

基于超图和卷积神经网络的高光谱图像分类

刘玉珍^{1**}, 蒋政权^{2*}, 马飞¹, 张春华³

¹ 辽宁工程技术大学电子与信息工程学院, 辽宁 葫芦岛 125105;

² 辽宁工程技术大学研究生院, 辽宁 葫芦岛 125105;

³ 辽宁联通阜新分公司, 辽宁 阜新 123100

摘要 针对高光谱图像数据维数多, 光谱信息和空间信息难以提取的问题, 提出了一种基于超图和卷积神经网络的分类算法, 依据高光谱图像中像素之间的光谱关系和空间关系构建超图; 通过超图构建具有谱空联合特征的样本, 将其送入卷积神经网络进行特征提取, 实现分类。在 3 种常用的高光谱数据集上进行实验, 于 Indian Pines 数据集上取得了 96.63% 的总体分类精度。相比于其他算法, 所提算法的分类精度高、速度快, 而且避免了传统方法在特征提取和融合时出现的不稳定性, 验证了其提取的谱空联合信息对高光谱图像具有更强的特征表达能力。

关键词 图像处理; 高光谱图像; 分类; 超图; 卷积神经网络; 谱空联合信息

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/LOP56.111007

Hyperspectral Image Classification Based on Hypergraph and Convolutional Neural Network

Liu Yuzhen^{1**}, Jiang Zhengquan^{2*}, Ma Fei¹, Zhang Chunhua³

¹ School of Electronics and Information Engineering, Liaoning Technical University,

Huludao, Liaoning 125105, China;

² Graduate School, Liaoning University of Engineering and Technology, Huludao, Liaoning 125105, China;

³ Liaoning Unicom Fuxin Branch, Fuxin, Liaoning 123100, China

Abstract To solve the problem that hyperspectral image data has many dimensions and it is difficult to extract spectral information and spatial information, a classification algorithm is proposed based on a hypergraph and a convolutional neural network. In this algorithm, the hypergraph is first constructed based on the spectral and spatial relationships among pixels in a hyperspectral image, and then a sample with spectral space joint features is constructed through this hypergraph, which is finally sent to the convolutional neural network for feature extraction and thus the classification is finally achieved. The experiment is performed on three most commonly used hyperspectral datasets and an overall classification accuracy of 96.63% on the Indian Pines dataset is achieved. Compared with other algorithms, the proposed algorithm has a high classification accuracy and a high speed, which avoids the instability in feature extraction and fusion by traditional methods. It is verified that the spectral space joint information extracted by the proposed algorithm has a strong feature expression of hyperspectral images.

Key words image processing; hyperspectral image; classification; hypergraph; convolutional neural network; spectral space joint information

OCIS codes 100.4145; 100.4996; 100.2000

1 引言

高光谱图像是由高光谱遥感仪采集从可见光区

域到短红外光区域的光谱时获得的, 其通常包含上百个连续的光谱通道。高光谱图像集样本的图像信息与光谱信息于一身。其中, 图像信息可以反映样

收稿日期: 2018-08-28; 修回日期: 2018-10-04; 录用日期: 2018-10-29

基金项目: 辽宁省教育厅高等学校基本科研项目(LJ2017QL014)

* E-mail: 29360942@qq.com; ** E-mail: 825807294@qq.com

本的大小、形状、纹理等外部品质特征,而光谱信息则充分反映样品内部物理结构、化学成分的差异。由于不同成分对光谱吸收不同,故在某个特定波长下图像对某个缺陷会有较显著的反映。这些特点决定了高光谱图像技术在农产品品质、食品安全、环境污染状况的检测等方面具有独特的优势。

高光谱图像分类是一个重要且复杂的高光谱图像应用问题,与传统的图像分类任务^[1]相比较,高光谱图像分类的难点在于有限的训练样本和高维的数据特征。由于高光谱数据的多维性,光谱通道选择和数据特征降维在分类中扮演着重要的角色。以前大多数研究者的工作都集中在特征降维上。传统的特征降维方法有:独立成分分析(ICA)^[2]、主成分分析(PCA)等。就分类而言,广泛应用的方法是K近邻分类算法(KNN)和支持向量机(SVM)^[3-4]。文献^[5]中利用像素构造流形结构,并对其进行局部流形学习,再采用加权KNN分类器进行分类。该方法^[6]和高斯成分^[7]构造的半监督分类方法也在高光谱图像分类中得到应用。

在高光谱图像分类任务中,探索邻域内像素之间

的关系和选择有代表性的特征数据是一个关键性的问题。上述分类方法虽然有效地降低了高光谱数据的特征维数,但同时也丢失了一些重要的光谱特征信息和空间特征信息。近年来,卷积神经网络(CNN)由于其在特征提取和分类任务中的出色表现,成为图像分类、目标检测、图像增强等众多领域研究的热点。本文提出了一种基于超图和卷积神经网络(G-CNN)的高光谱图像分类算法,利用超图探索高光谱图像中像素之间的空间特征关系和光谱特征关系。同时,提出了一种新颖的卷积神经网络模型,该模型能够有效地降低高光谱数据的特征维数并提取数据特征。

2 所提算法

所提出的基于超图和卷积神经网络的高光谱图像分类模型(G-CNN)如图1所示。首先利用超图表达高光谱图像像素之间的空间关系和光谱特征关系;基于图的超边和权重加权处理图中的像素,将不同像素之间的空间关系和光谱特征关系融合,得到加权后的谱空联合特征;再利用卷积神经网络进行特征降维和特征提取,实现分类结果。

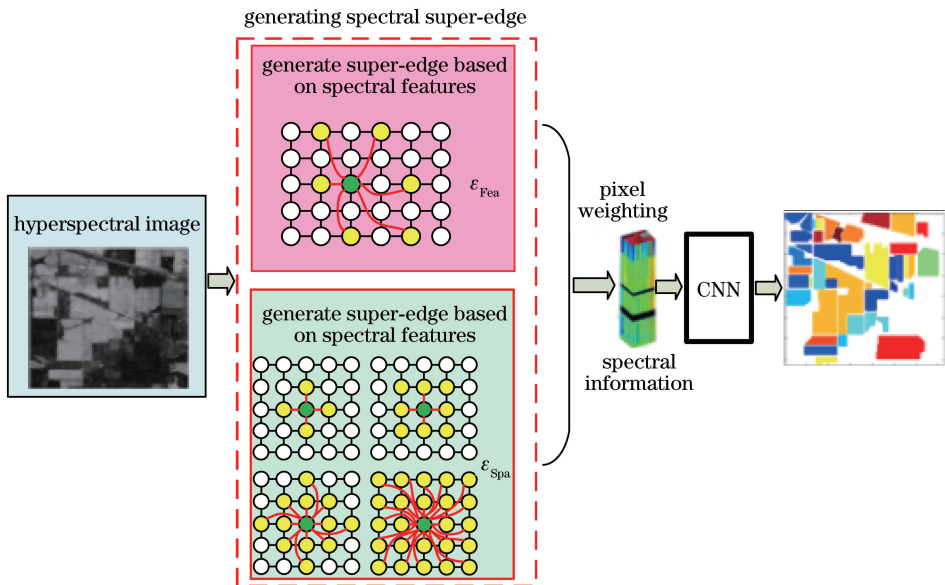


图1 G-CNN分类模型图

Fig. 1 Schematic of G-CNN classification model

2.1 超图的构建

由于超图具有捕获样本高阶关系的能力,其结构已应用在图像检索的框架中^[8]。其中,每一个超图的顶点代表一张图片。超图的结构更进一步地应用在多媒体信息服务上。Bu等^[9]提出了音乐推荐系统的超图学习方法,其中音乐的社交网络中的多种类型对象的关系由超图结构表示,用于测量音乐

推荐系统中音乐轨迹之间的关系。

鉴于超图表示对象高阶关系的高效性,所提算法采用其表示高光谱图像中不同像素之间的关系。通过观察,高光谱图像具有以下的特点:

- 1) 在光谱特征空间中相近的像素很大可能具有相同的标签。
- 2) 空间中相邻的像素很大可能具有相同的标

签,由于高光谱图像表示真实的地物场景,每种地物类型的表面像素通常在一个区域中扩散,因此每个像素应该和其空间相邻的像素具有相同的标签。

图 2 是由机载红外光谱仪(AVIRIS)拍摄的北印第安纳地区的真实场景图。其中,A、B两像素在空间上是相邻的关系,具有相同的标签;A、C两像素在光谱特征上具有相似性,并具有相同的标签;而D像素无论在空间上还是在光谱特征上都不与A像素近邻,其具有不同的标签。




图 2 高光谱图像的谱空信息关系

Fig. 2 Relationship between spectral and spatial information of hyperspectral images

构造空间关系和光谱关系两种类型的超图能够更好地表达不同像素之间的谱空关系。为了构造光谱关系和空间关系的超图,所提算法把高光谱图像中的每个像素 $X = \{x_1, x_2, \dots, x_z\}$ 看作超图 $G = \{V, \epsilon, W\}$ 中的一个顶点,其中: z 为高光谱图像的光谱维数; G 为超图; V 为超图中顶点的集合; ϵ 为超图中超边的集合; W 为超边权重的集合。如图 1 所示,算法构建的两类超边包括基于光谱关系的超边 ϵ_{Fea} 和基于空间关系的超边 ϵ_{Spa} 。

1) 基于光谱关系的超边:在光谱空间中,用超边连接相似性较大的像素,并赋予超边较大的权重,这意味着所有超边连接的像素应该具有相同的标签。常用的定义像素之间光谱相似度的方法有两种,即欧氏距离和光谱角距离。Sohn 等^[10]验证了利用光谱角距离度量光谱空间中像素之间的距离比欧氏距离更加准确。故本文采用光谱角距离来度量光谱空间中像素之间的相似性。在高光谱图像中,每个像素视为一个中心顶点,使用中心顶点的 K 个近邻像素构成超边。因此,在每个超边中,总共有 $K+1$ 个顶点。图 3 展示了基于光谱关系的超图的构建。

如图 3 所示,算法选择 $5 \text{ pixel} \times 5 \text{ pixel}$ 的窗口 P 构建超图,绿色点为中心像素点,而黄色点与绿色点在光谱特征上相似,所以可用超边来连接。在此例中,中心像素有 6 个光谱特征相邻的像素,超边连接 7 个像素点。




图 3 基于光谱特征的超边构建

Fig. 3 Super-edge construction based on spectral features

每条超边 $e_i \in \{\epsilon_{\text{Fea}}\}$ 提供一个权重 $w_{\text{Fea}}(e_i)$,这个权重根据超边连接的两个像素之间的光谱角距离度量,表示为

$$w_{\text{Fea}}(e_i) = \exp\left[-\frac{D_{\text{Fea}}(v_i)}{2\sigma^2}\right], \quad (1)$$

式中: σ 为中心像素和所有超边连接的像素的平均值, $\sigma = \frac{1}{n} \sum_{i=1}^n D_{\text{Fea}}(v_i)$; $D_{\text{Fea}}(v_i)$ 为第 i 个像素和中心像素之间的光谱角距离,表示为

$$D_{\text{Fea}}(v_i) = \arccos\left(\frac{v \cdot v_i}{|v| |v_i|}\right), \quad (2)$$

其中, v 为中心像素, v_i 为第 i 个像素。通过(1)式可知,像素之间的距离越小,赋予的权值越大。

对于基于光谱特征的超边 $e_i \in \{\epsilon_{\text{Fea}}\}$,超图 G 的关联矩阵 H_{Fea} 表示为

$$H_{\text{Fea}}(v, e_i) = \begin{cases} \mathbf{1}, & \text{if } D_{\text{Fea}}(v_i) < \delta \\ \mathbf{0}, & \text{if } D_{\text{Fea}}(v_i) > \delta \end{cases}, \quad (3)$$

式中: δ 为光谱特征相似度。基于图的构建规则,由超边 $e_i \in \{\epsilon_{\text{Fea}}\}$ 连接的两个像素具有高的相似性,这种定义规则充分探索了像素之间的光谱特征关系。

2) 基于空间关系的超边:基于空间关系的超边是由中心像素和其空间邻域的像素构成,在这个过程中,高光谱图像中每个像素可看作是图中的顶点,图 4 展示了 4 种中心像素和邻域像素的关系。

在图 4 中,绿色像素为中心像素,黄色像素为与中心像素相连接的邻域像素,图 4(a)~(d)分别为 4 邻域、8 邻域、12 邻域和 24 邻域,距离中心像素的距离 D_{Spa} 分别用 2、3、4、5 表示。假设选择的邻域大小为 U ,在一个超图中总共有 $U+1$ 个顶点,每一个超边 $e_i \in \{\epsilon_{\text{Spa}}\}$ 提供了一个权重 $w_{\text{Spa}}(e_i) = 1/D_{\text{Spa}}$,超图 G 的关联矩阵 H_{Spa} 表示为

$$H_{\text{Spa}}(v, e_i) = \begin{cases} \mathbf{1}, & \text{if } v_i \in U \\ \mathbf{0}, & \text{if } v_i \notin U \end{cases} \quad (4)$$

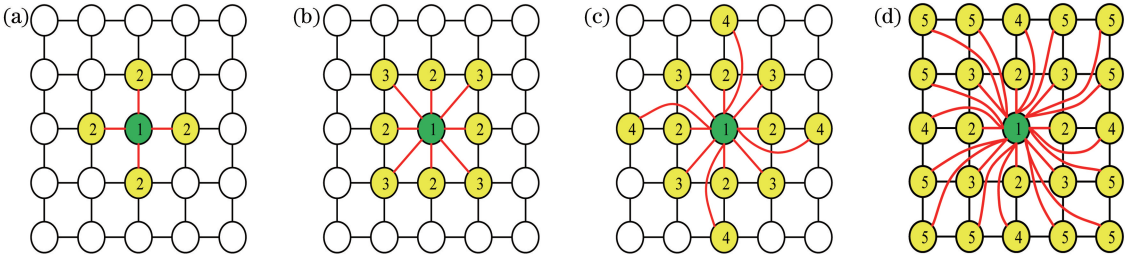


图 4 空间关系的超图构造。(a) 4 邻域;(b) 8 邻域;(c) 16 邻域;(d) 24 邻域

Fig. 4 Hypergraph construction of spatial relationship. (a) 4 neighborhood; (b) 8 neighborhood; (c) 16 neighborhood; (d) 24 neighborhood

在生成关联矩阵 \mathbf{H}_{Fea} 和 \mathbf{H}_{Spa} 后,中心像素和图中的像素作加权处理,就组成了具有谱空特征信息的样本,其计算式表示为

$$x_{m,n} = v + \sum_{i=1}^{L_{\text{Fea}}} \omega_{\text{Fea}}(e_i) \mathbf{H}_{\text{Fea}}(v, e_i) + \sum_{i=1}^{L_{\text{Spa}}} \omega_{\text{Spa}}(e_i) \mathbf{H}_{\text{Spa}}(v, e_i), \quad (5)$$

式中: $x_{m,n}$ 为高光谱图像中 m, n 位置加权后的像素; L 为超边的数量。

2.2 CNN 分类

对于目标像元 $x_{m,n} \in \mathbf{R}^z$ 为一个一维的张量,将其作为 CNN 的输入进行分类。如图 5 所示,CNN 的网络结构共包含 7 层,分别为输入层、卷积层 C_1 、最大池化层 M_2 、卷积层 C_3 、最大池化层 M_4 、全连接层 F_5 和输出层。 N_d 为第 d 个网络层数据特征的维数;24 为每层特征图的个数,对于第 d 个网络层的第 j 个特征图的位置 x 的神经元 $q_{d,j}^{(x)}$,其计算式表示为

$$q_{d,j}^{(x)} = g[b_{d,j} + \sum_m \sum_{p=0}^{P_d-1} \omega_{d,j,m}^{(p)} \cdot q_{(d-1),m}^{(x+p)}], \quad (6)$$

$$g(x) = \text{relu}(x) = \max(0, x), \quad (7)$$

式中: m 为连接当前神经元的上一层的特征图; $\omega_{d,j,m}^{(p)}$ 为连接到第 m 个特征图的位置 p 的权重; P_d 为卷积核的宽度; $b_{d,j}$ 为第 d 层第 j 个特征图的偏置项;relu 为修正线性单元。最后模型采用 Softmax 回归模型来计算每个类别的得分,其定义式表示为

$$y_k = \exp \left[\frac{N_{7k}}{\sum_{N_7} \exp(N_k)} \right], \quad (8)$$

式中: y_k 为第 k 个类别的得分; N_{7k} 为 N_7 中的每一个元素的值。

3 实 验

所提算法均用 python 编写,操作系统为

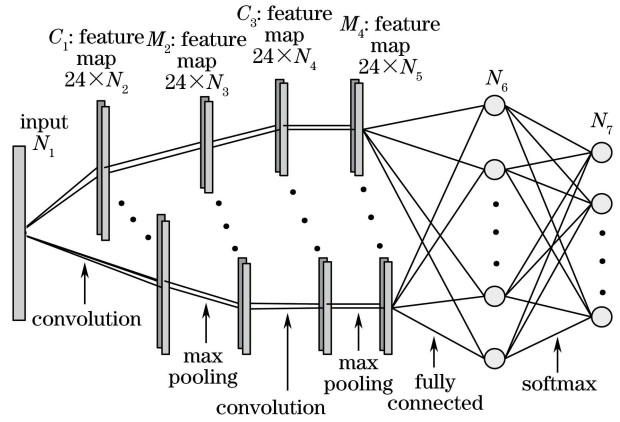


图 5 CNN 分类模型图

Fig. 5 Schematic of CNN classification model

ubuntu14, 计算机机配备 Intel I7 6850K、3.6 GHz 处理器和 Nvidia TITAN Xp 图形处理器。所用的评价指标主要包括总体分类精度(OA)、平均分类精度(AA)以及 Kappa 系数。其中,总体分类精度是最简单直观的一种衡量分类性能好坏的指标,平均分类精度表示的是每一类样本的分类精度的平均值,Kappa 系数利用混淆矩阵中的所有因子,从而更加全面地反映分类结果。为了使实验结果更具有说服力,取 10 次实验的平均值作为最终的实验结果。

3.1 实验数据集

在 3 种常用的高光谱数据集上进行实验,分别为 Indian Pines、University of Pavia 和 Salinas。此外,为了加快网络的收敛速度,实验中把每一个像素点都归一化到 $[-1.0, +1.0]$ 之间。

Indian Pines 数据集由 AVIRIS 光谱仪在北印第安纳州西部的 Indian Pines 地区采集得到。数据集图片大小为 $145 \text{ pixel} \times 145 \text{ pixel}$,由 220 个光谱通道组成,光谱变化范围为 $0.4 \sim 2.5 \mu\text{m}$,空间分辨率为 20 m。去除 20 个水吸收波段,剩余 200 个波段应用在实验中。数据集一共有 16 个地物类别,由于一些地物类别的数量非常少,为了排除小样本因

素的干扰,最终选择 8 个地物类别。

为了选择合适的训练样本数目,在本数据集上分别选取训练样本数目为 50、100、200、300 做实验,实验结果如图 6 所示,图中 Epoch 表示网络模型被训练的次数。算法的训练精度随着训练样本数目的增加而增加,当训练样本数目达到 200 时,样本数目已经充分满足算法对训练数据特征拟合的要求,增加训练样本数目为 300 时,算法精度的提升效果并不理想。同时为了和其他算法作公平对比,展现有限的训练样本对算法性能的影响,在每个地物类别中选取 200 个样本作为训练集,剩余的样本作为测试集。详细的信息如表 1 所示。

Pavia of University 图像数据集是通过 ROSIS-03 光学传感器捕获帕维亚大学城市区域获得的。该场景大小为 $610 \text{ pixel} \times 340 \text{ pixel}$,空间分辨率高达 1.3 m 。在 Pavia of University 数据集中,原始的光谱带数量为 115,去除 12 个噪声光谱带,剩余 103 个光谱带被保留在实验中。场景中包含 9 个地物类别,训练集和测试集的样本数目与表 1 类似,每个




图 6 训练样本数目对算法精度的影响

Fig. 6 Effect of number of training samples on accuracy of algorithm




图 7 实验参数变化对实验精度的影响。(a) P ; (b) U ; (c) δ

Fig. 7 Influence of experimental parameter change on experimental precision. (a) P ; (b) U ; (c) δ

利用(5)式将超图中的像素做加权处理,得到具有谱空信息的一维特征向量 $\mathbf{X}_{m,n}$,输入卷积神经网络之后,通过卷积层、最大池化层特征提取和全连接层特征融合,经过输出层完成分类。设卷积层 C_1 的卷积核尺寸为 t_1 、步长为 s_1 ,池化层 M_2 的核尺寸为 t_2 、核步长为

表 1 Indian Pines 数据集的训练样本和测试样本数
Table 1 Number of training samples and test samples in Indian Pines dataset

No.	Class	Number of training samples	Number of teat samples
1	Corn-notill	200	1228
2	Corn-mintill	200	630
3	Grass-pasture	200	283
4	Hay-windrowed	200	278
5	Soybean-notill	200	772
6	Soybean-mintill	200	2255
7	Soybean-clean	200	393
8	Woods	200	1065
Total		1600	6904

地物类别随机选取 200 个样本作为训练集,剩下的样本作为测试集。

Salinas 数据集是在 1998 年由 AVIRIS 传感器拍摄加利福尼亚州萨利纳斯山谷获得的。数据集大小为 $512 \text{ pixel} \times 217 \text{ pixel}$,高空间分辨率高达 3.7 m 。在 Salinas 数据集中有 224 个光谱带,去除 20 个水吸收光谱带,在实验中保留了 204 个光谱带。数据集中有 16 个地物类别,训练集和测试集的样本数目与表 1 类似,在各个地物类别中随机选取 200 个样本作为训练集,剩余的样本作为测试集。

3.2 实验参数设置

为了确定不同的超参数对所提算法的精确度的影响,针对不同的窗口大小 P 和邻域大小 U ,算法在 Indian Pines 数据集上做大量的实验,实验的结果如图 7 所示。分类精确度均会随 P 、 U 和 δ 值呈先升高后下降的趋势,实验选择窗口尺寸 $P=9$ 、邻域大小 $U=24$ 、阈值 $\delta=0.0486$,构建具有谱空信息的超图。

s_2 ,同样地,卷积层 C_3 和池化层 M_4 的核尺寸和步长分别为 t_3 、 s_3 和 t_4 、 s_4 。通过公式 $N_{i+1}=(N_i-t_i)/s_i+1$ 可以计算卷积层和池化层特征的维数 $N_2 \sim N_5$ 。全连接层神经元的个数 N_6 以及输出层的神经元个数 N_7 在 3 个数据集上的值如表 2 所示。

表2 卷积神经网络参数设置

Table 2 Parameter setting of convolutional neural network

Dataset	t_1	s_1	t_2	s_2	t_3	s_3	t_4	s_4	N_6	N_7
Indian Pines	21	1	2	2	21	1	2	2	100	8
University of Pavia	10	1	2	2	10	1	2	2	100	9
Salinas	21	1	2	2	21	1	2	2	100	16

3.3 实验结果与分析

为了测试所提算法的性能,将本文算法同传统的 SVM 算法、超图与 SVM 结合算法(G-SVM)作对比。SVM 算法是利用林智仁开发的软件包(LIBSVM)^[11]实现的,对于 SVM 模型,实验中选用径向基核函数,参数 $C=121$ 、 $\gamma=0.4$ 。由于卷积神经网络是一个深度模型分类器,因此所提算法还与

表3 Indian Pines 数据集上不同算法的训练时间和测试时间

Table 3 Training time and test time for each algorithm on Indian Pines dataset

Item	SVM	G-SVM	Shallower CNN	Contextual Deep CNN	SPPF CNN	G-CNN
Training time	0.21	4.74	287.16	431.71	2704.34	337.08
Testing time	1.12	0.92	0.23	3.35	19.57	0.29

由表3可知,SVM 模型简单,所需的训练时间较少,虽然 G-SVM 算法增加了模型的训练时间,但是该模型用于测试的时间明显降低,这表明加入超图的 SVM 算法更容易区分数据之间的差异性。SPPF CNN 模型最为复杂,所需的训练时间和测试时间相对较长。由于 G-CNN 算法中添加了超图的运算,所以该算法的训练时间比模型较简单的 Shallower CNN 长一些,而测试时间却没有明显的提高。

其他的卷积神经网络模型算法作对比,主要包括 Shallower CNN 模型^[12]和 Contextual Deep CNN 模型^[13]以及空间像素对卷积神经网络(SPPF CNN)模型^[14]。在实验中,用训练集训练每个算法,当算法充分拟合高光谱数据后,用测试集测试每个模型分类精度,表3给出了每个算法在 Indian Pines 数据集上的训练时间和测试时间。

图8给出了 Indian Pines 数据集的真实场景图和每个模型分类后的效果图。SVM 分类器在每个类别中都存在较高的错分率,将超图算法加入 SVM 分类器后,每个类别中的错分率明显降低。G-CNN 模型较其他模型分类效果有较大的提升,Shallower CNN 模型、Contextual Deep CNN 模型、SPPF CNN 模型在 Soybean-notill 和 Soybean-mintill 类别中错分率较高,而 G-CNN 模型降低了这两个类别的错分率。




图8 不同算法在 Indian Pines 上分类效果图。(a)真实地图物;(b)支持向量机;(c)图-支持向量机;(d)浅层卷积神经网络;(e)上下文深度卷积神经网络;(f)空间像素对卷积神经网络;(g)图-卷积神经网络;(h)标签

Fig. 8 Classification results by different algorithms on Indian Pines dataset. (a) Ground-truth; (b) SVM; (c) G-SVM; (d) Shallower CNN; (e) Contextual Deep CNN; (f) SPPF CNN; (g) G-CNN; (h) label

表 4 给出了不同算法总体分类精度的精确值,传统的 SVM 分类算法分类精度较低,但将超图和 SVM 算法结合之后分类精度明显提高,在每个数据集上提高 3%~4%,但是和神经网络分类模型还有一定的差距。Shallower CNN 神经网络模型由于其结构比较简单,且没有加入高光谱数据的空间信息,只利用光谱信息作类别分类,分类精度较低。而 Contextual Deep CNN 和 SPPF CNN 均融入高光谱数据的空间信息,所以分类结果有所提高,但是其模型复杂,对高光谱数据的谱空特征提取不精确。而 G-CNN 不仅将高光谱数据空间信息和光谱信息融合,还能很好地提取重要的谱空特征,所以分类精度均高于其他算法。

表 4 3 个数据集上不同算法的总体分类精度

Table 4 Overall classification accuracy of each model on three datasets %

Algorithm	Indian	University	Salinas
	Pines	of Pavia	
SVM	85.86	86.83	87.12
G-SVM	89.40	90.91	90.97
Shallower CNN ^[12]	90.12	92.34	92.18
Contextual Deep CNN ^[13]	93.30	95.01	95.47
SPPF CNN ^[14]	94.87	91.74	94.21
G-CNN	96.63	97.42	97.27

表 5 给出了 G-CNN 在 3 个数据集上分类的具体精度。采用 3 种最常用的分类评价指标,可以得到比较相近的结果,这表明 G-CNN 分类算法比较稳定。

表 5 G-CNN 分类结果

Table 5 G-CNN classification results %

Parameter	Indian	University	Salinas
	Pines	of Pavia	
OA	96.63	97.42	97.27
AA	96.87	97.83	97.44
Kappa	96.54	97.18	97.12

4 结 论

由于高光谱数据的空间特征信息和光谱特征信息同等重要,为了更好地探索这种谱空联合信息,利用超图表示高光谱图像像素之间的关系,通过超边连接特征空间中相似的像素,根据超边权重对不同的像素作加权求和,获得具有谱空联合特征的高光谱数据样本。采用卷积神经网络对样本的数据特征进行提取、降维,实现分类。与传统的 SVM 分类器相比,卷积神经网络对数据特征的提取和拟合更具

有优势。而同其他卷积神经网络相比,所提算法利用光谱关系和空间关系分别构建超图,依据超边将超图中的像素作加权处理,形成具有谱空联合信息的样本,从而最大限度地避免由“同谱异物”或“同物异谱”带来的近邻选择错误问题。同时,这种具有谱空联合信息的样本能够缩小类内差异性及扩大类间可分性。从实验来看,所提算法的分类精度高于其他算法,这表明其所提取的谱空联合特征更具有表示性。今后将利用正则化、反差网络进一步提高卷积神经网络的训练速度和分类精度。

参 考 文 献

- [1] Zha Z J, Hua X S, Mei T, *et al.* Joint multi-label multi-instance learning for image classification[C] // 2008 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2008, Anchorage, AK, USA. New York: IEEE, 2008: 4587384.
- [2] 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.
- [3] Marconcini M, Camps-Valls G, Bruzzone L. A composite semisupervised SVM for classification of hyperspectral images [J]. IEEE Geoscience and Remote Sensing Letters, 2009, 6(2): 234-238.
- [4] Archibald R, Fann G. Feature selection and classification of hyperspectral images with support vector machines [J]. IEEE Geoscience and Remote Sensing Letters, 2007, 4(4): 674-677.
- [5] Ma L, Crawford M M, Tian J W. Local manifold learning-based k -nearest-neighbor for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010: 4099-4109.
- [6] Camps-Valls G, Bruzzone L. Kernel-based methods for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(6): 1351-1362.
- [7] Berge A, Schistad Solberg A H. Structured Gaussian components for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(11): 3386-3396.
- [8] Huang Y C, Liu Q S, Zhang S T, *et al.* Image retrieval via probabilistic hypergraph ranking [C] // 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, June 13-18, 2010, San Francisco, CA, USA. New York:

- IEEE, 2010: 5540012.
- [9] Bu J J, Tan S L, Chen C, *et al.* Music recommendation by unified hypergraph [C] // Proceedings of the international conference on Multimedia - MM'10, October 25-29, 2010, Firenze, Italy, 2010. New York: ACM, 2010: 391-400.
- [10] Sohn Y, Rebello N S. Supervised and unsupervised spectral angle classifiers [J]. Photogrammetric Engineering & Remote Sensing, 2002, 68(22):1271-1280.
- [11] Chang C C, Lin C J. LIBSVM: a library for support vector machines [J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 27.
- [12] Hu W, Huang Y Y, Wei L, *et al.* Deep convolutional neural networks for hyperspectral image classification [J]. Journal of Sensors, 2015, 2015: 258619.
- [13] Lee H, Kwon H. Going deeper with contextual CNN for hyperspectral image classification [J]. IEEE Transactions on Image Processing, 2017, 26(10): 4843-4855.
- [14] Ran L Y, Zhang Y N, Wei W, *et al.* A hyperspectral image classification framework with spatial pixel pair features [J]. Sensors, 2017, 17(10): 2421.