

基于3D卷积联合注意力机制的高光谱图像分类

王浩¹, 张晶晶¹, 李园园¹, 王峰², 寻丽娜¹

(1. 安徽大学 电气工程与自动化学院 计算智能与信号处理教育部重点实验室, 安徽 合肥 230601;

2. 偏振光成像探测技术安徽省重点实验室, 安徽 合肥 230031)

摘要: 由于高光谱图像存在较高的数据维数, 会给分类过程带来一些困难。为了提高分类的准确率, 提出了一种使用3D卷积联合注意力机制的高光谱图像分类方法。首先, 将中心像素与周围相邻的其它像素进行配对, 可以通过配对构成多组新的像素对, 充分利用了像素之间的邻域相关性。接着, 将像素对放入3D卷积联合注意力机制网络框架中进行分类, 它能够对高光谱图像中的特征进行选择性的学习。最后, 通过投票策略获得像素标签。实验是在两个真实的高光谱图像数据集上进行。结果表明, 所提出的方法充分挖掘了高光谱图像的光谱空间特征, 能有效地提高分类精度。

关键词: 高光谱图像分类; 注意力机制; 深度学习; 像素配对

中图分类号: O235 文献标识码: A 文章编号: 1001-8891(2020)05-0264-08

Hyperspectral Image Classification Based on 3D Convolution Joint Attention Mechanism

WANG Hao¹, ZHANG Jingjing¹, LI Yuanyuan¹, WANG Feng², XUN Lina¹

(1. Key Laboratory of Computational Intelligence and Signal Processing, Ministry of Education,

School of Electrical Engineering and Automation, Anhui University, Hefei 230061, China;

2. Key Laboratory of Polarization Imaging Detection Technology, Hefei 230031, China)

Abstract: The high data dimension of hyperspectral images causes difficulties in the classification process. To improve the accuracy of classification, a hyperspectral image classification method using a 3D convolution joint attention mechanism is proposed. First, by pairing the center pixel with other pixels adjacent to it, it can form multiple sets of new pixel-pairs, and the neighborhood correlation between the pixels can be fully utilized. Then, the pixel-pairs are classified into the 3D convolution joint attention mechanism network framework, which can selectively learn the features in the hyperspectral image. Finally, the pixel label is obtained through the voting strategy. An experiment was carried out on two real hyperspectral image datasets. The results show that the proposed method fully exploits the spectral-spatial features of hyperspectral images, and this can effectively improve the classification accuracy.

Key words: hyperspectral image classification, attention mechanism, deep learning, pixel-pairs

0 引言

近年来, 国内外高光谱遥感技术得到了快速发展, 因此在农业, 环境科学, 地物观测等方面取得了广泛的应用^[1-4]。高光谱图像(Hyperspectral Image, HSI)是一个三维立方体的图像数据, 它是由二维数字图像和一个光谱维度组成, 包含几十甚至几百个连续的光谱波段, 可以利用这些光谱信息对图像进行分

类。常用的分类方法包括: K最近邻(K Nearest Neighbor, K-NN)^[5-7], 极端学习机(Extreme Learning Machine, ELM)^[8]以及支持向量机(Support Vector Machine, SVM)^[9-11]等, K最近邻是最简易的分类器, 这些都是充分依赖光谱信息进行分类, 而不是利用像素之间的空间信息。其中, 极端学习机(ELM)是一种有效的高光谱图像数据分类方法, 对分类准确率的提高是非常有效。支持向量机(SVM)是以数量不多

收稿日期: 2019-07-12; 修订日期: 2020-02-29。

作者简介: 王浩(1992-), 男, 硕士, 主要从事高光谱图像分类的研究。E-mail: 386943738@qq.com。

通信作者: 张晶晶(1974-), 女, 博士, 副教授, 主要从事偏振图像算法研究。E-mail: 874878644@qq.com。

基金项目: 安徽省自然科学基金(1808085MF209); 偏振光成像探测技术安徽省重点实验室开放基金(2019KJS030009)。

的样本为前提,通过探求网络模型的复杂程度和学习能力之间的最好调和,得到最佳的分类准确率。另外,目前还有一些常用的特征选择方法用于高光谱图像分类,例如:主成分分析(Principal Component Analysis, PCA)^[12-13],它可以使用频段选择来减少噪声和一些不重要的特征,有效地保留最重要的一些特征,有助于高光谱图像分类。独立成分分析(Independent Component Analysis, ICA)^[14]是一种利用统计原理进行计算的方法,具有运算复杂程度低的特点。

近些年基于深度学习的图像分类方法^[15-18]受到普遍的关注。文献[19]提出了一种基于深度卷积神经网络(Convolutional Neural Network, CNN)学习的像素对特征的新型框架(Convolutional Neural Network Pixel-Pair Feature, CNN-PPF),利用像素配对增加训练样本的数量,确保输入数据有足够的数量,这样可以在CNN中学习大量的参数。但是采用的像素配对方法没有充分考虑像素之间的邻域相关性,不能很好地利用像素之间的特征信息。文献[20]提出了一种三维卷积神经网络(3D Convolutional Neural Network, 3D-CNN),用于高光谱图像分类。该方法比其它基于深度学习的方法需要更少的参数,发生过拟合的概率更小。但是目标在提取特征过程中,提取每个特征的权重是相同的,不能有效地区分不同特征的重要程度,这样并不利于分类。递归神经网络(Recurrent Neural Network, RNN)^[21]对顺序数据的处理是非常有效的,可以作为序列数据很好地分析高光谱图像像素,通过神经网络确定信息类别。但是,该网络只研究了高光谱图像特征最近时刻的状态,不能记住长期的状态。

基于以上问题,本文提出了一种3D卷积联合注意力机制神经网络的分类方法。首先,通过组合中心像素和周围像素构成的像素对,增加训练样本的数量,既能充分考虑像素之间的邻域相关性,又可以很好地利用像素之间的特征关系。接着,将像素对馈入到提出的神经网络框架中(Long Short-Term Memory 3D Convolution Joint Attention Mechanism Neural Network, LA 3D-CNN),先利用长短期记忆网络(Long Short-Term Memory, LSTM)来处理特征,这种处理方式能够将最近时刻的状态,和长期状态的特征做结合,能更好地将光谱特征和空间特征进行融合,对后续的分类起到一定的促进作用。由于目标在经过三维卷积神经网络过程中,像素特征之间被分配的权重是相同的,不能有效地区分特征之间的重要程度,降低分类准确率。为了解决这个问题,引入了注意力机制

网络,该网络来源于对人类视觉的研究,主要应用在图像识别^[22-24]领域中,是一种特征强化的策略。它可以模拟人类视觉的观察方式,在观察物体时会忽视全局信息和背景信息,有选择性地使视觉注意力集中在物体的某些部分上,通过对物体局部信息的理解综合得到对整体物体的理解,从众多信息中选择出对当前任务更关键的信息。可以在特征学习过程中,选择性学习高光谱图像中的特征,对不同特征分配不同的权重,让分类效果更好。图1所示的分类框架流程图由3个主要部分组成:①可用的训练样本构建多组像素对。②构造一个LA 3D-CNN神经网络框架来学习像素对中的特征信息。③通过投票策略确定最终标签。




图1 分类框架流程图

Fig.1 Classification framework flow chart

1 基本原理

1.1 像素对训练样本

高光谱数据集在 $R^{n \times 1}$ 特征空间中表示为 $X = \{x_i\}_{i=1}^Q$, 类标签表示为 $y_i \in \{1, 2, \dots, c\}$; 其中 n 是光谱带的数量, c 是类别的数量, q_i 是第 i 类中可用的标记样本的数量, 并且 $\sum_{i=1}^c q_i = Q$ 。我们将中心像素与周围相邻的其它像素进行配对, 可以通过配对构成多组新的像素对, 每组像素对的配对方法如下: 每组像素对都含有4个训练样本, 像素对的集合表示为: $S_{ijkl} = [x_i, x_j, x_k, x_l]$, 其中: x_i, x_j, x_k, x_l 是来自 X 的4个训练样本。 S_{ijkl} 的标签生成方式是如果4个样本来自同一类别或者中心像素样本与其它两个样本的类别一致, 与另一个样本的类别不同, 则标签 S_{ijkl} 的类别由中心像素决定。如果是其它生成方式则标签 S_{ijkl} 的类别设为背景标签0, 在训练过程中不被采用。如式(1)所示:

$$\text{Label}(S_{ijkl}) = \begin{cases} 1, & \text{if } y_i = y_j = y_l = y_k = 1 \text{ or } y_i = y_j = y_l \neq y_k = 1 \\ 0, & \text{other} \end{cases} \quad (1)$$

1.2 LA 3D-CNN 网络架构

在获得输入训练样本后, 我们可以使用 LA

3D-CNN 网络提取特征信息,如图2所示。该网络由长短期记忆网络(LSTM)层,3D卷积层,注意力机制网络层和完全连接层组成。首先,训练样本通过LSTM层,可以将光谱特征和空间特征更好地融合。接着,通过3D卷积层提取特征,利用注意力机制网络从众多特征中筛选出对当前目标更有用的特征。最后,通过完全连接层到简单的分类器,获得所需的分类结果。

1.2.1 3D卷积网络和注意力机制网络

虽然,目前二维卷积神经网络(2D Convolutional Neural Network, 2D-CNN)在图像处理领域^[25]中具有很好的应用前景,其优势是直接从原始输入图像中提取特征,但是,2D-CNN中每个输入都对需要一组内核,会导致高光谱图像需要的内核量变大,增加计算成本。我们将3D卷积联合注意力机制网络引入到高光谱图像处理中,它使用3D内核进行三维卷积运算,具有内核数少,计算成本低的特点。另外,引入注意力机制网络可以从高光谱图像的众多特征中,选择性地筛选出对当前任务目标更关键的特征,并且聚焦到这些重要的特征上,忽略一些对分类没有帮助的特征。通过对高光谱图像部分特征的分析概况得出对整个高光谱图像特征的分析,让网络模型更加集中于对重要特征的理解,这样能够有针对性的弱化对分类无用的特征。在处理分类任务时,更加专注于找到与当前输出相关联的有用的特征,获取对不同类别更具有识别能力的特征表示,提高了最后的分类准确率。

注意力机制框架如图3所示。从输出,解码器部分,如公式(2):

$$S_t = f(S_{t-1}, y_{t-1}, C_t) \quad (2)$$

式中: S_t 是时刻 t 的解码器的状态输出; S_{t-1} 是时刻 t

-1 的解码器的状态输出; y_{t-1} 是时刻 $t-1$ 的标签; f 是循环神经网络。

$$C_t = \sum_{j=1}^{T_t} a_{ij} h_j \quad (3)$$

式中: C_t 是查看下一个状态输出; h_j 是解码器中第 j 个输入的输入; a_{ij} 是权重。

$$a_{ij} = \frac{\exp(e_{ij})}{\sum_{k=1}^{T_t} \exp(e_{ik})} \quad (4)$$

式中: 该公式类似于 softmax, 原理是相同的, 为了得到条件概率 $P(a|e)$, a_{ij} 表示当前解码器与第 j 个输入对齐的程度。

$$e_{ij} = g(S_{t-1}, h_j) = v \cdot \tanh(w \cdot h_j + u \cdot S_{t-1} + b) \quad (5)$$

式中: g 用于计算 S_{t-1} 和 h_j 之间的关系分数。可以看出, 如果得分越高, 注意力分布就集中于该输入上面。

1.2.2 参与投票策略的联合分类

在高光谱图像分类中, 由于相邻像素倾向于属于高概率的那一类, 所以我们使用联合分类和投票策略。如图4所示, 构造与周围相邻像素联合的像素对后, 我们将像素对馈入到 LA 3D-CNN 网络中。在图4中, 块窗口用于相邻像素(尺寸大小可以是 $3 \times 3, 5 \times 5$ 等)。例如, 选择 3×3 , 则有4组(即: $\{T, 1, 2, 4\}, \{T, 2, 3, 5\}, \{T, 4, 6, 7\}, \{T, 5, 7, 8\}$) 像素对馈入到 LA 3D-CNN 网络中。其中 T 表示为中心像素, 其它数字代表与中心像素相邻的其他像素。每个中心像素可以通过配对构成4组新的像素对。网络会输出一个 $4 \times C$ 的矩阵, 由 softmax 产生一个 4×1 的矢量。最后, 中心像素的最终分类标签由多数投票策略决定, 显示出标签矩阵获得的结果。

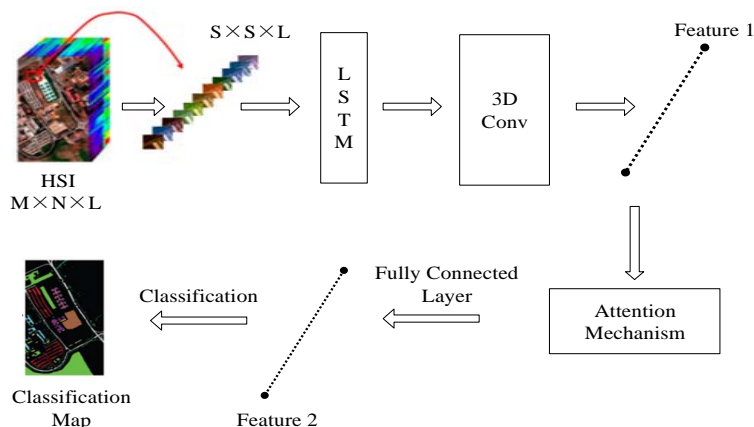


图2 LA 3D-CNN 网络框架

Fig.2 LA 3D-CNN network framework




图3 注意力机制神经网络模型

Fig.3 Attention mechanism neural network model

2 实验结果与分析

2.1 数据集

University of Pavia 数据集是由反射光学系统成像光谱仪传感器获得的。意大利帕维亚市覆盖 610×340 像素的图像场景是在德国航空航天局管理的 HySens 项目下收集的，数据集有 103 个光谱带，它的光谱覆盖范围为 $0.43\sim0.86\mu\text{m}$ ，空间分辨率为 1.3 m。地面实况图中大约有 42776 个带有 9 个等级的标记像素，在表 1 中列出了训练样本和测试样本的数量。

Indian Pines 数据集是由可见红外成像光谱仪传感器在印第安纳州西北部采集的。在可见光和红外光谱的 $0.4\sim0.45\mu\text{m}$ 区域中有 220 个光谱带，空间分辨率为 20 m。原始地面真实图像中有 16 种不同的土地覆盖类别。然而，由于少数类别训练样本较少，本文只使用了 9 个类别。训练样本和测试样本的数量列于表 2 中。

2.2 分类结果分析

为了证明本文提出的分类方法是有效的，将其与另外几种基于深度学习的分类方法进行比较，如：K-NN^[7]，SVM^[9]，PCA^[13]，ICA^[14]，RNN^[21]，3D-CNN^[20]和 CNN-PPF^[19]。表 3 和表 4 显示的是在两种不同的数据集下，各种分类方法的总体准确率（Overall Accuracy，OA），平均准确率（Average Accuracy，AA），Kappa 值（K）。表 3 显示的是使用 Indian Pines 数据集进行实验得出的分类结果，可以看出 LA

3D-CNN 的准确率（95.67%）比 CNN-PPF（94.11%）高出 1%。特别是一些类别，如：Bare Soil，所提出的方法准确率比 CNN-PPF 提高了 2%。表 4 显示的是使用 University of Pavia 数据集进行实验得出的分类结果，从中可以看出 LA 3D-CNN 的准确率（96.61%）比 CNN-PPF（95.28%）高出 1%。特别是一些类别，如：Soybean-notill，所提出的方法准确率比 CNN-PPF 提高了 2%。从表 3 和表 4 中也可以看出本文提出的方法要优于其他常用的分类方法（如：K-NN 和 SVM）以及其他常用的特征选择方法（如：PCA 和 ICA），主要原因是提出的网络可以选择性地忽略对当前任务目标不是很关键的特征，聚焦到对分类有用的特征上，使网络模型更加集中于对重要特征的理解，有助于分类。综上所述，本文所提出的方法明显优于其他分类方法。

为了方便和其它基于深度学习的分类方法进行比较，我们制作了整个图像场景的地被植物分布图，这些图分别与表 3~4 中的结果对应。图 5 和图 6 为分类结果图，从两幅图我们可以看出，本文提出的方法在一些区域比其它基于深度学习的方法具有更少的噪声，例如，图 5 中的 Bare Soil 区域和图 6 中的 Soybean-notill 区域。为了验证引入注意力机制网络的有效性，表 5 显示了在 Indian Pines 数据集中，不同窗口尺寸下是否引入注意力机制网络层的分类准确率。从实验结果可以看出，在不同的窗口大小下，具有注意力机制网络层要比没有注意力机制网络层的分类准确率高。另外，我们从表 5 中可以看出，当窗口大小为 5×5 和 7×7 时，得到的分类准确率的结果非常接近，但 7×7 的窗口尺寸将导致过高的计算复杂度。因此，窗口尺寸选择 5×5 。另一个数据集也有相似的情况。产生这种结果的原因是引入注意力机制网络可以在提取高光谱图像不同的特征过程中，对不同的特征分配不同的权重，取舍性地挑选在当前状态下对分类有帮助的重要特征，增加对当前状态起到关联作用的特征的权重，有助于提高分类的准确率。

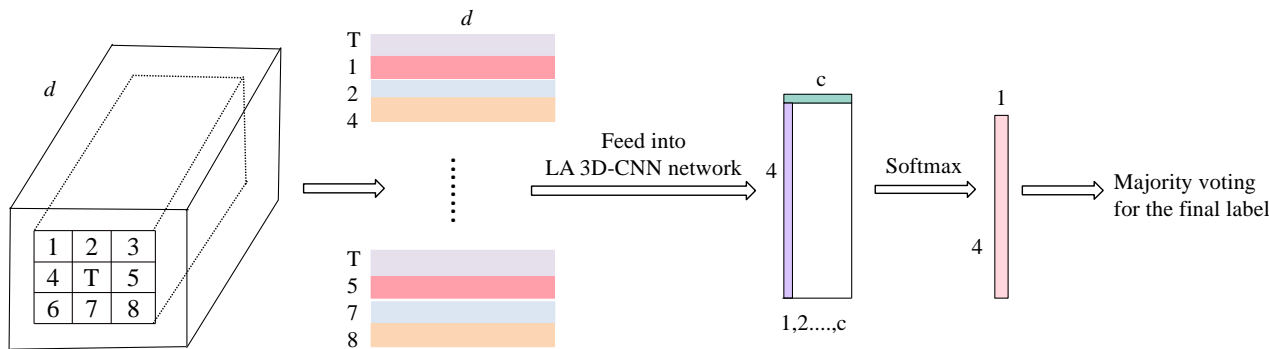


图4 投票策略的联合分类

Fig.4 Joint classification with voting strate

表 1 University of Pavia 数据集中使用训练和测试的样本数量

Table 1 Number of training and testing samples used in the University of Pavia data set

No.	Class	Training	Testing
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
Total		1800	40976

表 2 Indian Pines 数据集中使用训练和测试样本的数量

Table 2 Number of training and testing samples used in theIndia Pines data set

No.	Class	Training	Testing
1	Corn-notill	200	1228
2	Corn-mintill	200	630
3	Grass-pasture	200	283
4	Grass-trees	200	530
5	Hay-windrowed	200	278
6	Soybean-notill	200	772
7	Soybean-mintill	200	2255
8	Soybean-clean	200	393
9	Woods	200	1065
Total		1800	7434

表 3 Indian Pines 数据集准确率 Table 3 Indian Pines data set accuracy

%								
No.	K-NN	PCA	RNN	ICA	SVM	3D- CNN	CNN- PPF	LA 3D-CNN
1	87.21	87.89	88.76	89.12	89.45	89.63	91.25	91.27
2	88.73	89.51	90.02	91.21	91.52	92.71	96.26	95.34
3	93.85	94.51	95.42	95.91	96.05	96.14	96.58	97.02
4	93.08	93.63	94.32	94.73	95.25	95.35	95.98	96.27
5	97.41	97.96	98.88	99.14	99.25	99.46	100	100
6	87.15	87.74	88.54	88.82	89.02	89.21	89.24	91.12
7	84.73	85.15	85.99	86.58	88.12	88.55	92.80	93.29
8	88.61	89.13	89.81	90.51	91.03	91.18	92.98	93.47
9	92.56	93.12	93.64	94.29	94.81	95.44	96.31	97.88
OA	89.53	90.32	91.02	91.61	92.55	93.23	94.11	95.67
AA	89.22	89.64	90.89	90.63	92.23	92.48	94.14	94.82
K	89.09	89.35	91.03	91.32	92.07	92.25	94.01	94.51

表 4 University of Pavia 数据集准确率 Table 4 University of Pavia data set accuracy

%								
No.	K-NN	PCA	RNN	ICA	SVM	3D- CNN	CNN- PPF	LA 3D-CNN
1	84.79	85.51	86.17	89.54	92.11	94.87	96.02	96.11
2	88.54	89.12	89.89	90.91	91.08	91.22	93.76	93.41
3	87.01	87.57	88.23	88.98	92.82	94.17	94.35	95.01
4	91.51	92.02	92.31	93.18	94.57	95.78	96.02	96.47
5	98.44	99.12	99.39	99.56	99.42	99.71	100	100
6	92.51	93.03	93.87	94.16	94.82	95.23	97.31	99.47
7	85.76	86.59	87.18	89.18	91.43	92.57	92.89	93.21
8	88.83	89.51	90.33	90.97	91.73	92.32	93.99	94.87
9	95.05	95.87	96.31	96.91	97.14	97.25	97.53	98.18
OA	90.05	90.91	91.62	92.58	93.67	94.84	95.28	96.61
AA	89.77	90.53	90.28	94.84	93.13	94.61	95.02	95.72
K	89.53	90.17	90.17	91.46	93.08	94.98	95.27	95.57

在实际情况下,可用的训练样本数量大小可以影响到类别准确率的判断。图7表示具有不同数量的训练样本的分类准确率。从图7可以看出每类训练样本数从50变为200,间隔为50。在不同的样本数量下,本文提出的分类方法都是最有效的。另外,从图7中也能够发现当每类训练样本数量为200的时候,分类

准确率是最高的。根据以上实验结果可以看出,本文提出的分类方法的准确率优于其他几种分类方法。原因如下:1)将中心像素与周围相邻的其它像素进行配对,可以充分考虑像素之间的邻域相关性。2)引入3D卷积联合注意力机制网络可以选择性学习高光谱图像中的特征。

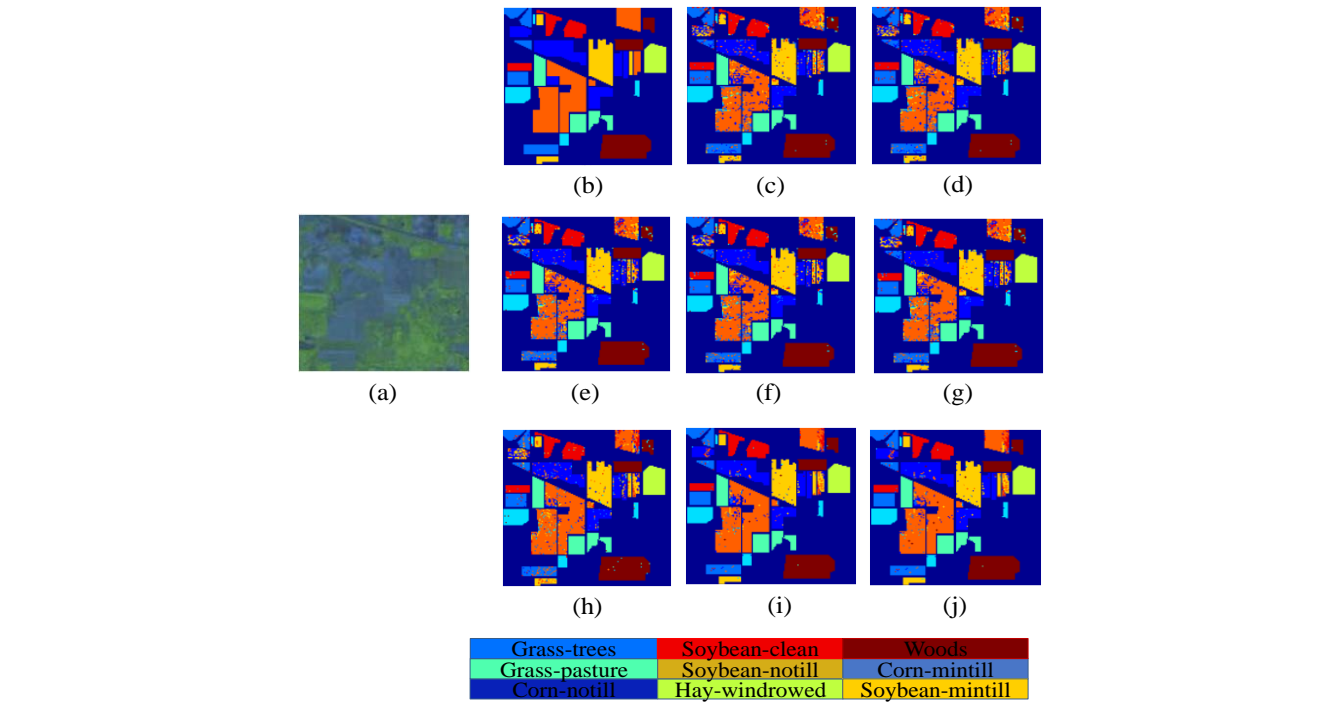


图5 Indian Pines 数据集的分类结果 Fig.5 Classification results of Indian Pines data set

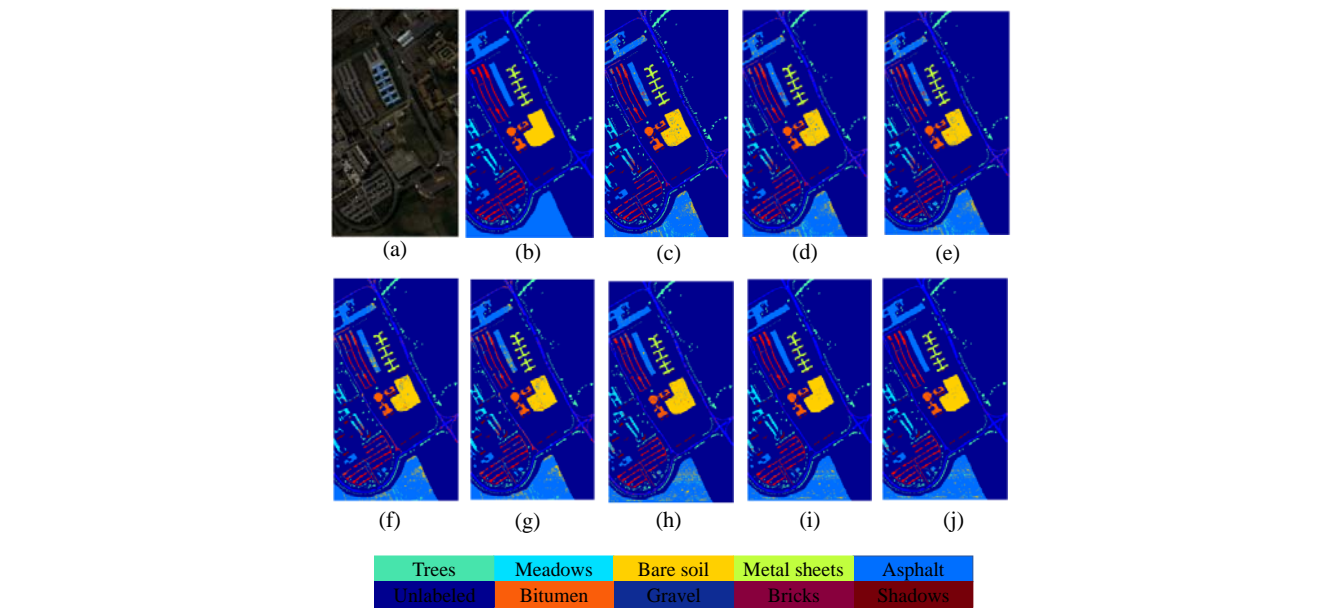



图6 University of Pavia 数据集的分类结果 Fig.6 Classification results University of Pavia data set

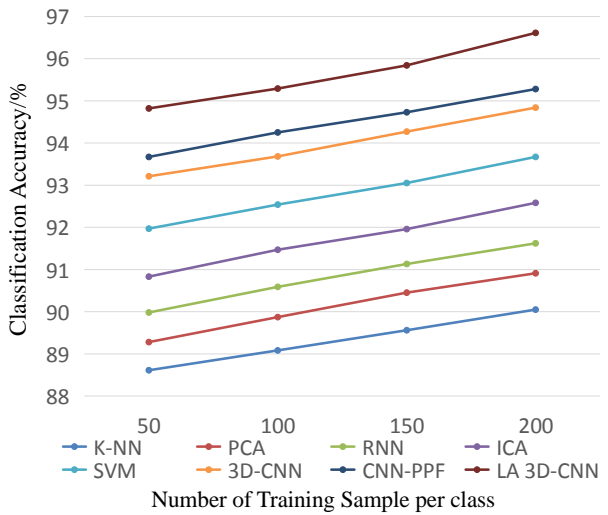
表 5 Indian Pines 数据集中有和没有注意力机制网络层的分类准确度

Table 5 Classification accuracy with and without attention mechanism layer using the Indian Pines data set

Window Size	3×3	5×5	7×7
With Attention Mechanism	95.12	95.67	95.75
Without Attention Mechanism	94.67	95.23	95.34



(a) Indian Pines 数据集 (a) Indian Pines data set



(b) University of Pavia 数据集 (b) University of Pavia data set

图 7 具有不同样本数量的分类准确率

Fig.7 Classification accuracy with different samplesizes

3 结论

为了提高高光谱图像的分类效果，提出了一种基于 3D 卷积联合注意力机制网络的高光谱图像分类方法。得到以下结论：①我们通过组织有效的训练样本来克服深度学习模型需要大量参数和训练数据来确保性能这个问题。②设计的网络结构可以选择性学习

高光谱图像中的特征，有效地联合了光谱特征和空间特征，重点学习对目标特征有用的重要信息，提高了高光谱图像的分类精度。实验表明，该方法在两个实验数据集上都表现出最佳的准确率。

对于高光谱图像，更容易获得未标记的样本。然而，基于 LA 3D-CNN 的监督分类无法利用这些未标记的样本。所以，为了更好地解决这个问题，我们将计划研究集成基于 LA 3D-CNN 的无监督和半监督分类方法。

参考文献:

[1] ZHANG M M, LI W, DU Q. Diverse Region-Based CNN for Hyperspectral Image Classification[J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2018, **27**(6): 2623-2634.

[2] LEE H, Kwon K. Going Deeper with Contextual CNN for Hyperspectral Image Classification[J]. *IEEE Trans Image Process*, 2017, **26**(10): 4843-4855.

[3] WANG L, ZHANG J B, LIU P, et al. Spectral-spatial multi-feature-based deep learning for hyperspectral remote sensing image classification[J]. *Soft Computing*, 2017, **21**(1): 213-221.

[4] Slavkovikj V, Verstockt S, Neve W D, et al. Unsupervised spectral sub-feature learning for hyperspectral image classification[J]. *International Journal of Remote Sensing*, 2016, **37**(2): 309-326.

[5] HUANG H, ZHENG X L. Hyperspectral image classification with combination of weighted spatial-spectral and KNN[J]. *Optics & Precision Engineering*, 2016, **24**(4): 873-881.

[6] 左航. 基于经验模态分解的 SVM-KNN 高光谱图像分类方法[J]. *微型电脑应用*, 2016, **32**(12): 60-63.

ZUO Hang. SVM-KNN Hyperspectral Image Classification Method Based on Empirical Mode Decomposition[J]. *Microcomputer Application*, 2016, **32**(12): 60-63.

[7] HUANG K, LI S, KANG X, et al. Spectral-Spatial Hyperspectral Image Classification Based on KNN[J]. *Sensing & Imaging*, 2016, **17**(1): 1-13.

[8] Echanobe J, Martinez M V, Basterretxea K, et al. Genetic Algorithm-based Optimization of ELM for On-line Hyperspectral Image Classification[C]//*International Joint Conference on Neural Networks*, 2017: 4202-4207.

[9] Jain D K, Dubey S B, Choubey R K, et al. An Approach for Hyperspectral Image Classification by Optimizing SVM using Self Organizing Map[J]. *Journal of Computational Science*, 2017, **25**(1): 252-259.

[10] 李铁, 张新君. 基于联合协同表示与 SVM 决策融合的高光谱图像分类研究[J]. *计算机应用研究*, 2017, **34**(6): 1913-1916.

LI Tie, ZHANG Xinjun. Hyperspectral Image Classification Based on Joint Collaborative Representation and SVM Decision Fusion[J]. *Journal*

- of Computer Applications, 2017, **34**(6): 1913-1916.
- [11] Majdar R S, Ghassemian H. A probabilistic SVM approach for hyperspectral image classification using spectral and texture features[J]. *International Journal of Remote Sensing*, 2017, **38**(15): 4265-4284.
- [12] KANG X, XIANG X, LI S, et al. PCA-Based Edge-Preserving Features for Hyperspectral Image Classification[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2017, **55**(12): 7140-7151.
- [13] WANG W, ZHANG R, WU Q. Hyperspectral image classification based on PCA network[C]//*Workshop on Hyperspectral Image & Signal Processing: Evolution in Remote Sensing*, 2017: 1-4.
- [14] Falco N, Benediktsson J A, Bruzzone L. A Study on the Effectiveness of Different Independent Component Analysis Algorithms for Hyperspectral Image Classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2014, **7**(6): 2183-2199.
- [15] LONG T, QIAN D, Kopriva I, et al. Tensor-based Offset-Sparsity Decomposition for Hyperspectral Image Classification[C]//*Geoscience & Remote Sensing Symposium*, 2017: 3656-3659.
- [16] LI H C, ZHOU H L, PAN L, et al. Gabor Feature-based Composite Kernel Method for Hyperspectral Image Classification[J]. *Electronics Letters*, 2018, **54**(10): 628-630.
- [17] Mughees A, Ali A, TAO L M. Hyperspectral image classification via shape-adaptive deep learning[C]//*IEEE International Conference on Image Processing*, 2017: 375-379.
- [18] WANG Q, LIN J Z, YUAN Y. Salient Band Selection for Hyperspectral Image Classification via Manifold Ranking[J]. *IEEE Transactions on Neural Networks & Learning Systems*, 2017, **27**(6): 1279-1289.
- [19] LI W, WU G D, ZHANG F, et al. Hyperspectral Image Classification Using Deep Pixel-Pair Features[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2016, **55**(2): 844-853.
- [20] LI Y, ZHANG H K, SHEN Q. Spectral-Spatial Classification of Hyperspectral Imagery with 3D Convolutional Neural Network[J]. *Remote Sensing*, 2017, **9**(1): 1527-1554.
- [21] Mou L, Ghamisi P, ZHU XX. Deep Recurrent Neural Networks for Hyperspectral Image Classification[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2017, **55**(7): 3639-3655.
- [22] WANG F, JIANG M Q, QIAN C, et al. Residual Attention Network for Image Classification[C]//*IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2017: 6450-6458.
- [23] PENG Y X, HE X T, ZHAO J J. Object-Part Attention Model for Fine-grained Image Classification[J]. *IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society*, 2018, **27**(3): 1487-1500.
- [24] Stanislaw S, Erhardt B. Image classification with recurrent attention models[C]//*Computational Intelligence*, 2017: 1-7.
- [25] ZHONG Z L, LI J T, MA L F, et al. Deep Residual Networks for Hyperspectral Image Classification[C]//*IEEE International Geoscience & Remote Sensing Symposium*, 2017: 1824-1827.