

文章编号 1004-924X(2024)09-1395-13

主动学习联合聚类分组网络的 高光谱遥感图像分类

刘 敬^{1*}, 李银桥¹, 刘 逸²

(1. 西安邮电大学 电子工程学院, 陕西 西安 710121;

2. 西安电子科技大学 电子工程学院, 陕西 西安 710071)

摘要: 基于卷积神经网络的高光谱图像(Hyperspectral Image, HSI)分类面临网络参数量大, 带类标样本少的现状, 针对这些问题, 提出了基于主动学习和聚类分组网络的高光谱图像分类方法(AL-CGNet)。AL-CGNet采用主动学习和聚类联合卷积神经网络进行HSI的特征提取与分类, 设计了基于分组卷积的轻量化网络模型以降低网络参数量。对线性判别分析(Linear Discriminant Analysis, LDA)降维后的高光谱图像采用小批量K均值聚类算法划分成不同的簇, 并用簇中心的光谱特征代表不同的簇, 以利用无类标样本的信息。在分组网络中将生成的特征图沿光谱维划分成一系列小组, 每组通过多个残差块依次提取空间-光谱特征, 这种分组策略可以充分利用波段的冗余性和差异性, 降低网络参数, 并实现轻量化。最后, 采用主动学习选取信息量大的样本作为训练样本集, 以解决带类标样本少的问题。实验结果表明, AL-CGNet在使用相同比例的6%训练样本的情况下, 在Indian Pines, Botswana, Houston 3个数据集下的分类结果明显高于ClusterCNN, SSRN和HybridSN等方法, 其OA分别为99.57%, 99.23%, 98.82%, 甚至在训练样本更少5%的小样本情况下也是有效的。该方法不仅大大提高了HSI的分类效率, 在获得高精度的同时还能高效率地提取特征。

关键词: 高光谱图像分类; 卷积神经网络; 分组卷积; 聚类; 轻量化

中图分类号: TP391 文献标识码: A doi:10.37188/OPE.20243209.1395

Active learning-clustering-group convolutions network for hyperspectral images classification

LIU Jing^{1*}, LI Yinqiao¹, LIU Yi²

(1. School of Electronic Engineering, Xi'an University of Posts and Telecommunications,
Xi'an 710121, China;

2. School of Electronic Engineering, Xidian University, Xi'an 710071, China)

* Corresponding author, E-mail: zyhalj1975@163.com

Abstract: Hyperspectral image (HSI) classification using convolutional neural networks often grapples with a large number of network parameters and a scarcity of class-labeled samples. To tackle these issues, we propose a method called AL-CGNet, which integrates active learning and clustering with group convolutions network for efficient HSI classification. AL-CGNet combines a convolutional neural network with active learning and clustering to enhance feature extraction and classification, while a group convolutions-based lightweight network model significantly reduces parameter count. Initially, HSI reduced in dimen-

收稿日期: 2023-11-02; 修订日期: 2023-12-12.

基金项目: 国家自然科学基金资助项目(No. 62077038, No. 61672405)

sionality through linear discriminant analysis is segmented into clusters via the mini-batch K -means algorithm. The central feature of each cluster substitutes the samples within, leveraging information from unlabeled samples. Subsequently, feature maps are segmented into groups along the spectral dimension in the group convolutions network, where each group sequentially extracts spatial-spectral features through multiple residual blocks. This grouping strategy optimizes band redundancy and diversity, cuts down network parameters, and achieves lightweighting. Active learning then selects informative samples for the training set, mitigating the issue of limited labeled samples. Experimental results demonstrate that AL-CGNet, with only 6% training samples, significantly outperforms ClusterCNN, SSRN, and HybridSN on the Indian Pines, Botswana, and Houston datasets, achieving overall accuracies of 99.57%, 99.23%, and 98.82%, respectively. Remarkably, AL-CGNet remains effective even with a smaller training sample size of 5%. This method not only boosts HSI classification efficiency but also ensures robust feature extraction and high accuracy.

Key words: hyperspectral images classification; convolutional neural networks; group convolutions; clustering; lightweighting

1 引言

近年来,高光谱图像(Hyperspectral Image, HSI)在遥感领域、农业等领域都有广泛的应用^[1-3]。相比于传统的自然影像,HSI包含更多的光谱通道,具有丰富的地物信息^[4-6],在遥感分类领域具有很高的研究价值。然而,HSI的分类仍然面临着诸多问题与挑战:一方面波段增加会导致信息冗余,增加数据处理的复杂性;另一方面,由于标记样本获取困难因此带类标样本少,而深度学习随着网络深度的增加,参数量会增加,同时需要更多的训练样本,以达到更好的分类效果。

高维数据通常包含大量的无关特征与冗余特征,因此,高光谱数据在送入网络之前需要进行降维预处理,以减少由于高光谱图像信道相关性造成的冗余。主成分分析(Principal Component Analysis, PCA)^[7]和线性判别分析(Linear Discriminant Analysis, LDA)^[8]等技术广泛应用于HSI分类框架中来降低光谱冗余。Sun等^[9]出于波段选择的目的,提出鲁棒多特征谱聚类方法选取代表性波段来降低光谱冗余,接着可以进行分类器的设计。

K -最近邻(K -Nearest Neighbors, KNN)^[10],支持向量机(Support Vector Machines, SVM)^[11]

等传统分类器只使用光谱信息,没有考虑空间信息,不能取得很好的分类结果。经典特征提取与分类方法基于浅层学习,分类效果不太理想。

随着深度学习的快速发展,特别是卷积神经网络(Convolutional Neural Network, CNN)的出现,为HSI分类带来了新的机遇。近年来,研究者在HSI分类领域开展了许多基于深度学习的工作。为使网络可以自动学习特征,Luo等^[12]建立了一个具有一维流形嵌入的CNN架构来提取光谱空间特征,但该方法没有充分考虑空间信息。为缓解网络参数学习过程中的过拟合问题并更好地处理高光谱图像信息,Yu等^[13]提出了一种基于二维CNN的HSI分类特征学习方法,但该方法没有充分考虑光谱信息。为学习到更深层次的光谱空间特征,Zhang等^[14]设计了一种用于HSI分类的三维密集连接卷积网络(Three-dimensional Densely Connected Convolutional Network, 3D-DenseNet),其结构比三维CNN更深,采用的密集连接结构可增强特征传输,使网络更容易训练,但网络模型较为复杂,造成网络参数增加。为解决以上问题,Roy等^[15]提出一种3D-CNN和2D-CNN的混合网络模型(Hybrid Spectral CNN, HybridSN),降低了模型的复杂性,提高了计算效率。为了更好地提取HSI的光

谱和空间信息,Yao等^[16]提出一种两步高光谱分类方法 Cluster CNN,并使用分层特征学习顺序处理光谱特征和空间特征,可使分类更加准确,网络参数也大大减少。为减少模型参数,Ahmad^[17]等提出一个快速紧凑的3D-CNN模型用于高光谱分类,这种端到端的训练模型有更少的参数,显著缩短了收敛时间,但不适合带类标样本少的情况。

在采用CNN对HSI进行分类时,对于同一个网络,适当加入残差学习可使整个网络的学习状态更活跃,同时随着网络加深,梯度消失的风险降低。为防止随着网络加深梯度消失的问题,Song等^[18]引入残差学习,通过将输入信息“绕道”传导至输出,极大地保护了信息的完整性,实现了浅层特征和深层特征的融合。为提升网络性能,提取更深层次的特征,Zhong等^[19]提出了光谱空间残差网络(Spectral-Spatial Residual Networks, SSRN),SSRN通过多个光谱残差块和多个空间残差块的堆叠进行特征提取,最后采用全连接层分类。为突出感兴趣区域,抑制不重要的信息,Roy等^[20]提出基于注意力的自适应光谱空间核改进的残差网络(Attention-Based Adaptive Spectral-Spatial Kernel Improved Residual Network, A²S²K-ResNet),该网络可自动调整神经元的感受野,同时利用光谱注意力以端到端训练的方式为HSI分类捕捉鉴别性的光谱空间特征。然而,这些工作只利用了光谱波段的重要信息,没有反映空间位置的关键信息。为此,Guo等^[21]提出了一种基于光谱-空间连接注意机制的特征分组网络,从原始HSI中使用光谱注意模块和空间注意模块连续提取重要的光谱波段和空间位置,之后对生成的特征图分组并通过多个光谱和空间残差块依次提取空间光谱特征。为缓解随着输入图像块尺寸增加而导致的性能下降问题,Zhang等^[22]提出了一种高效的基于CNN的光谱划分残差网络用于HSI分类,所提出的空间注意模块可基于中心像素的光谱特征捕获图像块的均匀像素。

随着CNN网络层数的增加,为了更好地获取深度特征提取效果,基于CNN的高光谱图像特征提取与分类需要大量的标记样本来提取具

有鉴别性的空间-光谱特征,而标签样本的采集需要花费大量的时间和金钱,且人工标注样本成本高昂,使用少量训练样本进行高精度的高光谱分类是一个亟待解决的问题。Zhao等^[23]提出的图注意力网络通过半监督学习表现出良好的性能。它结合了标记和未标记样本的信息,从而缓解了标记样本不足的弱点。半监督深度学习方法可以从有限的标记样本和大量的未标记样本中提取互补信息,进一步提高分类精度。为提升模型在不同场景下的地物识别效率,Weng等^[24]将自适应分类方法进行了对比分析,其中深度域适应方法优势最为明显,邻域自适应通过将源域学到的知识传递到目标域,可实现模型迁移,提升不同场景下的地物分类精度和计算效率。为了在提高分类性能的同时降低标注成本,Cao等^[25]提出了一种用于HSI分类的主动深度学习方法,该方法将主动学习(Active Learning, AL)和CNN集成到一个统一的框架中,以更好地预测HSI像素的类标签。Lei等^[26]为了提高训练样本的有效性,提出了一个深度网络主动学习框架进行高光谱分类,构建了一个辅助深度网络来学习候选数据集中未标记样本的不确定性。

然而,随着CNN网络层数的增加,网络参数量也会进一步增加。为解决这一问题,Fang等^[27]提出了一种轻量化模块代替传统网络中的卷积层,不仅可以降低网络参数,还可以保持较高的HSI分类性能。为减少CNN模型的规模并进一步降低参数量,Meng等^[28]提出一种轻量级的光谱-空间卷积模块,可在保持分类性能的同时,大大降低网络参数和计算复杂度,但该模块的执行时间较长。Zhang等^[29]提出了一种基于注意力的轻量级网络用于高光谱图像分类,可优化分类性能和计算效率,但计算效率提高的同时分类精度却有所下降。

针对基于CNN的高光谱图像分类面临的网络参数量大且标记样本少的问题,本文提出了一种基于主动学习和聚类的分组网络(Active Learning-Clustering-Group Convolutions Network, AL-CGNet)。将聚类 and 卷积神经网络相结合,利用聚类充分利用无类标样本的信息以弥补带类标样本少的问题。利用点卷积和深度卷

积结合代替三维卷积,并在二维卷积处使用分组卷积实现多特征的融合来设计更高效、偏轻量化的 2D 分组卷积神经网络。网络采用点卷积和二维卷积形成类似于深度可分离的结构,可更有效地利用模型参数,学习通道间和空间上的相关性,实现三维卷积的效果并降低参数量;同时在二维卷积中采用分组卷积可进一步降低参数量,这种设计充分利用了波段的冗余性和差异性,可降低网络参数量,实现轻量化。由于分组卷积后又进行了深层特征融合,网络可提取到更深层次的融合特征,从而提高识别率。在上述的聚类卷积神经网络中引入主动学习,以选取有效训练样本。为了解决带类标样本少的问题,采用 AL 技术选取少量信息量大的样本加入训练集,用于训练网络模型。为验证本文所提 AL-CGNet 方法的有效性,将其与现有的先进方法 ClusterCNN, SSRN, HybridSN, FC-3DCNN^[17], 3D-DenseNet^[14] 在三个实测数据集上进行实验比较,实验结果证明本文所提方法在使用相同训练样本比例的情况下,其分类结果明显高于其他五种方法,甚至在小样本的情况下 AL-CGNet 方法更有优势,可以在获得高分类精度的同时高效率地提取有效特征。

2 原 理

AL-CGNet 首先采用 LDA 对高光谱图像进行降维以减少光谱冗余;接着对降维后的高光谱图像,采用小批量 K -Means 对其光谱维进行聚类,将高光谱图像划分为不同簇,并用簇中心的光谱特征代表不同簇以充分利用无类标样本的信息,这些光谱特征是 LDA 降维后产生的聚类平均。然后,随机选取一定数量的标记样本作为初始训练集,送入偏轻量化的 2D 分组卷积网络中进行训练。同时为解决标记样本获取困难的问题,采用主动学习策略帮助选取信息量大的标记样本加入训练集来训练 2D 分组卷积网络,以少量的高质量标记数据训练高性能的模型,进一步提取高光谱图像的深度光谱-空间特征,并利用这些特征对高光谱图像进行分类。本文将未结合主动学习的聚类分组网络称为 CGNet。图 1 为 AL-CGNet 总体方案,虚线部分为 CGNet 方案。




图 1 AL-CGNet 总体方案

Fig. 1 Overall scheme of AL-CGNet

2.1 HSI 聚类平均

原始高光谱数据 $X \in \mathbb{R}^{M \times Q \times D}$, M 和 Q 分别为高光谱数据的长和宽, D 为原始高光谱图像的光谱波段数。首先,采用 LDA 对高光谱数据进行降维,既可降低数据量,也可提高可分性,光谱波段从 D 减少到 B (B 为降维后的维数),这里采用 LDA,是因为 LDA 是一个浅层的降维特征提取方法,且 LDA 降维后数据的可分性最大,因此没有采用 PCA 或流形学习。处理后的高光谱数据记为 $X \in \mathbb{R}^{M \times Q \times B}$,再采用小批量 K 均值聚类算法沿光谱维进行聚类,将高光谱像素精细地划分为不同的簇,并用每个簇的聚类中心替换该簇中所有样本,可充分利用无类标样本的信息,实现半监督的作用。

图 2 为聚类平均过程,图 2(a)是原始数据的散点图,对原始数据聚类后,把具有相似特征的样本聚成一簇,如图 2(b)所示,图中 a_1, a_2, a_3 分别代表各簇的聚类中心。接着,用每个簇中心替换该簇内的所有像素点,使其内部高度相似,如图 2(c)所示。




图 2 聚类平均过程

Fig. 2 Schematic diagram of clustering averaging process

2.2 样本选择

针对标记样本获取困难的问题,使用主动学习挑选模型中难区分的样本加入训练集,以解决带类标样本少的问题。首先,从聚类平均

后的HSI各类中随机选取少量的带标记样本,通常小于5%,当总体训练样本为5%时,初始训练样本若选择过少,则不足以训练网络;若初始训练样本选择过多,则主动学习挑选的有效样本会减少。本文选取2%作为初始训练集,接着采用主动学习方法从剩余样本中挑选信息量大的高质量标记样本,即难区分的样本,添加到初始训练集中,以少量的高质量标记数据训练网络。图3为训练样本集组成示意图。




图3 训练样本集组成

Fig. 3 Composition of training sample set

本文采用不确定采样方法中的边缘采样^[25]来描述不确定性,以进行样本的选择。模型预测最大可能类和第二大可能类的概率差值越小,代表此样本容易被混淆,其不确定性也就越大,从而在随后的训练中选择该样本,即:

$$x^* = \arg \min_x (P_\theta(\hat{y}_1|x) - P_\theta(\hat{y}_2|x)), \quad (1)$$

其中: $\hat{y}_1$ 和 $\hat{y}_2$ 分别代表对于样本 x 而言,模型预测为最大可能类和第二大可能类; P_θ 代表概率, x^* 代表模型预测最大可能类和第二大可能类的概率差值最小的样本。

主动学习假定只有少量有用的样本对分类器比较重要,定义分离面,大多数样本是冗余的,因此只要发现有用的样本就可以避免多余的标注样本,解决带类样本少的问题。本文通过主动学习法可以帮助选择有用的样本进行标注,还能减少标注样本的数量。

在AL-CGNet中,首先对LDA降维后的HSI像素光谱进行聚类划分为不同簇,并用簇中心替换簇中所有样本,得到聚类平均后的HSI;然后,随机选取2%的训练样本作为初始训练集送入2D分组卷积网络进行训练,接着采用主动学习的边缘采样法不断选取信息量大的样本加入训练集中,继续对网络进行训练以得到高性能模型。

2.3 2D分组卷积网络

本文设计更高效、偏轻量化的分组网络进一步提取高光谱图像的深度光谱-空间特征。随着CNN的加深,参数量也会随之增加,为了让网络更容易学习,本文通过引入分组卷积和残差构建新的CNN来解决以上问题。

该网络将聚类平均后的高光谱图像中裁剪的图像块作为输入,对分组卷积网络进行训练并为每个块的中心像素生成一个类预测。图4为2D分组卷积网络的示意图。每个图像块都是以标记像素为中心,尺寸为 $S \times S \times B$,其中 S 表示图像块的长度, B 表示降维后的通道数。

图4中 $\oplus$ 表示特征按分量相加做融合, $\ominus$ 表示特征直连做融合。图4为分组卷积网络的架构。首先,对聚类平均后的高光谱图像块,利用点卷积对光谱维进行拉伸以粗略地获得特征,光谱维扩展到 N 维;随后,沿光谱维依次将高光谱图像分成2组,每组具有相同的通道数,对每个小组各自再沿光谱维依次分组,可得到4组通道数相同的高光谱图像;对前两组和后两组分别使用 $3 \times 3 \times k$ 和 $5 \times 5 \times k$ 的卷积进行特征提取,然后将通道进行拼接,其中 k 为卷积核个数。这里采用尺寸不等的卷积核,由于不同的卷积核有不同的感受野,感受到的特征也就不同,能够起到互补的作用。同时,采用不同尺寸的卷积核可以考虑更多的局部特征和全局特征,但太大的卷积核尺寸会导致计算量增加,综合考虑选用这两种尺寸的卷积核。之后,各自经过批归一化(Batch Normalization, BN)和线性修正单元Relu后引入残差学习,利用跳跃连接将浅层特征向后传递,实现浅层特征与深层特征的融合。对于这两组残差块,有:

$$\begin{cases} X_1^{u+1} = X_1^u + f_1(X_1^u; \theta_1) \\ f_1(X_1^u; \theta_1) = [f_1(X_{11}^u; \theta_1); f_1(X_{12}^u; \theta_1)] \\ f_1(X_{11}^u; \theta_1) = \sigma(X_{11}^u) * W_{3 \times 3 \times k}^{u+1} + b_{3 \times 3 \times k}^{u+1}, \quad (2) \\ f_1(X_{12}^u; \theta_1) = \sigma(X_{12}^u) * W_{5 \times 5 \times k}^{u+1} + b_{5 \times 5 \times k}^{u+1} \\ X_1^u = [X_{11}^u; X_{12}^u] \end{cases}$$

其中: $\theta_1 = \{W_{3 \times 3 \times k}^{u+1}, b_{3 \times 3 \times k}^{u+1}\}$ 是第一组残差块的参数, $W_{3 \times 3 \times k}^{u+1}$ 和 $b_{3 \times 3 \times k}^{u+1}$ 分别表示第 $(u+1)$ 层的卷积核和偏置, $f_1(X_1^u; \theta_1)$ 为残差函数, X_i 中的 i 表




图4 分组卷积网络示意图

Fig. 4 Schematic diagram of grouped convolutional network

示第 i 个分组的空谱特征图, X_1^u 和 X_1^{u+1} 分别表示第 1 个分组残差块的输入和输出。

$$\begin{cases} X_2^{u+1} = X_2^u + f_2(X_2^u; \theta_2) \\ f_2(X_2^u; \theta_2) = [f_2(X_{21}^u; \theta_2); f_2(X_{22}^u; \theta_2)] \\ f_2(X_{21}^u; \theta_2) = \sigma(X_{21}^u) * W_{5 \times 5 \times k}^{u+1} + b_{5 \times 5 \times k}^{u+1}, (3) \\ f_2(X_{22}^u; \theta_2) = \sigma(X_{22}^u) * W_{5 \times 5 \times k}^{u+1} + b_{5 \times 5 \times k}^{u+1} \\ X_2^u = [X_{21}^u; X_{22}^u] \end{cases}$$

其中: $\theta_2 = \{W_{5 \times 5 \times k}^{u+1}, b_{5 \times 5 \times k}^{u+1}\}$ 是第二组残差块的参数, $W_{5 \times 5 \times k}^{u+1}$ 和 $b_{5 \times 5 \times k}^{u+1}$ 分别表示第 $(u+1)$ 层的卷积核和偏置, $f_2(X_2^u; \theta_2)$ 为残差函数, X_i 表示第 i 个分组的空谱特征图, X_2^u 和 X_2^{u+1} 分别表示第 2 个分组残差块的输入和输出。残差在输入输出采用一个捷径连接, 可以保留全部的原始信息并减少网络参数, 加速神经网络训练。

当 group₁, group₂ 两个分支处未使用分组卷积时, 分支处的参数量为 $3 \times 3 \times N/2 \times N/2 + 3 \times 3 \times N/2 \times N/2 + 5 \times 5 \times N/2 \times N/2 + 5 \times 5 \times N/2 \times N/2 = 17N^2$; 当 group₁, group₂ 两个分支处使用分组卷积后, 如图 4 所示, 参数量变为 $3 \times 3 \times N/4 \times N/4 + 3 \times 3 \times N/4 \times N/4 + 5 \times 5 \times N/4 \times N/4 + 5 \times 5 \times N/4 \times N/4 = 4.25N^2$, 可以发现, 使用分组卷积后, 分支处的参数量相较于未使用分组卷积时分支处的参数量减少了四分之三, 因此, 所提分组卷积降低参数量是有效的。

在经过残差学习后, 将两个残差块的光谱-空间特征进行通道拼接, 并采用点卷积将通道进行压缩降维, 可以有效地捕获更精细和高级别的深度特征, 随后利用 3×3 卷积层和平均池化层对全局光谱空间特征进行提取。最后, 通过全连接层 (Fully Connected, FC) 和 softmax 层可以得到分类结果, 再结合地面真值标签可计算出分类精度。

3 实验结果与分析

3.1 数据集的描述

为验证本文所提方法的有效性, 采用 Indian Pines (IP), Botswana (BW) 以及 Houston (HT) 3 个实测数据集评估该方法的性能。其中, IP 数据集由 AVIRIS 传感器获取, 尺寸为 145×145 , 包含 224 个光谱波段, 去除覆盖吸水区域的波段, 将波段数减少到 200, IP 数据包含 16 个地物类别。BW 数据集由 EO-1 卫星上的传感器获得, 原始数据包含 242 个波段, 去除噪声波段后, 波段数减少到 145, BW 数据包括 14 个类别。HT 数据集由 ITRES CASI-1500 传感器获取, 尺寸为 $349 \times 1\,905$, 包含 364~1\,046 nm 的 144 个光谱波段, HT 数据包含 15 个类别。

实验中, 硬件平台为 AMD Ryzen 7 4700U

with Radeon Graphics 2.00 GHz 的 CPU 和 16 GB 的 RAM,软件平台基于 windows 10 操作系统,包括 python 3.8 和 keras 2.8.0。batch size 设为 256,patch 设为 11,降维后的通道数 B 为类别数减 1,初始点卷积核个数 N 设为 64,结合实验将通道数由原来的 B 维扩展到 64 维比较合适。结合地物空间分布的先验知识和实验,考虑到样本数太少不足以覆盖地物类型,将聚类数设为 130,将卷积核数 k 设为 16,训练过程中使用 Adam 优化器,学习率为 10^{-3} 。

3.2 实验结果

为验证 AL-CGNet 的有效性,首先将聚类分组网络 CGNet 与现有的 ClusterCNN,SSRN,HybridSN,FC-3DCNN,3D-DenseNet 进行比较,来验证 CGNet 的有效性,接着将 CGNet 与 AL-CGNet 进行比较从而验证引入 AL 技术的有效性。随机选取训练样本,每个实验重复训练 10 次,取 10 次平均值,采用总体分类精度(Overall Accuracy, OA)、标准差(Standard Deviation, SD)、Kappa 系数和训练时间作为评估指标。

为了验证聚类分组网络 CGNet 的有效性,每类随机选取 6% 的数据作为训练样本集,其余作为测试集。SSRN 在实验前进行了数据预处理,使用 PCA 将原始高光谱数据降到了 15 维。

表 1~表 3 为 6 种高光谱分类方法分别在 IP,BW,HT 3 个数据集上的分类结果。在 IP 数据集和 BW 数据集上,ClusterCNN 方法相较于 SSRN,HybridSN,FC-3DCNN,3D-DenseNet 方法,分类结果相对较好且比较稳定,Kappa 系数最大。CGNet 的分类精度在这两个数据集上相较于 ClusterCNN 分别提高了 2.44%,1.08%。CGNet 方法的分类结果相对于其他 5 种方法具

表 1 在 IP 数据集上的分类结果
Tab. 1 Classification results on IP dataset

Method	OA±SD/%	Kappa	Time/s
ClusterCNN	95.84±0.43	0.952 5	186.18
SSRN	93.07±0.92	0.920 5	57.50
HybridSN	94.90±0.52	0.941 7	257.70
FC-3DCNN	70.13±1.23	0.655 4	65.00
3D-DenseNet	85.04±1.76	0.828 4	336.10
CGNet	98.28±0.17	0.980 3	172.66

表 2 在 BW 数据集上的分类结果
Tab. 2 Classification results on BW dataset

Method	OA±SD/%	Kappa	Time/s
ClusterCNN	97.12±0.97	0.968 7	56.32
SSRN	96.44±0.81	0.961 4	17.80
HybridSN	94.32±1.67	0.938 4	77.30
FC-3DCNN	94.15±1.91	0.936 6	21.11
3D-DenseNet	92.25±1.38	0.916 0	111
CGNet	98.20±0.68	0.980 5	54.34

表 3 在 HT 数据集上的分类结果
Tab. 3 Classification results on HT dataset

Method	OA±SD/%	Kappa	Time/s
ClusterCNN	96.33±0.60	0.960 3	260.50
SSRN	96.99±0.33	0.967 5	91.40
HybridSN	95.99±1.11	0.956 7	380.2
FC-3DCNN	92.51±0.84	0.919 0	90.82
3D-DenseNet	93.62±0.97	0.931 0	486.9
CGNet	96.91±0.28	0.966 5	255.89

有最高的分类精度、最小的标准差,训练所花费的时间相对较少,Kappa 系数最大,分类准确率最高。在 HT 数据集上,CGNet 的分类精度相比 ClusterCNN, HybridSN, FC-3DCNN, 3D-DenseNet 方法,分别提高了 0.58%,0.92%,4.4%,3.29%,与 SSRN 方法的分类效果持平,CGNet 方法标准差最小,其分类结果相对比较稳定,分类准确率较好,训练时间相对较少。由此可见,CGNet 可以在获得高分类精度的同时高效率地提取特征。

表 4 为各分类方法在 IP,BW,HT 这 3 个数据集的可训练参数量和 FLOPs。由表 4 可知,CGNet 和其余 5 种高光谱分类方法相比可训练参数量最少,这是因为在 CGNet 分类网络中使用了分组卷积,从而使网络偏轻量化,参数较少,其计算量也仅次于 SSRN,FC-3DCNN。和 SSRN,FC-3DCNN 相比,CGNet 参数较少,但训练时间有所增加,这是因为 CGNet 采用并行结构以加宽网络,可使每一层学习到更丰富的特征,并因此增加了训练时间成本。在 SSRN 实验中,先采用 PCA 降低光谱维数,大大降低了 SSRN 的计算量及训练时间,未降维时其计算量是目前的 4.5 倍,其训练时间是目前的 8 倍。FC-3DCNN 采用紧

凑的网络结构,结构简单、复杂度低,计算量较小,易于训练,因此训练时间较少。结合表1~表3的实验结果,本文所提出的方法训练所花费的

时间相对较少,而且分类精度较高,综合来看,本文提出的半监督的聚类分组网络 CGNet 是有效的。

表 4 在 IP, BW, HT 数据集上的可训练参数量和 FLOPs

Tab. 4 Number of trainable parameters and FLOPs on IP, BW, and HT datasets

Method	Parameters(IP/BW/HT)	FLOPs(IP/BW/HT)
ClusterCNN	201,488/201,358/201,423	26,196,864/26,196,608/26,196,736
SSRN	63,520/63,470/63,495	1,754,920/1,754,824/1,754,872
HybridSN	4,845,696/4,845,438/4,845,567	51,346,384/51,345,872/51,346,128
FC-3DCNN	995,456/995,198/995,327	4,220,000/4,219,488/4,219,744
3D-DenseNet	2,549,584/2,548,878/2,549,231	9,690,464/9,689,056/9,689,760
CGNet	58,176/57,982/58,111	5,524,480/5,508,736/5,524,352

为了验证添加主动学习方法的有效性,将 ClusterCNN 与添加主动学习技术的 ClusterCNN (AL-ClusterCNN),以及半监督的聚类分组网络 CGNet 与添加主动学习技术的 AL-CGNet,在 3 个数据集上进行实验,进而验证所提出的 AL-CGNet 的有效性。这里选择对 ClusterCNN 添加 AL 与 AL-CGNet 进行比较,是因结合表 1~表 3 的实验结果,ClusterCNN 方法相较于其他对比方法表现最优。

对于所有的非主动学习方法,从各类中选取 6% 的标记样本作为训练集对网络进行训练;对于所有的主动学习方法,实验中从各类中先选取 2% 的带标记样本作为初始训练样本集对网络进行训练。之后 4 轮采用主动学习方法主动选取信息量大的样本,给它们带上标记放入训练集中对网络进行训练,总共使用的训练集是 6% 的数据集。同时,考虑小样本的情况,共使用 5% 的标记样本作为训练集,首先从各类中选取 2% 的带标记样本作为初始训练集对网络

进行训练,之后 3 轮采用主动学习方法选取信息量大的样本给它们带上标签添加到训练集中对网络进行训练。

表 5~表 7 为两个非主动学习方法 ClusterCNN, CGNet 和两个主动学习方法 AL-ClusterCNN, AL-CGNet 在 IP, BW, HT 3 个数据集上的分类结果。使用 OA, SD, Kappa 系数、训练时间和训练样本比例作为各个分类方法的评估指标。从表 5~表 7 可以看出,使用相同数量 6% 的训练集的情况下,添加主动学习的 AL-ClusterCNN 在 IP, BW, HT 数据集上的分类结果明显高于 ClusterCNN 方法,分别提高了 2.67%, 1.49%, 2.17%。AL-CGNet 相较于 CGNet 分别提高了 1.29%, 1.03%, 1.91%, 分类结果相对较稳定,时间也较少。在 5% 小样本情况下,AL-ClusterCNN 和 AL-CGNet 均优于 ClusterCNN 和 CGNet。其中,AL-CGNet 表现最佳,所花费时间最少,分类结果稳定且分类准确率最高,相较于使用 6% 训练样本的 CGNet,在 3 个

表 5 各个方法在 IP 数据集上的分类结果

Tab. 5 Classification results of each method on IP dataset

Method	OA $\pm$ SD/%	Kappa	Time/s	Training data
ClusterCNN	95.84 $\pm$ 0.43	0.952 5	186.18	6%
CGNet	98.28 $\pm$ 0.17	0.980 3	172.66	6%
AL-ClusterCNN	98.51 $\pm$ 0.35	0.982 9	186.04	6%
	97.12 $\pm$ 0.43	0.967 1	148.31	5%
AL-CGNet	99.57 $\pm$ 0.12	0.995 0	176.84	6%
	98.90 $\pm$ 0.35	0.987 4	145.68	5%

表 6 各个方法在 BW 数据集上的分类结果
Tab. 6 Classification results of each method on BW dataset

Method	OA±SD/%	Kappa	Time/s	Training data
ClusterCNN	97.12±0.97	0.968 7	56.32	6%
CGNet	98.20±0.68	0.980 5	54.34	6%
AL-ClusterCNN	98.61±0.55	0.984 9	56.47	6%
	97.68±0.60	0.974 9	48.14	5%
AL-CGNet	99.23±0.47	0.991 7	58.16	6%
	98.81±0.58	0.987 1	47.33	5%

表 7 各个方法在 HT 数据集上的分类结果
Tab. 7 Classification results of each method on HT dataset

Method	OA±SD/%	Kappa	Time/s	Training data
ClusterCNN	96.33±0.60	0.960 3	260.50	6%
CGNet	96.91±0.28	0.966 5	255.89	6%
AL-ClusterCNN	98.50±0.53	0.983 8	274.39	6%
	97.81±0.58	0.976 3	223.69	5%
AL-CGNet	98.82±0.16	0.987 2	256.77	6%
	97.88±0.37	0.977 1	214.88	5%

数据集上的分类精度分别提高了 0.62%, 0.61%, 0.97%, 这说明 AL-CGNet 在小样本情况下也是极具优势的,也验证了主动学习技术的有效性。

表 8 为 AL-CGNet 使用更少训练样本情况下在 IP, BW, HT 3 个数据集上的分类结果。在小样本情况下, AL-CGNet 采用的主动学习方法通过选取信息量大的有效样本加入训练集来训练高性能的网络模型,有助于分类。对比表 5~表 8 可见, AL-CGNet 在使用 4% 训练样本的情况下, 仍然优于其他方法使用 6% 的训练样本, 说明

AL-CGNet 可在降低标记样本的同时获得更佳分类性能。当 AL-CGNet 使用 3% 训练样本, 相比 ClusterCNN, SSRN, HybridSN, FC-3DCNN, 3D-DenseNet 使用 6% 训练样本, AL-CGNet 在 IP 数据集上仍稍具优势; 在 BW 数据集上 AL-CGNet 和 ClusterCNN 方法持平, 但训练时间更少; 而在 HW 数据集上, AL-CGNet 相比 ClusterCNN, SSRN, HybridSN 均处于劣势。实验表明, AL-CGNet 在使用少于 3% 标记样本的情况下, 与其他方法使用 6% 标记样本相比, 小样本优势就不存在了。

表 8 AL-CGNet 方法使用更少训练样本在 IP/BW/HT 数据集上的分类结果
Tab. 8 Classification results of AL-CGNet method on IP/BW/HT dataset using fewer training samples

Index	4%			3%		
	OA±SD/%	Kappa	Time/s	OA±SD/%	Kappa	Time/s
IP	98.48±0.35	0.982 7	110.63	96.42±0.82	0.959 1	81.93
BW	98.24±1.18	0.981 0	37.25	97.22±1.43	0.969 9	28.79
HT	96.92±0.50	0.966 7	170.58	95.81±0.63	0.954 7	121.31

图 5~图 7 为 3 个数据集的地面真值图和各个分类方法在这 3 个数据集上的分类图。从图 5~图 7 可见, (b)~(f) 这些分类方法不能正确分类某些区域的像素, 例如, IP 数据集的左上角黄

框区域、BW 数据集的红框区域以及 HT 数据集的红框区域, 而 AL-CGNet 的误分类像素低于其他算法, 仍有较好的分类结果, CGNet 也有很好的表现。结合图 5~图 7 各方法的分类图, 在使用




图 5 IP 数据集的地面真值图及各个分类方法在 IP 数据集上的分类图

Fig. 5 Ground truth map of IP dataset and classification maps of each classification method on IP dataset




图 6 BW 数据集的地面真值图及各个分类方法在 BW 数据集上的分类图

Fig. 6 Ground truth map of BW dataset and the classification maps of each classification method on BW dataset




图 7 HT 数据集的地面真值图及各个分类方法在 HT 数据集上的分类图

Fig. 7 Ground truth map of HT dataset and the classification maps of each classification method on HT dataset

相同的6%标签样本的情况下,AL-CGNet在3个数据集中分类精度最高,标准差最小,分类结果比较稳定,Kappa系数最大,与其他分类方法相比有更好的分类准确率,训练时间相对较少。以上实验结果表明,AL-CGNet是有效的,不仅降低了网络参数、大大提高了分类效率,也解决了带类标样本少的问题。

4 结 论

针对高光谱图像网络参数量大、带标记样本获取困难的问题,本文提出了一种基于主动学习和聚类的偏轻量化半监督分组网络AL-CGNet用于高光谱图像分类。首先,对LDA降维后的高光谱图像使用MBK-Means将高光谱像素划分为不同的簇,并用簇中心替换簇内所有样本,以

充分利用无类标样本的信息;接着,设计了偏轻量化的2D分组卷积网络降低参数量,实现轻量化;最后,结合主动学习选取高质量的难分训练样本,解决了带类标样本少的问题。实验结果表明,在使用相同比例的6%标记样本下,AL-CGNet在Indian Pines, Botswana, Houston 3个数据集上的表现优于其他先进的高光谱分类方法ClusterCNN, SSRN, HybridSN, FC-3DCNN, 3D-DenseNet,其OA分别为99.57%,99.23%,98.82%。甚至在AL-CGNet使用5%标记样本的小样本情况下,相较于使用6%标记样本的最优方法CGNet在Indian Pines, Botswana, Houston 3个数据集上的分类结果,OA分别提高了0.62%,0.61%,0.97%,且训练时间更少。本文提出的方法在小样本情况下更有优势,尤其适用于高光谱数据。

参考文献:

- [1] HONG D F, GAO L R, YAO J, *et al.* Graph convolutional networks for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(7): 5966-5978.
- [2] XIE W Y, ZHANG X, LI Y S, *et al.* Weakly supervised low-rank representation for hyperspectral anomaly detection [J]. *IEEE Transactions on Cybernetics*, 2021, 51(8): 3889-3900.
- [3] TAN K, WANG X, NIU C, *et al.* Vicarious calibration for the AHSI instrument of Gaofen-5 with reference to the CRCS Dunhuang test site [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(4): 3409-3419.
- [4] 刘英旭,蒲春宇,许典坤,等.面向高光谱影像场景分类的轻量化深度全局-局部知识蒸馏网络[J]. *光学精密工程*, 2023, 31(17): 2598-2610.
LIU Y X, PU CH Y, XU D K, *et al.* Lightweight deep global-local knowledge distillation network for hyperspectral image scene classification [J]. *Opt. Precision Eng.*, 2023, 31(17): 2598-2610. (in Chinese)
- [5] 王碧琳,王生生,张哲.面向领域自适应的部分最优传输高光谱图像分类[J]. *光学精密工程*, 2023, 31(17): 2555-2563.
WANG B L, WANG S S, ZHANG ZH. Partial optimal transport-based domain adaptation for hyperspectral image classification [J]. *Opt. Precision Eng.*, 2023, 31(17): 2555-2563. (in Chinese)
- [6] 王爱丽,丁姗姗,刘和,等.空谱域适应与XGBoost结合的跨场景高光谱图像分类[J]. *光学精密工程*, 2023, 31(13): 1950-1961.
WANG A L, DING SH SH, LIU H, *et al.* Cross-scene hyperspectral image classification combined spatial-spectral domain adaptation with XGBoost [J]. *Opt. Precision Eng.*, 2023, 31(13): 1950-1961. (in Chinese)
- [7] LICCIARDI G, MARPU P R, CHANUSSOT J, *et al.* Linear versus nonlinear PCA for the classification of hyperspectral data based on the extended morphological profiles [J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(3): 447-451.
- [8] BANDOS T V, BRUZZONE L, CAMPS-VALLS G. Classification of hyperspectral images with regularized linear discriminant analysis [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(3): 862-873.
- [9] 孙伟伟,杨刚,彭江涛,等.鲁棒多特征谱聚类的高光谱影像波段选择[J]. *遥感学报*, 2022, 26(2): 397-405.
SUN W W, YANG G, PENG J T, *et al.* Robust multi-feature spectral clustering for hyperspectral band selection [J]. *National Remote Sensing Bulletin*, 2022, 26(2): 397-405. (in Chinese)

- [10] AHMAD M, KHAN A, KHAN A M, *et al.* Spatial prior fuzziness pool-based interactive classification of hyperspectral images [J]. *Remote Sensing*, 2019, 11(9): 1136.
- [11] WANG Y, YU W K, FANG Z C. Multiple kernel-based SVM classification of hyperspectral images by combining spectral, spatial, and semantic information [J]. *Remote Sensing*, 2020, 12(1): 120.
- [12] LUO H W, TANG Y Y, WANG Y L, *et al.* Hyperspectral image classification based on spectral-spatial one-dimensional manifold embedding [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(9): 5319-5340.
- [13] YU S Q, JIA S, XU C Y. Convolutional neural networks for hyperspectral image classification [J]. *Neurocomputing*, 2017, 219(C): 88-98.
- [14] ZHANG C J, LI G D, DU S H, *et al.* Three-dimensional densely connected convolutional network for hyperspectral remote sensing image classification [J]. *Journal of Applied Remote Sensing*, 2019, 13(1): 1.
- [15] ROY S K, KRISHNA G, DUBEY S R, *et al.* HybridSN: exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(2): 277-281.
- [16] YAO W, LIAN C, BRUZZONE L. Cluster-CNN: clustering-based feature learning for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(11): 1991-1995.
- [17] AHMAD M, KHAN A M, MAZZARA M, *et al.* A fast and compact 3-D CNN for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [18] SONG W W, LI S T, FANG L Y, *et al.* Hyperspectral image classification with deep feature fusion network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(6): 3173-3184.
- [19] ZHONG Z L, LI J, LUO Z M, *et al.* Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(2): 847-858.
- [20] ROY S K, MANNA S, SONG T C, *et al.* Attention-based adaptive spectral-spatial kernel ResNet for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(9): 7831-7843.
- [21] GUO W H, YE H L, CAO F L. Feature-grouped network with spectral-spatial connected attention for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-13.
- [22] ZHANG X R, SHANG S W, TANG X, *et al.* Spectral partitioning residual network with spatial attention mechanism for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-14.
- [23] ZHAO Z G, WANG H, YU X C. Spectral-spatial graph attention network for semisupervised hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [24] 翁汪磊, 孙伟伟, 任凯, 等. 高光谱影像领域自适应分类方法的对比分析 [J]. *遥感技术与应用*, 2023, 1-11.
- WENG W L, SUN W W, REN K, *et al.*. Comparison of domain adaptation methods for hyperspectral image classification [J]. *Remote Sensing Technology and Application*, 2023, 1-11. (in Chinese)
- [25] CAO X Y, YAO J, XU Z B, *et al.* Hyperspectral image classification with convolutional neural network and active learning [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(7): 4604-4616.
- [26] LEI Z, ZENG Y, LIU P, *et al.* Active deep learning for hyperspectral image classification with uncertainty learning [J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [27] FANG L Y, LIU G Y, LI S T, *et al.* Hyperspectral image classification with squeeze multibias network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(3): 1291-1301.
- [28] MENG Z, JIAO L C, LIANG M M, *et al.* A lightweight spectral-spatial convolution module for hyperspectral image classification [J]. *IEEE Geo-*

science and Remote Sensing Letters, 2022, 19: 3069202.

- [29] ZHANG X M, TIAN Q J, GU X F. An attention based lightweight network for hyperspectral images

classification[C]. *IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium*. July 17-22, 2022. *Kuala Lumpur, Malaysia*. IEEE, 2022:2251-2254.

作者简介:



刘 敬(1975—),女,安徽宿州人,博士,副教授,硕士生导师,2004年、2009年于西安电子科技大学分别获得硕士和博士学位,主要从事高光谱遥感影像特征提取和地物分类方面的研究。E-mail: zyhalj1975@163.com



刘 逸(1976—),男,安徽宿州人,博士,讲师,2002年、2013年于西安电子科技大学分别获得硕士和博士学位,主要从事计算智能,高光谱遥感影像特征提取和地物分类方面的研究。E-mail: yiliu@xidian.edu.cn



李银桥(1998—),女,山西永济人,硕士研究生,2020年于兰州文理学院获得学士学位,目前主要从事高光谱遥感影像光谱特征提取方面的研究。E-mail: ll577961745@163.com