.005	—	—
3D-CNN	$3 \times 3 \times 6$	[1,1,4]	$3 \times 3 \times 3$	$3 \times 3 \times 6$	[1,1,2]	$3 \times 3 \times 3$	400	200	0.005	—	—
3D-CNN-CRF	$3 \times 3 \times 6$	[1,1,4]	$3 \times 3 \times 3$	$3 \times 3 \times 6$	[1,1,2]	$3 \times 3 \times 3$	400	200	0.005	8	0.375

3.3 实验结果与分析

3.3.1 Indian Pines 数据集实验结果分析

在该数据集下, 算法随机选取 5% 的真值样本像元作为训练集, 其余 95% 的样本像元作为测试样本。测试结果如图 4 所示。

从图 4 的分类可视化效果与表 2 的精度定量分析可以看出, 3D-CNN-CRF 算法优势明显。虽然 LDM-FL 算法在高光谱遥感影像分类中总体精度高达 94.6%, 但仍无法避免分类混淆现象, 从图 4(c) 中可以看出类 C11 与类 C10 出现了分类混

淆, C10 类别精度仅为 87.60%。从图 4(d) 中可以看出, 2D-CNN 算法的分类效果虽然相比 LDM-FL 算法有所改善, 但总体来看地物依然出现类似“椒盐噪声”的分类混淆。从图 4(e) 中可以看出, 3D-CNN-CRF 算法充分结合高光谱数据中丰富的空间和光谱信息, 总体分类精度可达 94.8%, 并且联合多标签条件随机场对分类结果的全局优化效果明显, 分类混淆现象在后验概率及空间邻近的约束下得到了很好地优化, 如图 4(f) 所示, 总体精度最终高达 98.18%, 优于其他同类算法。

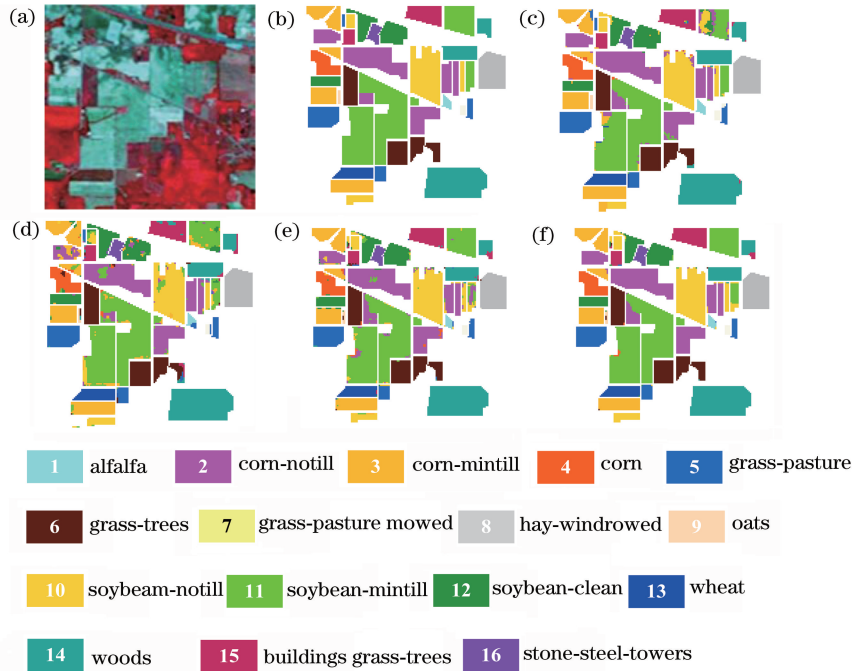


图 4 Indian Pines 数据集不同算法的分类效果对比(16 类)。(a) 伪彩色图; (b) 真值图; (c) LDM-FL; (d) 2D-CNN; (e) 3D-CNN; (f) 3D-CNN-CRF

Fig. 4 Classification results comparison of different algorithms on Indian Pines dataset (16 categories). (a) Pseud color image; (b) true image; (c) LDM-FL; (d) 2D-CNN; (e) 3D-CNN; (f) 3D-CNN-CRF

3.3.2 Pavia University 数据集实验结果分析

在该数据集下, 算法同样随机选取 5% 的真值样本像元作为训练集, 其余 95% 的样本像元作为测

试样本。测试结果如图 5 所示。

LDM-FL 算法对于细长型沥青路面(C1)分类效果不好, 如图 5(c) 中右边十字路口交汇处, 沥青

表 2 Indian Pines 数据集不同算法精度对比结果(16 类)

Table 2 Results of accuracy comparison of different algorithms on Indian Pines dataset (16 categories) %

Accuracy indicator	Category	Algorithm				
		LDM-FL	p-CNN*	2D-CNN	3D-CNN	3D-CNN-CRF
CA	C1	97.87	83.39	100	100	100
	C2	89.67	85.41	96.37	89.60	97.25
	C3	89.64	82.76	78.52	96.04	99.88
	C4	93.60	82.14	89.43	87.40	95.16
	C5	96.47	95.24	93.28	97.20	99.14
	C6	100	99.25	96.24	97.96	99.05
	C7	77.78	91.47	95.45	87.50	100
	C8	100	99.81	100	100	100
	C9	100	90.44	92.31	100	100
	C10	87.60	82.39	93.13	88.58	92.62
	C11	98.61	90.20	92.15	96.97	99.62
	C12	91.21	89.81	87.0	92.93	98.10
	C13	91.93	87.60	98.56	99.01	100
	C14	98.98	96.20	96.03	99.36	99.76
	C15	96.92	91.54	88.37	92.04	94.54
	C16	94.90	93.86	90.29	98.91	98.92
OA		94.6	90.16	92.27	94.85	98.18
Kappa		93.88	89.91	91.21	94.14	97.92

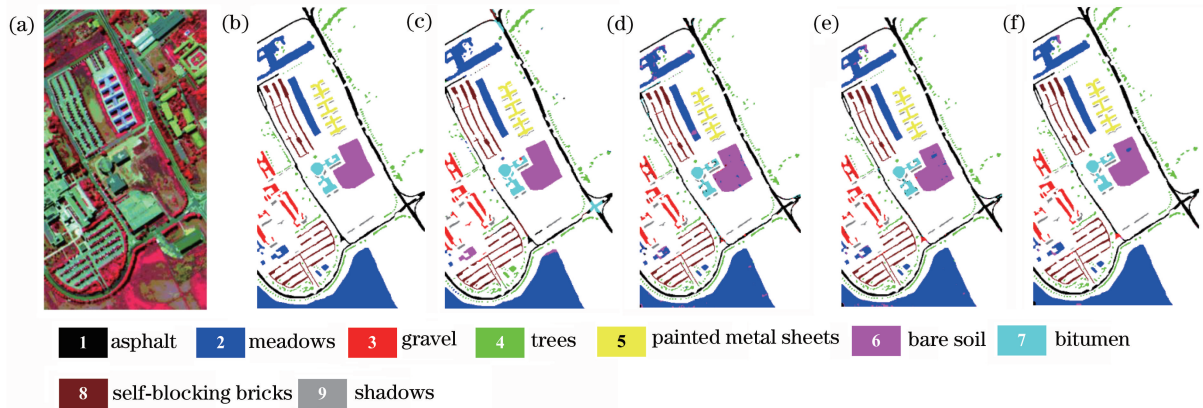


图 5 Pavia University 数据集不同算法的分类效果对比(9 类)。(a) 伪彩色图; (b) 真值图; (c) LDM-FL; (d) 2D-CNN; (e) 3D-CNN; (f) 3D-CNN-CRF

Fig. 5 Classification results comparison of different algorithms on Pavia University dataset (9 categories).

(a) Pseud color image; (b) true image; (c) LDM-FL; (d) 2D-CNN; (e) 3D-CNN; (f) 3D-CNN-CRF

路面(C1)被错分成柏油(C7),使得 C7 精度仅为 71.75%。对于 3D-CNN 算法,尽管结合了像元的空间与光谱信息,但类别相近的地物仍被错分,如图 5(d)与(e)中的裸露土壤(C6)与草地(C2)较难判断。考虑邻近空间的一致性,加入多标签条件随机场优化后,分类过程中类似“椒盐”的混淆噪声得到了很好地优化。从表 3 可以看出,对于 C7 的分类,3D-CNN-CRF 算法的精度比 LDM-FL 算法提升了 26.46%;横向比较,3D-CNN-CRF 算法总体精度比 2D-CNN 算法提高了 3.0%。

3.3.3 Pavia Center 数据集实验结果分析

在该数据集下,算法同样随机选取 5%的真值样本像元作为训练集,其余 95%的样本像元作为测

试样本。比较不同光谱维度的选取对地物目标分类精度的影响,结果如图 6 所示。

如图 6(c)~(e)所示,通过增加光谱特征的维度后发现地物分类效果有显著地提升。从图 6(c)标记框中可以看出,当光谱特征维度为 34 时,柏油(C7)错分成砖制材料类(C4)。如图 6(d)所示,当光谱特征维度增加至 68 时,C7 分类精度提升至 93.1%,但相对于图 6(e),仍出现类别的混淆。图 7 显示了 Pavia Center 数据集在不同维度光谱特征下的分类精度折线图。为了控制变量,3D-CNN-CRF 算法在空间感受野参数 $M=11$ 、空间邻域 $k=8$ 的尺度下进行测试后发现,柏油(C7)与瓦片(C8)对光谱特征维度变化比较敏感,这是由于它们是复合型

表 3 Pavia University 数据集不同算法精度对比(9 类)

Table 3 Results of accuracy comparison of different algorithms on Pavia University dataset (9 categories) %

Accuracy indicator	Category	Algorithm				
		LDM-FL	p-CNN*	2D-CNN	3D-CNN	3D-CNN-CRF
CA	C1	96.03	87.34	97.12	98.22	99.01
	C2	99.03	94.63	99.45	99.34	99.67
	C3	90.42	86.47	89.84	90.46	94.17
	C4	91.99	96.29	98.48	99.28	99.74
	C5	97.8	99.65	100	99.48	99.78
	C6	89.61	93.23	86.85	90.57	95.45
	C7	71.75	93.19	86.12	95.09	98.21
	C8	87.17	86.42	94.46	96.32	98.18
	C9	92.68	100	98.85	98.44	98.23
OA	94	92.56	95.6	97.2	98.6	
Kappa	92.1	91.7	94.7	96.3	98.1	

材质,类内异质性较为明显,故需要更充分地利用辐射光谱的信息,使类间的特征区别性更大,才更利于提高分类的准确性。图 6(f)为 3D-CNN-CRF 算法对实验数据未标记部分的泛化结果,与图 6(a)所示的伪彩色图相比较,分类结果基本正确,抽样检测准确率约 93.7%。

三个数据集的 2D/3D-CNN 训练与测试和优化时间如表 4 所示。本文算法为 Python 与 Matlab 混

合编程,在处理器为 Intel Core i7-5930K 3.50 GHz、图形处理器(GPU)为 NVIDIA GeForce GTX Titan X 的配置下运行。计算了三个数据集中整个分类与优化过程的时间,其中 3D-CNN 训练占用了大部分时间,占总运行时间的 60%左右,与 2D-CNN 相比多耗时近 48%。在未来工作中,将考虑采用 GPU 并行技术来实现并行训练,减少运行时间,提高算法效率。

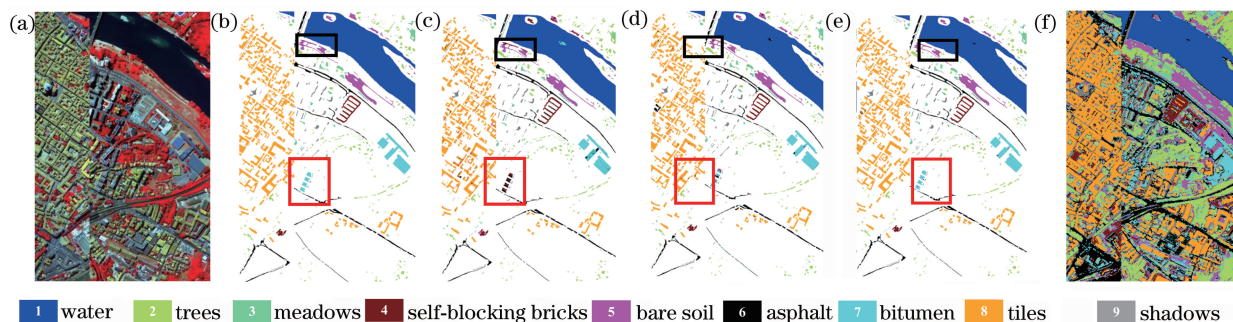


图 6 Pavia Center 数据集分类优化以及未知区域泛化效果图(9 类)。(a)伪彩色图;(b)真值图;(c) 3D-CNN-CRF(特征维度: 34);(d) 3D-CNN-CRF(特征维度: 68);(e) 3D-CNN-CRF(特征维度: 102);(f)未知区域泛化结果

Fig. 6 Classification and unknown region generalization result on Pavia Center dataset (9 categories). (a) Pseud color image; (b) true image; (c) 3D-CNN-CRF (feature dimension: 34); (d) 3D-CNN-CRF (feature dimension: 68); (e) 3D-CNN-CRF (feature dimension: 102); (f) unknown region result

表 4 三个数据集的 2D/3D-CNN 训练与测试和优化时间

Table 4 2D/3D-CNN training, testing and optimization time for three datasets

Dataset	Size of dataset	Algorithm	Time			
			Feature extraction /min	2D/3D-CNN training /min	2D/3D-CNN testing /min	CRF /s
Indian Pines	145×145×220	2D-CNN	0.6	2.6	0.85	—
		3D-CNN-CRF	0.9	3.7	1.2	26.3
Pavia University	610×340×103	2D-CNN	1.3	2.9	1.6	—
		3D-CNN-CRF	1.8	4.3	2.2	32.5
Pavia Center	1096×715×102	2D-CNN	1.7	3.4	1.7	—
		3D-CNN-CRF	2.1	5.3	2.6	42.5

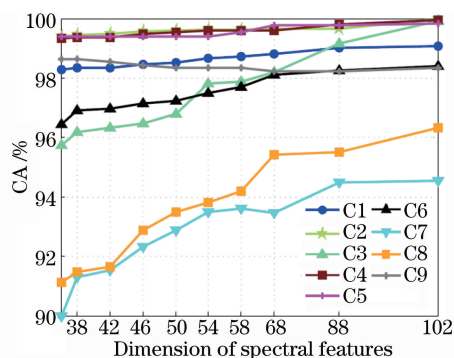


图 7 不同维度光谱特征对分类精度的影响

Fig. 7 Influence of spectral features with different dimensions on classification accuracy

4 结 论

为解决高光谱遥感影像分类后地物分类混淆、总体分类精度低等问题,提出了 3D-CNN-CRF 算法,通过重新设计 3D-CNN 模型架构并充分利用高光谱影像中像素的空间邻域信息与光谱信息,联合多标签条件随机场算法,对分类进行全局优化。方法的稳健性较强,无需刻意调整参数即可达到较高的分类精度。

对公共高光谱数据集的测试结果表明,3D-CNN-CRF 算法提供了一个简单高效的方法来实现高光谱影像的光谱-空间特征提取,并且 3D-CNN 模型是一个轻量级、泛化能力强、收敛速度快的 CNN 模型。算法的最终总体精度可达 98%,优于其他高光谱影像分类算法。

目前,高光谱遥感影像分类的关键在于充分利用地物辐射光谱信息,并提取区别性大、更有代表性的空间-光谱特征。在未来的研究工作中,一方面计划在 3D-CNN 中融合多个尺度卷积核,对特征进行自适应学习以进一步提升分类性能;另一方面考虑采用 GPU 并行技术来实现并行卷积网络训练,减少运算时间,提高算法效率。

参 考 文 献

- [1] Baraniuk R G. More is less: signal processing and the data deluge[J]. Science, 2011, 331(6018): 717-719.
- [2] Li D R, Zhang L P, Xia G S. Automatic analysis and mining of remote sensing big data[J]. Acta Geodaetica et Cartographica Sinica, 2014, 43(12): 1211-1216.
李德仁, 张良培, 夏桂松. 遥感大数据自动分析与数据挖掘[J]. 测绘学报, 2014, 43(12): 1211-1216.
- [3] Sun L, Wu Z B, Liu J J, *et al.* Supervised spectral-spatial hyperspectral image classification with

weighted Markov random fields[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(3): 1490-1503.

- [4] Du P J, Xia J S, Xue Z H, *et al.* Review of hyperspectral remote sensing image classification[J]. Journal of Remote Sensing, 2016, 20(2): 236-256.
杜培军, 夏俊士, 薛朝辉, 等. 高光谱遥感影像分类研究进展[J]. 遥感学报, 2016, 20(2): 236-256.
- [5] Lacar F M, Lewis M M, Grierson I T. Use of hyperspectral imagery for mapping grape varieties in the Barossa valley [J]. Proceedings of the IEEE, 2001, 6: 2875-2877.
- [6] Plaza A, Du Q, Chang Y L, *et al.* High performance computing for hyperspectral remote sensing [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2011, 4(3): 528-544.
- [7] Samaniego L, Bardossy A, Schulz K. Supervised classification of remotely sensed imagery using a modified κ -NN technique[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(7): 2112-2125.
- [8] Ediriwickrema J, Khorram S. Hierarchical maximum-likelihood classification for improved accuracies[J]. IEEE Transactions on Geoscience and Remote Sensing, 1997, 35(4): 810-816.
- [9] Li L, Dong Z L. Color image segmentation using improved graph cuts[J]. Geomatics and Information Science of Wuhan University, 2014, 39(12): 1504-1508.
李磊, 董卓莉. 利用改进图割的彩色图像分割算法[J]. 武汉大学学报(信息科学版), 2014, 39(12): 1504-1508.
- [10] Zhu S P, Yang L. Stereomatching algorithm with graph cuts based on adaptive watershed [J]. Acta Optica Sinica, 2013, 33(3): 0315004.
祝世平, 杨柳. 基于自适应分水岭的图割的立体匹配算法[J]. 光学学报, 2013, 33(3): 0315004.
- [11] Wu J F, Jiang Z G, Zhang H P, *et al.* Hyperspectral remote sensing image classification based on semi-supervised conditional random field [J]. Journal of Remote Sensing, 2017, 21(4): 588-603.
吴俊峰, 姜志国, 张浩鹏, 等. 半监督条件随机场的高光谱遥感图像分类[J]. 遥感学报, 2017, 21(4): 588-603.
- [12] Jia K, Li Q Z, Tian Y C, *et al.* A review of classification methods of remote sensing imagery[J]. Spectroscopy and Spectral Analysis, 2011, 31(10): 2618-2623.
贾坤, 李强子, 田亦陈, 等. 遥感影像分类方法研究进展[J]. 光谱学与光谱分析, 2011, 31(10): 2618-

- 2623.
- [13] Liu J W, Liu Y, Luo X L. Semi-supervised learning methods[J]. Chinese Journal of Computers, 2015, 38(8): 1592-1617.
刘建伟, 刘媛, 罗雄麟. 半监督学习方法[J]. 计算机学报, 2015, 38(8): 1592-1617.
- [14] Song L, Cheng Y M, Zhao Y Q. Hyper-spectrum classification based on sparse representation model and auto-regressive model[J]. Acta Optica Sinica, 2012, 32(3): 0330003.
宋琳, 程咏梅, 赵永强. 基于稀疏表示模型和自回归模型的高光谱分类[J]. 光学学报, 2012, 32(3): 0330003.
- [15] Dong A G, Li J X, Zhang B, *et al.* Hyperspectral image classification algorithm based on spectral clustering and sparse representation[J]. Acta Optica Sinica, 2017, 37(8): 0828005.
董安国, 李佳逊, 张蓓, 等. 基于谱聚类 and 稀疏表示的高光谱图像分类算法[J]. 光学学报, 2017, 37(8): 0828005.
- [16] Zhao W Z, Du S H. Learning multiscale and deep representations for classifying remotely sensed imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 113: 155-165.
- [17] Liu D W, Han L, Han X Y. High spatial resolution remote sensing image classification based on deep learning [J]. Acta Optica Sinica, 2016, 36(4): 0428001.
刘大伟, 韩玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究 [J]. 光学学报, 2016, 36(4): 0428001.
- [18] Mou L C, Ghamisi P, Zhu X X. Deep recurrent neural networks for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7): 3639-3655.
- [19] Mei S H, Ji J Y, Hou J H, *et al.* Learning sensor-specific spatial-spectral features of hyperspectral images via convolutional neural networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(8): 4520-4533.
- [20] Zhan K, Wang H B, Huang H, *et al.* Large margin distribution machine for hyperspectral image classification [J]. Journal of Electronic Imaging, 2016, 25(6): 063024.
- [21] Hu W, Huang Y Y, Wei L, *et al.* Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015(2): 1-12.
- [22] Liu Y, Yin B C, Yu J, *et al.* Image classification based on convolutional neural networks with cross-level strategy[J]. Multimedia Tools and Applications, 2016, 76(8): 11065-11079.
- [23] Boykov Y, Kolmogorov V. An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(9): 1124-1137.
- [24] Fulkerson B, Vedaldi A, Soatto S. Class segmentation and object localization with superpixel neighborhoods[J]. Proceedings of the IEEE, 2009, 30(2): 670-677.