

基于空谱结合孪生对比网络的高光谱遥感图像分类模型

李天聪¹, 赵佳兴², 王宇晗¹, 刘华清¹, 王雯雯¹, 蔡之华³

(1. 中国舰船研究院 数据工程技术部; 2. 中国电子科技集团公司第十一研究所, 北京 100000;
3. 中国地质大学(武汉) 计算机学院, 湖北 武汉 430078)

摘要: 当前多数高光谱图像对比学习模型在标签信息利用和正负样本均衡方面存在不足。针对高光谱遥感图像分类中的小样本问题, 提出基于空谱结合孪生对比网络的分类模型。该模型首先采用双重对比学习策略, 将有监督对比任务与分类任务并行训练, 以便更充分地利用标签信息; 其次, 引入孪生网络进行对比学习, 以正负样本对为输入, 强化模型对样本间差异性的学习能力, 提升了分类的准确性与鲁棒性; 最后, 为应对正负样本数量不平衡的问题, 采用平衡对比损失函数, 并构建对比学习与分类联合训练模型, 利用数据内在结构信息来增强模型的泛化能力, 从而在标签样本稀少的情况下进行高精度分类。在 Long Kou 和 Pavia University 标准高光谱数据集上的实验结果表明, 该模型的分类精度比表现最佳的对照模型分别提升 1.42% 和 1.32%, 分类结果图更逼近真实标签图, 解决了高光谱遥感图像分类中的小样本问题。

关键词: 高光谱图像分类; 孪生网络; 对比学习

DOI: 10.11907/rjdk.251675

扫描二维码阅读全文:



中图分类号: TP391.41

文献标识码: A

文章编号: 1672-7800(XXXX)0XX-0001-10

Hyperspectral Remote Sensing Image Classification Model Based on Spatial-spectral Combined with Siamese Contrastive Network

LI Tiancong¹, ZHAO Jiaxing², WANG Yuhang¹, LIU Huaqing¹, WANG Wenwen¹, CAI Zhihua³

(1. Data Engineering Technology Department, China Ship Research Institute;

2. The 11th Research Institute of China Electronics Technology Group Corporation, Beijing 100000, China;

3. School of Computer Science, China University of Geosciences (Wuhan), Wuhan 430078, China)

Abstract: Currently, most hyperspectral image contrastive learning models exhibit deficiencies in label information utilization and positive-negative sample balance. To address the small sample size issue in hyperspectral remote sensing image classification, a classification model based on a spatial-spectral combined siamese contrastive network is proposed. Firstly, this model adopts a dual contrastive learning strategy, training supervised contrastive tasks and classification tasks in parallel to fully utilize label information. Secondly, a siamese network is introduced for contrastive learning, taking positive-negative sample pairs as inputs to enhance the model's learning ability for sample differences, thereby improving classification accuracy and robustness. Finally, to address the imbalance between positive and negative samples, a balanced contrastive loss function is adopted, and a joint training model for contrastive learning and classification is constructed. This utilizes the inherent structural information of the data to enhance the model's generalization ability, enabling high-precision classification even with scarce labeled samples. Experimental results on the Long Kou and Pavia University standard hyperspectral datasets show that the classification

收稿日期: 2025-10-01

基金项目: 国家自然科学基金项目(61973285)

作者简介: 李天聪(1997-), 男, 博士, 中国舰船研究院数据工程技术部工程师, 研究方向为深度学习、高光谱图像处理; 赵佳兴(1999-), 男, 硕士, 中国电子科技集团公司第十一研究所工程师, 研究方向为深度学习、高光谱图像处理; 王宇晗(1996-), 男, 硕士, 中国舰船研究院数据工程技术部工程师, 研究方向为深度学习、数据挖掘; 刘华清(1992-), 女, 中国舰船研究院数据工程技术部工程师, 研究方向为网络安全、机器学习; 王雯雯(1993-), 女, 硕士, 中国舰船研究院数据工程技术部工程师, 研究方向为数据挖掘、数据应用论证; 蔡之华(1963-), 男, 博士, 中国地质大学(武汉)计算机学院教授、博士生导师, 研究方向为机器学习、演化算法、高光谱图像处理。本文通讯作者: 蔡之华。

accuracy of this model is improved by 1.42% and 1.32% respectively compared to the best-performing control model. The classification result maps are closer to the true label maps, solving the small sample size issue in hyperspectral remote sensing image classification.

Key Words: hyperspectral image classification; siamese networks; contrastive learning

0 引言

高光谱图像(Hyperspectral Images, HSIs)是当代遥感技术的重要分支之一。高光谱传感器所拍摄的高光谱遥感图像具有丰富的光谱信息,因而被广泛应用于智慧农业、军事探测、海洋探索等领域^[1-2]。然而,高光谱遥感图像中所包含的巨量波段及其复杂的数据分布使该类图像的处理难度极大,标记样本的缺失也使相关模型的训练难度大大提高。

分类是高光谱图像处理的重要步骤。不同于传统图像直接对整张图像进行分类,高光谱遥感图像分类是指对每个像素点进行单独分类。早期的HSIs分类研究通常将重点放在光谱信息的利用上,首先通过主成分分析(Principal Component Analysis, PCA)等方式提取特征;其次利用支持向量机(Support Vector Machines, SVM)等传统机器学习方法进行分类^[3]。传统的机器学习方法依赖于手工制作的特征,特征质量是影响分类效果的关键因素。然而,该类方法的特征提取步骤仅能捕获样本之间的线性关系,而HSIs复杂的数据分布中往往存在大量非线性关联,极大限制了传统分类方法的应用。

卷积神经网络(Convolutional Neural Network, CNN)、图卷积网络(Graph Convolutional Network, GCN)、自编码器(AutoEncoder, AE)、Transformer等深度神经网络具备挖掘复杂数据分布下样本非线性关联的能力,能有效适配高光谱数据的特征特性,因此被广泛应用于HSIs分类任务中^[4-9]。现有国内外相关研究围绕各类深度学习模型开展了大量探索。例如, Hu等^[10]采用一维卷积神经网络(1D-CNN)进行HSIs分类,通过卷积核沿单一光谱维度滑动的方式提取纯光谱特征,取得了优于传统机器学习方法的分类效果。Haut等^[11]采用二维卷积神经网络(2D-CNN)处理HSIs分类任务,通过卷积核在二维空间平面滑动捕获邻域空间特征,实现了高光谱空间信息的有效挖掘。Hamida等^[12]采用三维卷积神经网络(3D-CNN)进行HSIs分类,利用三维卷积核同步遍历光谱与空间维度,联合提取空谱融合特征,取得了精度更高的分类结果。Yang等^[13]采用双分支结构深度CNN进行高光谱分类,分别独立提取光谱域与空间域特征,融合双域特征后输入全连接层完成分类,有效提升了空谱特征的利用效率。Zhong等^[14]采用端到端的光谱-空间残差网络(Spectral-Spatial Residual Network, SSRN)进行HSIs分类,通过引入残差结构缓解卷积层数增加引发的模型精度退化问题,有效提升了深层卷积网络的分类稳定性。Bhatti等^[15]采用多策略融合的空间-光谱特征提取方法进行HSIs分类,首先通过局部相似性分

析实现高光谱数据的降维;其次利用2-D Gabor滤波器提取降维数据的空间特征,同时借助CNN提取原始数据的光谱特征,最终融合双域特征完成二次深度特征提取与分类,进一步优化了小样本场景下的分类性能。综上可知,深度学习模型可精准挖掘HSIs的空谱特征,大幅提升分类精度,但该类模型的训练需要大量标注样本支撑,而高光谱遥感图像的人工标注难度大、成本高,有效样本稀缺,严重制约了深度学习模型的实际应用效果。

HSIs分类面临小样本难题,对比学习凭借独特优势成为主流解决方法。其通过度量样本间的相似性与差异性完成特征学习,无需依赖大规模标注数据,可充分挖掘有限样本的数据价值,有效提升模型的泛化能力;同时具备良好的通用性与可扩展性,能够适配各类数据与视觉任务。孪生网络(Siamese Network)是对比学习的经典基础模型,该模型由两个结构完全一致、参数共享的子网络构成,通过成对输入样本完成特征提取,再通过相似度计算模块判别样本特征的异同,可高效学习正负样本对的关联特征,被广泛应用于各类对比学习任务中。在HSIs分类研究中, Huang等^[16]采用双路径孪生卷积网络(Dual-SCNN)开展小样本分类研究,通过扩展形态学特征、CNN与空谱特征融合策略构建分类框架,同时结合对抗训练与数据增强方法优化模型性能,显著提升了有限样本下的HSIs分类精度。总体而言,孪生网络凭借权重共享与对比学习的核心机制,完美适配HSIs标注数据稀缺、需度量样本特征相似性的应用场景,展现出传统深度学习模型无可替代的优势。

尽管基于对比学习的孪生网络可有效利用有限样本数据,缓解HSIs小样本分类难题,但现有相关研究仍存在诸多不足。多数研究直接将传统图像的对比学习算法迁移至HSIs分类任务中,忽略了HSIs空谱耦合、维度冗余的独特数据特性。同时,现有方法未充分利用标签信息引导对比学习训练,且忽视了训练过程中正负样本的均衡性问题,导致模型特征学习的针对性与有效性不足。针对上述问题,本文提出一种空谱结合孪生对比网络的高光谱遥感图像分类模型,从光谱、空间两个维度分层提取高光谱特征,并引入对比学习完成模型预训练,以此精准解决HSIs分类中的小样本学习难题。

1 模型构建

本文模型总体结构如图1所示,其训练分为两个阶段:第一阶段使用基于孪生网络的对比学习模型进行预训练;第二阶段保留预训练阶段的空谱特征提取网络参数,并在有监督对比分类任务中进行微调。




Fig. 1 Overall structure of the proposed model

图1 本文模型总体结构

1.1 空谱特征提取孪生对比预训练模块

该模块包含两个特征学习网络,分别从光谱维度和空间维度进行表示学习。光谱特征提取模块可视为函数 $f_{spe}()$,其可将输入的 HSI 数据 X 映射为专注于光谱信息的特征表示,这个过程可表示为 $Z_{spe} = f_{spe}(X)$ 。该模块将 HSI 的每一个像素视作一维信号,通过卷积层和池化层来提取其光谱特征,并在池化层与激活函数之间添加批归一化层,从而加速训练过程,增强模型的泛化能力,使网络更容易优化。除光谱信息外,HSIs 中还包含着丰富的空间信息,例如目标的形状、纹理等。为能充分利用这些信息,本文使用基于 2D-CNN 的模块对 HSI 进行空间特征提取,该

模块可视为一个函数 $f_{spa}()$,将输入数据 X 映射为专注于空间信息的特征表示,该过程可表示为 $Z_{spa} = f_{spa}(X)$ 。具体来说,该模块将 HSI 中心像素及其邻域像素组成的像素块视作二维图像,并通过卷积层和池化层来提取其空间特征。为充分挖掘 HSI 的光谱与空间特征信息,本文在光谱特征提取网络与空间特征提取网络的基础上构建双路卷积网络(Two-CNN)结构,以实现双域特征协同学习。该网络中的 1D-CNN 和 2D-CNN 分别负责光谱和空间特征提取,并对输出特征进行拼接,该过程可表示为 $Z_{joint} = \text{concat}(Z_{spa}, Z_{spe})$,整体的联合特征提取过程可表示为 $Z_{joint} = f_{joint}(X)$ 。

第一阶段采用孪生对比预训练架构,通过正负样本对来训练模型,其中正样本对表示相似样本,负样本对表示不相似样本。在传统图像领域,为了生成这些样本对,常对图像进行随机数据增强,例如旋转、裁剪等操作,以增强模型的泛化能力。然而,HSIs在通道维度上具有高度相似性,而空间上的信息较为稀疏。传统图像数据增强方法可能会过度关注空间维度的信息,而忽略光谱通道的重要性,从而导致特征表示不充分。针对以上问题,本研究利用HSIs的标签信息来构建正负样本对,进行孪生网络的训练。具体来说,将具有相同标签的样本视为正样本对,将具有不同标签的样本视为负样本对。当有 N 个有标样本时,组建样本对后,样本数便成为 $\frac{N \times (N-1)}{2}$,不仅达到了网络输入数据指数级别的扩充,而且还可以利用数据的标签信息来指导模型学习到更有意义的特征表示,从而提高模型的性能和泛化能力。

孪生网络通常采用对比损失进行训练。表示为:

$$L(W, (Y, Z_{joint1}, Z_{joint2})) = \frac{1}{2N} \sum_{n=1}^N Y D_W(Z_{joint1}, Z_{joint2})^2 + (1-Y) \max(m - D_W(Z_{joint1}, Z_{joint2}), 0)^2 \quad (1)$$

式中: W 表示模型的可训练参数; $(Y, Z_{joint1}, Z_{joint2})$ 表示一对输入样本, Y 表示这对样本的标签, Z_{joint1}, Z_{joint2} 表示这对样本经过空谱特征提取所产生的表示; $D_W(Z_{joint1}, Z_{joint2})$ 表示特征表示之间的欧氏距离。当网络输入正样本对时,标签为1,此时损失函数只剩下 $D_W(Z_{joint1}, Z_{joint2})^2$ 项,当该项缩小时表示两正样本之间的差距减小。反之,当标签为0时,唯一损失项则为 $\max(m - D_W(Z_{joint1}, Z_{joint2}), 0)^2$,当该项缩小表示负样本之间的距离扩大。值得注意的是,该过程中正负样本的提取网络共享可训练参数,即 $Z_{joint1} = f_{joint}(X_1), Z_{joint2} = f_{joint}(X_2)$ 。

然而,经典的对比损失存在正负样本对不均衡的问题,即在组建样本对的过程中,负样本对的数量远远大于正样本对,这会为模型训练带来负面效果。为避免此类现象发生,本研究引入指数权重来调整正负样本间的平衡。表示为:

$$L(W, (Y, Z_{joint1}, Z_{joint2})) = \frac{1}{2N} \sum_{n=1}^N \frac{1-\beta}{1-\beta^{n_+}} Y D_W(Z_{joint1}, Z_{joint2})^2 + \frac{1-\beta}{1-\beta^{n_-}} (1-Y) \max(m - D_W(Z_{joint1}, Z_{joint2}), 0)^2 \quad (2)$$

式中: $\beta \in [0, 1)$,用于控制正样本对和负样本对损失项随着正负样本对数目 n_+ 和 n_- 的增长而逐渐衰减的速度。当 β 接近0时,损失项对 n_+ 和 n_- 的增长不敏感;而当 β 接近1时,损失项对样本对数目的增长更敏感。

1.2 有监督对比学习分类模块

有监督对比学习分类模块继承了“1.1”章节中预训练的模型参数,并在此基础上进行微调。该模块包含分类损

失部分与有监督对比损失部分,二者共同指导模型训练。输入高光谱数据 X 经过融合特征提取模块得到其对应的特征表示 $Z_{joint} = f_{joint}(X)$ 。随后,该模块设置对比投影头与分类投影头两个分支,分别对应对比损失与分类损失的计算。对于第 i 个样本而言,对比头可以表示为映射函数 $h_{contrast}()$,将其对应的融合特征映射为 z_i 。分类头同样可以视为一个函数 $h_{cla}()$,将第 i 个样本表示映射为所属类别的概率分布 $\tilde{y}_i$ 。计算每个样本的有监督对比损失,公式为:

$$L_i^{sup} = -\frac{1}{2N_{\tilde{y}_i} - 1} \sum_{j=1}^{2N} 1_{i \neq j} \cdot 1_{\tilde{y}_i = \tilde{y}_j} \cdot \log \frac{\exp(z_i \cdot z_j / \tau)}{\sum_{j=1}^{2N} 1_{i \neq j} \cdot \exp(z_i \cdot z_j / \tau)} \quad (3)$$

式中: L_i^{sup} 表示第 i 个样本的有监督对比损失,且 $i \in [1, 2N]$, N 为样本数量; $N_{\tilde{y}_i}$ 表示与第 i 个样本具有相同类别的样本数量; $1_{i \neq j}$ 表示指示函数,当 $i \neq j$ 时为1,否则为0,用于在计算过程中去除自身相似度; z_i, z_j 分别表示样本 i 和 j 对应的表示; τ 用于平衡对比损失的温度参数。

整体对比损失的计算公式为:

$$L^{sup} = \sum_{i=1}^{2N} L_i^{sup} \quad (4)$$

式中: L^{sup} 表示有监督对比损失,是由每个样本的对比损失相加所得。其通过优化特征表示的方式,使得同一类别的样本在特征空间中更加接近,不同类别的样本更加分散,从而提高分类性能。

根据分类头的输出 $\tilde{y}_i$ 可以计算分类任务的交叉熵损失。公式为:

$$\hat{Y}_{class_i} = \text{softmax}(\tilde{y}_i) \quad (5)$$

$$L_{CE} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C Y_{ic} \log(\hat{Y}_{class_c}) \quad (6)$$

式中: $\hat{Y}_{class}$ 表示经过softmax函数处理后的类别概率分布; C 为类别数量; Y_{ic} 为样本 i 对应类别 c 的真实标签; $\hat{Y}_{class_c}$ 为模型预测样本 i 对应类别 c 的概率。

该模块的总损失可表示为有监督对比损失 L^{sup} 与分类损失 L_{CE} 的加权求和。公式为:

$$L_{total} = \alpha \cdot L^{sup} + L_{CE} \quad (7)$$

式中: α 为权重超参数。损失函数 L_{total} 可以综合利用标签信息和样本相似性信息来提高模型的性能和泛化能力。

1.3 模型算法

模型算法的伪代码如下:

输入:高光谱图像数据 X ,标签矩阵 Y

1 依据标签将训练集划分为样本对集 D_{pair} ;

2 初始化空谱提取网络 $f_{joint}()$,对比头 $h_{contrast}()$,分类头 $h_{cla}()$;

3 for i in epoch do

4 for $(\tilde{x}_i, \tilde{x}_j)$ in D_{pair} do

5 提取特征并获取对比表示: $z_i = h_{contrast}(f_{joint}(\tilde{x}_i)), z_j =$

$h_{contrast}(f_{joint}(\tilde{x}_j))$;

6 利用公式(2)计算对比损失,并利用Adam优化器更新网络参数;;

```
7   end
8   保留空谱特征提取网络参数 $f_{joint}()$ ;
9   for  $(\tilde{x}_i)$  in  $D_{pair}$  do
10    提取特征并获取表示:  $z_i = h_{contrast}(f_{joint}(\tilde{x}_i))$ ,
 $\tilde{y}_i = h_{cla}(f_{joint}(\tilde{x}_i))$ ;
11    利用公式(3), (4), (5), (6), (7)计算损失,并利用 Adam
优化器更新网络参数;
12  end
13  end
```

模型交替进行对比学习和分类任务训练,确保网络既能保留对比学习对特征的约束,又能适应分类任务需求。具体来说,首先进行一批次的对比学习任务训练,着重于提炼和优化特征表示;其次,在保留空谱特征提取主干网络参数的基础上进行一批次的分类任务训练,使网络能够适应分类任务,如此持续交替。

2 实验方法与结果分析

2.1 实验环境与参数设置

本文所有实验均在统一的软硬件环境下开展,以确保实验结果的公平性与可重复性。硬件配置采用 Intel i9-9900K CPU 与 NVIDIA TITAN Xp GPU,并配置 CUDA 实现并行加速。

模型网络参数设置见表 1、表 2、表 3。光谱空间特征提取网络主要由 1D-CNN 和 2D-CNN 组成。对比投影头与分类投影头则由全连接神经网络组成。

2.2 数据集

本研究在 LongKou 与 Pavia University 两个数据集上进行实验。Longkou 高光谱数据集由武汉大学测绘遥感信息工程国家重点实验室 RSIDEA 团队构建,该数据集基于新型的无人机高光谱遥感技术,于 2018 年 7 月 17 日在中国湖北省龙口镇采集,其包含一个 550×217 像素的 HSIs,共有 270 个波段,分为玉米、棉花、芝麻、圆叶大豆、长叶大豆、水稻、水体、房屋、杂草 9 个类别。Pavia University 数据集来源于意大利 Pavia 大学,涵盖了意大利 Pavias 地区的一部分区域,由 ROSIS (Reflective Optics System Imaging Spectrometer) 传感器获取。该传感器能够在 0.43~0.86 μm 的波段范围内以高光谱分辨率采集数据。Pavia University 数据集包含一个 610×340 像素的 HSIs,在移除 12 个嘈杂波段后,共有 103 个波段,分为柏油路、草甸、石、树木、金属板、裸土、沥青、砖块、阴影 9 个类别。在实验过程中,每个数据集均在各个类别中随机取 10 个样本作为训练样本,其余作为测试样本。

2.3 对照模型与评价指标

实验选取的对照模型包括:①传统机器学习分类模型 PCA-SVM;②深度学习模型 3D-CNN^[12];③结合 2D-CNN 与 3D-CNN 的深度学习模型 HybridSN^[17];④基于 HybridSN

Table 1 Parameter settings of spectral spatial feature extraction network

表 1 光谱空间特征提取网络参数设置			
分支	网络层类型	输出尺寸	参数量
光谱分支	Conv1d	[1, 32, 98]	224
	BatchNorm1d	[1, 32, 98]	64
	ReLU	[1, 32, 98]	-
	MaxPool1d	[1, 32, 49]	-
	Conv1d	[1, 32, 44]	6 176
	BatchNorm1d	[1, 32, 44]	64
	ReLU	[1, 32, 44]	-
	MaxPool1d	[1, 32, 22]	-
	Conv1d	[1, 32, 17]	6 176
	BatchNorm1d	[1, 32, 17]	64
	ReLU	[1, 32, 17]	-
	MaxPool1d	[1, 32, 8]	-
	Conv1d	[1, 32, 4]	5 152
	BatchNorm1d	[1, 32, 4]	64
	ReLU	[1, 32, 4]	-
	MaxPool1d	[1, 32, 2]	-
	Conv1d	[1, 32, 21, 21]	8 672
	BatchNorm1d	[1, 32, 21, 21]	64
	ReLU	[1, 32, 21, 21]	-
	MaxPool1d	[1, 32, 10, 10]	-
空间分支	Conv1d	[1, 64, 8, 8]	18 496
	BatchNorm1d	[1, 64, 8, 8]	128
	ReLU	[1, 64, 8, 8]	-
	MaxPool1d	[1, 64, 4, 4]	-
	Conv1d	[1, 128, 2, 2]	73 856
	BatchNorm1d	[1, 128, 2, 2]	256
	ReLU	[1, 128, 2, 2]	-

Table 2 Parameter settings of comparative projection head

表 2 对比投影头参数设置		
网络层类型	输出尺寸	参数量
Linear	[1, 288]	166 176
ReLU	[1, 288]	-
Linear	[1, 50]	14 450

Table 3 Parameter settings of classification projection head

表 3 分类投影头参数设置		
网络层类型	输出尺寸	参数量
Linear	[1, 288]	166 176
ReLU	[1, 288]	-
Linear	[1, 9]	2 601

的对比学习模型 3D-CSNet^[18];⑤基于 Transformer 的深度学习模型 SS-MTR^[19];⑥基于扩张卷积的对比学习模型 SC-EADNet^[20];⑦基于 Transformer 的对比学习模型 SC-SS-MTR^[19]。

采用总体准确率 (Overall Accuracy, OA)、平均准确率 (Average Accuracy, AA) 和 Kappa 系数 3 个指标对模型性能进行评估。

2.4 比较试验

表 4、表 5 分别为各模型在 LongKou 数据集与 Pavia University 数据集上的分类结果。可以看出,深度学习模型的综合分类性能显著优于传统机器学习模型 PCA-SVM。

这是由于传统方法仅依靠人工提取浅层特征,无法充分挖掘高光谱数据的非线性空谱关联特征;而深度学习模型凭借强大的深层特征表征能力,能够自适应学习 HSIs 的复杂空谱特征。

具体来说,在 LongKou 数据集上,传统方法 PCA-SVM 的 OA 仅为 87.17%。基础深度学习模型 3D-CNN 受限于特征提取能力不足,OA 低至 70.66%。相较于基础深度学习模型,引入对比学习机制的 3D-CSNet、SC-EADNet、SC-

SS-MTR 等模型的分类精度均有明显提升,充分证明对比学习可有效挖掘样本特征差异,适配高光谱分类任务。本文模型的 OA、AA、Kappa 系数分别达到 97.05%、95.65%、96.15%,均优于所有对比模型,取得该数据集下的最优分类效果。究其原因,本文模型依托空谱结合的特征提取结构来全面挖掘光谱与空间维度特征,同时结合有监督预训练策略优化特征表征能力,有效提升了小样本场景下的分类稳定性与精度。

Table 4 Comparison of classification result of different models on LongKou dataset

表 4 不同模型在 LongKou 数据集上的分类结果比较

(%)

类别	PCA-SVM	3D-CNN	HybridSN	3D-CSNet	SS-MTR	SC-EADNet	SC-SS-MTR	本文模型
1	88.46	75.69	83.68	99.66	92.60	99.46	99.03	98.63
2	29.61	12.22	96.03	99.69	84.51	66.86	89.30	92.78
3	19.29	10.24	100	97.91	100	87.43	100	98.10
4	94.10	53.20	94.72	92.36	90.54	99.16	95.64	94.74
5	35.43	52.38	95.17	94.45	90.07	40.73	99.59	94.80
6	65.95	61.34	85.48	98.30	97.56	88.37	99.09	98.03
7	100	99.41	93.72	94.62	95.40	99.97	96.19	99.96
8	69.62	79.64	83.05	70.73	52.61	98.26	68.67	87.35
9	28.13	31.47	94.02	94.96	89.90	52.16	99.44	96.53
OA	87.17±0.33	70.66±0.22	91.71±0.23	94.41±0.27	91.43±0.11	91.96±0.58	95.63±0.17	97.05±0.16
AA	58.96±0.25	52.84±0.42	91.76±0.18	93.63±0.33	88.13±0.23	81.37±0.43	94.11±0.13	95.65±0.09
Kappa	70.11±0.29	63.06±0.34	89.19±0.24	92.74±0.46	88.89±0.37	89.68±0.39	94.31±0.23	96.15±0.23

在 Pavia University 数据集上,各模型 OA 的变化规律与 LongKou 数据集基本一致。传统模型与基础深度学习模型分类效果较差,PCA-SVM 的 OA 仅为 68.13%,3D-CNN 的 OA 仅为 48.83%。搭载对比学习策略的各类模型性能整体优于常规深度学习模型。本文模型的 OA、AA、

Kappa 系数分别为 91.43%、95.65%、88.89%,为该数据集下的最优值,进一步验证了空谱协同特征提取与对比学习预训练机制的有效性,证明所提模型具备良好的泛化能力,可适配不同场景的高光谱分类任务。

Table 5 Comparison of classification result of different models on Pavia University dataset

表 5 不同模型在 Pavia University 数据集上的分类结果比较

(%)

类别	PCA-SVM	3D-CNN	HybridSN	3D-CSNet	SS-MTR	SC-EADNet	SC-SS-MTR	本文模型
1	83.59	10.94	84.11	80.41	79.60	85.76	93.69	92.60
2	80.39	53.55	81.43	86.34	74.74	82.92	84.90	84.51
3	57.35	39.68	88.18	90.57	79.19	84.03	92.55	100
4	55.60	80.53	91.81	90.44	74.97	81.48	90.07	90.54
5	100	99.61	96.55	97.90	93.97	99.92	98.47	90.07
6	26.39	44.73	94.58	94.58	89.47	76.07	95.72	97.56
7	57.27	35.53	100	99.85	94.87	86.11	98.85	95.41
8	67.09	52.55	92.18	84.64	91.42	58.48	96.34	52.61
9	12.50	93.45	89.01	86.66	73.68	99.05	84.67	89.90
OA	68.13±0.23	48.83±0.22	86.6±0.23	87.52±0.44	80.09±0.33	80.41±0.36	90.11±0.13	91.43±0.17
AA	60.02±0.19	56.73±0.16	90.87±0.32	90.15±0.67	83.54±0.21	83.75±0.53	92.80±0.15	88.13±0.06
Kappa	50.55±0.21	38.21±0.33	82.88±0.38	83.89±0.45	74.91±0.46	73.78±0.35	87.39±0.23	88.89±0.03

图 2、图 3 分别为各算法在 LongKou、Pavia University 数据集上的分类效果图。在 LongKou 数据集上,PCA-SVM、3D-CNN 两类方法生成的分类图存在大面积错分噪点,多种地物类别连片误判,地物边缘模糊杂乱;HybridSN、SS-MTR 等常规深度学习模型可小幅改善噪声问题,但细碎斑块错分现象仍较为突出;引入对比学习的 3D-CSNet、SC-EADNet、SC-SS-MTR 的边界连续性相较前述模型有所提升,但局部零散噪声与异类像素穿插问题未能完全消除。本文模型各类别地块轮廓完整、地物交界线平滑连贯,零

散椒盐噪声数量远少于其他算法,各类内部错分像素显著减少。

在 Pavia University 数据集上,PCA-SVM 与 3D-CNN 模型的错分区域遍布整幅影像,不同地物大面积混淆;HybridSN、SC-EADNet 能够区分主体地物,但细小地物斑块极易被错划;SC-SS-MTR 等对比学习模型整体成像质量较好,但狭长带状地物边缘存在断裂、杂点粘连问题。本文模型充分利用对比学习拉近相同空谱特征,同类地物像素聚类紧凑,狭长地物边界完整连续,异类区域混叠现象




Fig. 2 Classification effect of different models on LongKou dataset

图2 不同模型在LongKou数据集上的分类效果




Fig. 3 Classification effect of different models on Pavia University dataset

图3 不同模型在Pavia University数据集上的分类效果

得到有效抑制。

以上可视化结果表明,有监督对比学习能约束空谱特征相近样本的特征分布趋于一致,帮助模型精准区分不同地物,直观验证了空谱孪生对比网络在抑制分类噪声、优化地物边界方面的有效性。

2.5 消融实验

为验证所提模型各个模块的作用,将总体模型拆分为

6个模块分别进行验证,分别为仅提取光谱特征的1D-CNN、仅提取空间特征的2D-CNN、提取双路特征但不进行对比学习的Two-CNN、双路特征加监督对比模型SupCon、空谱特征提取有监督对比学习分类模块Siamese和孪生对比预训练模块Siamese-b。消融实验结果见表6。可以看出,完整模型在各个指标上全面领先于消融模型。具体来说,1D-CNN模型的OA较低,这是由于其仅考虑了光谱信

息,而忽略了空间上的相关性;2D-CNN在空间特征提取方面更加有效,性能优于1D-CNN。Two-CNN综合考虑光谱和空间特征信息,OA进一步提升。SupCon模型在Two-CNN的基础上引入有监督对比学习思想,Siamese模型在Two-CNN模型的基础上使用孪生网络进行对比学习,这两种模型在OA、AA、Kappa 3个指标方面均优于Two-CNN模型,证实了对比学习策略的有效性。Siamese-b模型引入平衡对比损失,相较于使用普通对比损失的Siamese模型性能略有提升,表明考虑正负样本对的平衡性可进一步提高孪生网络性能。

2.6 特征分析

为验证本文模型特征提取主干网络的有效性,对不同特征提取网络分类结果的混淆矩阵与各个模块所产生的特征分布进行可视化分析。图4、图5为不同特征提取网络的混淆矩阵,可以直观展示其在每个类别上的分类性

22406	36	0	3266	1094	5994	0	273	1432
17	4106	13	275	2441	7	0	1454	51
0	306	985	1024	160	10	0	0	536
187	3766	1	47301	5452	4647	0	668	1180
0	266	0	6	3678	1	0	183	7
7	0	0	0	160	10171	742	69	695
3	0	0	0	0	8	67032	0	3
6	267	0	2	1064	0	0	5767	8
93	147	0	621	765	393	10	71	3119

(a) 1D-CNN

34045	1	0	444	0	0	0	1	10
40	8044	4	235	11	0	0	29	1
0	42	2974	0	2	0	0	0	3
226	644	437	60006	1416	93	0	327	53
0	24	0	0	4117	0	0	0	0
0	4	0	10	22	11467	0	9	332
0	1	0	0	0	105	66693	0	247
3	655	0	12	0	0	28	6284	132
0	29	0	19	0	6	3	421	4741

(b) 2D-CNN

34429	0	5	65	0	0	0	0	2
15	8133	5	168	0	0	0	0	43
0	36	2962	3	2	0	0	0	18
478	1182	561	59437	1212	24	0	75	233
6	77	0	13	4045	0	0	0	0
8	10	29	2	26	11657	0	7	105
0	0	0	0	0	0	67037	0	0
7	898	11	11	36	0	13	5847	291
0	45	15	0	0	0	21	4	5134

(c) Two-CNN

Fig. 4 Confusion matrix on the LongKou dataset

图4 LongKou数据集上的混淆矩阵

3919	78	382	0	14	355	1555	316	2
0	11948	49	890	0	5745	0	7	0
60	19	428	0	0	26	198	1357	1
0	978	0	2047	1	27	0	0	1
0	1	2	0	1329	2	0	1	0
0	982	9	0	2	3977	0	49	0
54	1	94	0	0	3	1149	19	0
3	33	303	0	0	91	17	3225	0
0	0	0	0	0	0	0	0	937

(a) 1D-CNN

4591	202	81	7	0	20	1543	147	30
0	17585	0	857	0	197	0	0	0
96	2	1851	0	0	0	0	140	0
41	64	1	2886	8	0	1	21	32
0	0	0	0	1335	0	0	0	0
0	250	1	0	0	4768	0	0	0
172	0	0	4	0	0	1116	18	10
54	7	1140	0	0	0	2	2467	2
0	0	0	0	2	0	0	0	935

(b) 2D-CNN

4626	124	595	6	0	34	1080	149	7
0	17338	23	991	0	286	0	1	0
102	0	1745	0	0	1	127	114	0
7	28	0	3001	0	0	0	18	0
0	0	0	0	1333	0	0	2	0
0	224	0	0	0	4795	0	0	0
100	0	4	0	0	1	1202	13	0
7	0	1173	0	0	0	0	2492	0
0	0	0	4	2	0	0	0	931

(c) Two-CNN

Fig. 5 Confusion matrix on the Pavia University dataset

图5 Pavia University数据集上的混淆矩阵

为探究各组成模块对样本特征空间分布的作用,采用t-SNE算法将各模型输出的高维特征降维至二维空间进行可视化,结果如图6、图7所示。可以看出,原始特征、1D-CNN、2D-CNN、Two-CNN、SupCon、Siamese以及Siamese-b等对照模型提取的特征空间中,同类样本聚类松散、异类样本重叠穿插严重,不同类别样本特征相似度偏高,类别

Table 6 Ablation experiment result

表6 消融实验结果

(%)

模型	LongKou			Pavia University		
	OA	AA	Kappa	OA	AA	Kappa
1D-CNN	82.29±0.13	68.94±0.21	77.34±0.15	62.53±0.32	69.38±0.25	53.15±0.34
2D-CNN	95.91±0.11	95.42±0.14	94.65±0.17	85.41±0.25	88.34±0.32	81.27±0.15
Two-CNN	96.54±0.12	95.25±0.32	95.48±0.22	87.34±0.10	88.57±0.18	83.61±0.24
SupCon	97.02±0.15	95.83±0.12	96.09±0.18	89.76±0.12	89.96±0.19	86.61±0.11
Siamese	96.75±0.23	94.86±0.25	95.75±0.15	89.17±0.21	90.12±0.17	85.89±0.15
Siamese-b	96.95±0.12	96.51±0.13	95.99±0.11	89.31±0.12	90.44±0.16	86.07±0.18
本文模型	97.05±0.11	95.65±0.09	96.15±0.07	90.81±0.03	91.41±0.04	87.98±0.06

能,对角线颜色越深,分类效果越好,对角线之外颜色越深,分类错误样本越多。可以看出,在两个数据集上,1D-CNN混淆矩阵对角线之外有较多深色块,说明存在较多分类错误样本;而结合了空间信息的2D-CNN和Two-CNN深色集中在对角线,说明融合空间信息对于分类性能有很大提升。

边界模糊难分。而在本文模型得到的特征分布中,各类样本能形成聚集紧凑的独立簇团,不同类别在特征空间分区清晰、间隔明显,类内聚合度与类间分离度均优于对比算法。可视化结果直观证明,本文模型能够学习到判别性更强的空谱特征,对地物样本具备优异的特征区分与聚类能力。




Fig. 6 Visualization results of feature distribution on LongKou dataset

图6 LongKou数据集上的特征分布可视化结果




Fig. 7 Visualization results of feature distribution on the Pavia University dataset

图7 Pavia University数据集上的特征分布可视化结果

3 结语

针对高光谱遥感图像分类中的小样本问题,本文提出一种基于空谱结合的孪生对比网络模型。该模型分别采用1D-CNN和2D-CNN提取光谱特征与空间特征,兼顾光谱局部关联与空间结构信息,可实现更全面的特征表达;同时融合有监督对比学习与孪生网络策略,引入类别平衡

对比损失,用于缓解正负样本不平衡问题;将交替训练与对比任务、分类任务结合起来,增强模型的性能与泛化能力。在两个真实高光谱数据集上的实验结果表明,所提模型在小样本分类任务中的性能较表现最佳的对照方法分别提升1.42%和1.32%。然而,本文模型依靠固定尺寸卷积核提取局部空间特征,仅能捕获像素邻域级空间细节,无法依托地物天然边界获取同质区域的全局结构化空间信息;对大面积均质地物、不规则细碎地物的空间上下文

挖掘仍存在局限。后续研究将引入超像素分割算法,依托地物物理边界聚合同质像素,挖掘区块级空间关联特征;同时优化损失函数设计,结合类别分布自适应调整对比约束权重,进一步提升小样本场景下的特征判别能力与分类精度。

参考文献:

- [1] ZUO R, XIONG Y, WANG J, et al. Deep learning and its application in geochemical mapping[J]. *Earth-Science Reviews*, 2019, 192: 1–14.
- [2] LI S, SONG W, FANG L, et al. Deep learning for hyperspectral image classification: an overview[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(9): 6690–6709.
- [3] MELGANI F, BRUZZONE L. Classification of hyperspectral remote sensing images with support vector machines[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(8): 1778–1790.
- [4] SHI C, LIAO D, ZHANG T, et al. Hyperspectral image classification based on expansion convolution network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1–16.
- [5] WAN S, YANG J, GONG C. Advances of hyperspectral image classification based on graph neural networks. [J]. *Acta Electronica Sinica*, 2023, 51(6): 1687–1709.
万升, 杨健, 宫辰. 基于图神经网络的高光谱图像分类研究进展[J]. *电子学报*, 2023, 51(6): 1687–1709.
- [6] WU G, AL-QANESS M A A, AL-ALIMI D, et al. Hyperspectral image classification using graph convolutional network: a comprehensive review [J]. *Expert Systems with Applications*, 2024, 257: 125106.
- [7] KHOSLA P, TETERWAK P, WANG C, et al. Supervised contrastive learning[C]//*Advances in Neural Information Processing Systems 33 (NeurIPS 2020)*, 2020: 18661–18673.
- [8] MEI S, JI J, GENG Y, et al. Unsupervised spatial-spectral feature learning by 3d convolutional autoencoder for hyperspectral classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(9): 6808–6820.
- [9] FANG Y, YE Q, SUN L, et al. Multiattention joint convolution feature representation with lightweight transformer for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 1–14.
- [10] HU W, HUANG Y, WEI L, et al. Deep convolutional neural networks for hyperspectral image classification [J]. *Journal of Sensors*, 2015, 7: 1–12.
- [11] HAUT J M, PAOLETTI M E, PLAZA J, et al. Hyperspectral image classification using random occlusion data augmentation [J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(11): 1751–1755.
- [12] BEN H A, BENOIT A, LAMBERT P, et al. 3-d deep learning approach for remote sensing image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(8): 4420–4434.
- [13] YANG J, ZHAO Y Q, CHAN J C W. Learning and transferring deep joint spectral-spatial features for hyperspectral classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(8): 4729–4742.
- [14] ZHONG Z, LI J, LUO Z, et al. Spectral-spatial residual network for hyperspectral image classification: a 3-d deep learning framework [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 56(2): 847–858.
- [15] BHATTI U A, YU Z, CHANUSSOT J, et al. Local similarity-based spatial-spectral fusion hyperspectral image classification with deep CNN and Gabor filtering [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1–15.
- [16] HUANG L, CHEN Y. Dual-path siamese cnn for hyperspectral image classification with limited training samples [J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(3): 518–522.
- [17] CAO Z Y. Research on hyperspectral remote sensing image classification algorithm based on deep learning in small sample scenarios [D]. Hangzhou: Zhejiang University, 2023.
曹泽煜. 小样本场景下基于深度学习的高光谱图像分类算法研究 [D]. 杭州: 浙江大学, 2023.
- [18] 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.
- [19] HUANG L, CHEN Y, HE X. Spectral-spatial masked transformer with supervised and contrastive learning for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 1–18.
- [20] ZHU M, FAN J, YANG Q, et al. Sc-ea-net: a self-supervised contrastive efficient asymmetric dilated network for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1–17.

(责任编辑:尹晨茹)