

中图法分类号: 文献标识码: A 文章编号: 1006-8961(XXXX)XX-0001-16

论文引用格式: He Mengyao, He Jinrong, Liu Hanchi. Diversity prompt-guided cross-domain few-shot learning for hyperspectral image classification [J/OL]. Journal of Image and Graphics, XXXX:1-16. DOI: 10.11834/jig.250585. (何梦瑶, 何进荣, 刘寒池. 多样性提示引导的跨域小样本高光谱图像分类[J/OL]. 中国图象图形学报, XXXX:1-16. DOI: 10.11834/jig.250585. ) [DOI:10.11834/jig.250585]

## 多样性提示引导的跨域小样本高光谱图像分类

何梦瑶, 何进荣\*, 刘寒池

延安大学数学与计算机科学学院, 延安 716000

**摘要:** 目的 遥感高光谱图像分类面临标注数据稀缺, 小样本模型易过拟合等挑战, 尤其在标注样本数量较少的情况下, 模型泛化能力严重不足。为提升小样本条件下的模型鲁棒性与分类精度, 需要研究有效的数据扩增与语义增强方法, 利用预训练语言模型生成多样性语义提示, 开发了能够生成多样性训练样本并严格保持类别一致性的数据扩增技术, 旨在增强类别语义表示的丰富性, 显著提升模型在目标域上的分类准确率与泛化能力。方法 融合 HyperBlend 数据扩增与 PromptMix 语义增强方法。HyperBlend 通过对同类图像进行裁剪-拼接-掩码, 生成外观多样、语义一致的混合样本。PromptMix 则利用 BERT 为每个类别生成多样性文本提示, 并通过随机选择与正则化损失丰富语义表征。最终, 通过融合分类、跨模态对齐、对比学习及多样性正则化损失进行端到端优化。结果 在 Indian Pines (IP)、Houston (HT)、Salinas (SA) 和 LK (WHU-Hi-LongKou) 4 个标准高光谱数据集上进行实验, 取得了显著提升。IP 数据集上, 与 SCFDA 方法相比总体准确率 (OA) 提升 3.8%, 平均准确率 (AA) 提升 2.67%, Kappa 系数 (KC) 提升 4.3%。SA 数据集上, 与 MEDPL 方法相比总体准确率 (OA) 提升 1.16%, 平均准确率 (AA) 提升 0.84%, Kappa 系数 (KC) 提升 1.28%。LK 与 HT 数据集上, 分类性能与现有最佳结果 SCFDA 和 MEDPL 方法基本持平, 保持了竞争力。结论 提出 HyperBlend 方法, 通过结构化图像混合与掩码操作, 低成本生成高质量多样性训练数据; 提出 PromptMix 机制, 从语义层面引入多样性提示, 增强模型语义判别能力。二者提升了模型的鲁棒性与泛化性能。方法实现简单, 无需复杂结构或大量参数, 为高光谱图像分析及少样本学习任务提供了实用参考。

**关键词:** 高光谱图像 (HSI); 跨域小样本学习; HyperBlend 数据扩增方法; PromptMix 机制; 多模态特征对齐

### Diversity prompt-guided cross-domain few-shot learning for hyperspectral image classification

He Mengyao, He Jinrong\*, Liu Hanchi

School of Mathematics and Computer Science, Yan'an University, Yan'an 716000, China

**Abstract: Objective** Scarce annotated data is a critical bottleneck constraining the performance of remote sensing hyperspectral image classification models. The small-sample condition not only leads to model overfitting but also poses the significant challenge of severely insufficient generalization capability. To address this issue, this study aims to explore a novel solution that couples data augmentation with semantic enhancement. We innovatively utilize pre-trained language models to generate diverse semantic prompts, which guide the development of a data augmentation technique that strictly maintains category consistency. By generating training samples that are semantically rich and distributionally diverse, this technique

收稿日期: 2025-11-20; 修回日期: 2026-03-24

\* 通信作者: 何进荣 hejinrong@yau.edu.cn

基金项目: 国家自然科学基金 (项目编号: 62366053)

Supported by: National Natural Science Foundation of China (Grant No. 62366053)

aims to fundamentally strengthen the model's understanding of the core semantics of categories, rather than merely memorizing the limited training samples. Experimental results demonstrate that the proposed method effectively enhances the model's classification accuracy and generalization capability on the target domain, offering a new pathway for small-sample hyperspectral image classification. **Methods** This study employs the HyperBlend data augmentation method and the PromptMix mechanism. At the data level, the HyperBlend method performs cropping and blending of hyperspectral images from the same category, followed by the application of random rectangular masks. This process simulates real-world scenarios involving occlusion, noise, and illumination variations, thereby generating blended images that maintain semantic consistency while exhibiting visual diversity. The method is straightforward to implement, allows adjustable mask ratios, and effectively expands the training dataset. At the semantic level, the PromptMix mechanism utilizes a pre-trained BERT model to generate three diverse textual prompts for each target domain category, from which semantic features are extracted. During training, different prompt features are randomly selected as class prototypes, and a diversity regularization loss is introduced to constrain the discrepancies among these features. This prevents semantic representation from becoming homogenized, thereby enriching class representations and mitigating overfitting. In terms of loss function design, the framework integrates classification loss, cross-modal alignment loss, target-domain supervised contrastive loss, and the newly proposed diversity regularization loss, achieving end-to-end optimization. **Results** Experiments were conducted on four standard hyperspectral datasets: Indian Pines (IP), Houston (HT), Salinas (SA), and LK (WHU-Hi-LongKou), achieving significant improvements. On the IP dataset, compared with the SCFDA method, the overall accuracy (OA) increased by 3.8%, the average accuracy (AA) by 2.67%, and the Kappa coefficient (KC) by 4.3%. On the SA dataset, compared with the MEDPL method, the overall accuracy (OA) improved by 1.16%, the average accuracy (AA) by 0.84%, and the Kappa coefficient (KC) by 1.28%. On the LK and HT datasets, the classification performance was comparable to the best existing results of SCFDA and MEDPL methods, demonstrating strong competitiveness. **Conclusion** Here is the professional English translation and expansion of your method description: This paper introduces HyperBlend, a novel data augmentation method that generates high-quality, diverse training samples through structured image blending and mask operations with minimal computational overhead. By strategically fusing spectral-spatial features from limited labeled data, HyperBlend effectively simulates realistic inter-class variations and boundary conditions, addressing the data scarcity challenge in hyperspectral image analysis. Concurrently, we propose the PromptMix mechanism, which introduces semantic-level diversity through learnable prompt embeddings to enhance the model's semantic discrimination capability. This mechanism operates in the feature space, generating semantically meaningful perturbations that encourage the model to learn more robust feature representations. The synergy between HyperBlend and PromptMix creates a comprehensive augmentation framework that operates at both the pixel level (through structured image mixing) and semantic level (through prompt-based feature manipulation). The combined approach significantly improves model robustness and generalization performance in few-shot learning scenarios. Crucially, both methods feature simple implementation architectures requiring neither complex network designs nor substantial parameter additions. This practical and efficient solution provides valuable reference for the hyperspectral image analysis community, particularly for tasks with limited labeled data. Extensive experiments demonstrate consistent performance improvements across multiple benchmark datasets, validating the effectiveness of our approach for enhancing model adaptability in data-constrained environments. Key contributions include: 1) The HyperBlend method for structured spectral-spatial augmentation, 2) The PromptMix mechanism for semantic-level feature diversification, and 3) A lightweight, easily implementable framework that significantly boosts few-shot learning performance without computational burden.

**Key words:** Hyperspectral Image (HSI); Cross-Domain Few-Shot Learning; HyperBlend Data Augmentation Method; PromptMix Mechanism; Multimodal Feature Alignment

## 0 引言

高光谱图像 (Hyperspectral Image, HSI) 兼具丰富的光谱信息与空间信息, 具有“图谱合一”的特点, 在环境监测、精准农业、资源勘探等领域展现出重要的应用价值。然而, 高光谱图像分类在走向实际部署的过程中仍面临两大关键挑战: 一是目标场景中标注样本通常极为稀缺, 这使得依赖大量标注数据的传统监督学习方法泛化性能显著下降; 二是高光谱数据维度高、信息冗余, 易引发“维数灾难”, 加之不同成像条件与地理场景之间的域偏移问题, 共同制约了模型对跨域稳健特征的提取能力。因此, 如何在小样本条件下实现高光谱图像的准确、鲁棒分类, 成为提升其实际应用效能的关键前提。

为降低高光谱分类对标注数据的依赖, 研究者从多个方向上进行了探索。何进荣等人(2021)提出基于三维卷积自编码器的无监督分类方法, 通过光谱融合与端到端训练提升分类效果。在特征保持与重建方面, Tian 等人(2025)构建了基于波段相关结构与 Tikhonov 正则化的光谱保持重采样框架, 有效抑制光谱畸变; Nguyen 等人(2025)则设计空间-光谱 U-netFormer 网络, 融合 Transformer 与注意力 U-net, 提取局部与全局空间特征及长短期光谱关系; 张燕斌等人(2023)提出的双路径一致性深度特征共享学习模型, 显著提升了模型的域适应能力与分类精度。在开放集识别方向, Xi 等人(2025)设计了 Hyper-CASR 框架, 结合分组光谱空间保持变换器与类感知语义重建模块, 提升已知类别识别精度并实现未知样本拒绝; Nirala 等人提出多级特征对齐约束网络, 通过集成 CNN-Transformer 架构增强域不变特征学习。针对标注稀缺问题, Arshad 等人(2024)构建混合卷积 Transformer 框架, 在极低标注比例下保持较高分类精度; Li 等人(2024)提出语义引导原型学习方法, 通过语义信息融合增强原型表达能力。在特征融合与结构优化方面, Siyuan 等人(2023)设计了多层特征融合模块, 融合光谱-空间-边缘特征; Wen 等人(2023)将 FE-HybridSN 与焦点损失结合以应对类别不平衡。针对高光谱遥感图像分类所面临的小样本、高维及跨域适应等关键问题, 近年来基于深度学习的创新方法不断涌现。张宇翔等人(2025)提出一种基于局部表征的少样本学习框架, 通过设

计局部表征与跨域对齐机制, 有效应对新类别与域偏移的挑战。赵茹等人(2024)则针对小样本问题, 构建了多尺度多通道 3D-CNN 与注意力机制结合的分类模型, 并进一步集成生成对抗网络进行数据增强, 形成渐进式增强分类框架, 显著提升小样本分类性能。此外, 张锦丽等人(2024)从信息融合角度出发, 分别采用双支路长短期记忆网络实现光谱-空间特征融合, 以及多分支注意力增强卷积网络结合数据增强策略。在对抗鲁棒性方面, 石程等人(2024)提出了对比半监督对抗训练方法, 通过构造对比损失与高迁移性对抗样本, 在少量标记样本下显著提升了模型对已知与未知攻击的防御能力。针对跨数据集分类问题, 马晓瑞等人(2024)设计了一种融合特征优化的无监督方法, 通过特征均衡、匹配与对抗优化策略, 有效提升了跨域分类精度与预测多样性。在跨域少样本学习场景下, 杨丽霞等人(2026)提出了一种嵌入 Transformer 层的轻量级双流特征提取网络 (LRCT-CDFSL), 能够同时建模光谱长程依赖与空间局部特征, 在目标域少样本条件下取得了优越的分类性能。此外, 许媛媛等人(2025)针对视觉-语言预训练模型 CLIP 的域适应问题, 提出了双模态域无关提示学习方法 (DDAPs), 通过文本与视觉提示的协同优化, 学习域不变且判别性的特征, 在多个标准域适应基准上取得了领先性能。这些工作从不同角度推动了高光谱图像分类在实际复杂场景下的实用化进展。

尽管上述方法在无监督学习、跨域适应、开放集识别与小样本学习等方面取得显著进展, 当前方法仍普遍存在标注依赖强、特征冗余度高、模型泛化能力有限等问题。为此提出一种面向小样本高光谱图像分类的多样性提示引导跨域小样本学习框架 (Diversity Prompt-guided Cross-Domain Few-Shot Learning, DP-CDFSL), 通过对目标域进行数据增强并引入多样化文本提示, 进一步提升模型在有限标注样本下的泛化性能。本文的主要贡献如下:

- 1) 提出协同优化数据多样性与语义多样性的 DP-CDFSL 框架。从数据与语义两个层面同步增强模型的泛化能力, 通过 HyperBlend 数据增强与 PromptMix 语义生成机制的协同作用, 提升模型在目标域上的分类性能。

- 2) 设计了 HyperBlend 增强方法与 PromptMix 机制两项核心技术。HyperBlend 通过对同类样本进行

裁剪、拼接与随机掩码操作,以较低计算代价生成视觉多样、语义一致的训练样本。PromptMix 则利用预训练语言模型生成多样化文本提示,结合多样性正则化损失,防止语义表示坍塌,从而学习更具判别力的语义原型。

3) 在 IP、HT、SA 和 LK 四个公开高光谱数据集上进行实验,结果验证了所提框架与方法的有效性和先进性。

## 1 本文方法

面向小样本高光谱图像分类,提出一种多样性提示引导跨域小样本学习框架(DP-CDFSL),通过协同优化数据与语义层面的多样性,显著提升模型在目标域上的泛化能力。主要针对跨地理场景或跨成像条件的域偏移问题。即源域(如 Chikusei 数据集)和目标域(如 IP, LK 等)包含相似的地物类别(如植被、建筑、水体等),但由于成像地点、时间、传感器参数、光照条件等不同,导致数据分布存在差异,让模型利用源域知识,快速适应目标域的新场景。在数据层面,设计 HyperBlend 增强方法,以缓解目标域标记样本稀缺的问题。具体而言,对给定目标域样本,从同类其他样本中随机裁剪图像块,并通过拼接操作将其与原始样本融合,生成结构更丰富的混合图

像。随后,对混合图像施加随机矩形掩码,以模拟真实场景中遮挡、噪声及光照变化。该方法以较低计算成本生成外观多样且语义一致的训练样本,增强了模型对目标域外观变化的适应性。

在语义层面,提出 PromptMix 机制,利用预训练语言模型(如 BERT, Bidirectional Encoder Representations from Transformers)为每个目标域类别生成多样化文本提示,并提取其语义特征。训练过程中,随机选用提示特征作为语义原型,以替代传统的单一类别嵌入。为增强提示间的区分性,进一步引入多样性正则化损失,防止语义表示坍塌。

模型整体损失由多项约束构成,包括交叉熵分类损失、跨模态对比损失、目标域监督对比损失以及多样性正则化损失。通过端到端联合优化,模型能够同时学习判别性视觉特征与鲁棒语义原型,从而在少量标注样本下实现优异的分类性能。

### 1.1 DP-CDFSL 框架图

图 1 展示了 DP-CDFSL 网络的框架图,其核心特点是采用双分支异构处理流程:源域遵循标准的元学习范式,而目标域则额外引入了针对性的数据与语义增强,以实现知识的有效迁移与自适应。整体流程包含三个主要阶段:数据输入与预处理阶段、特征提取与映射阶段、多任务优化阶段。

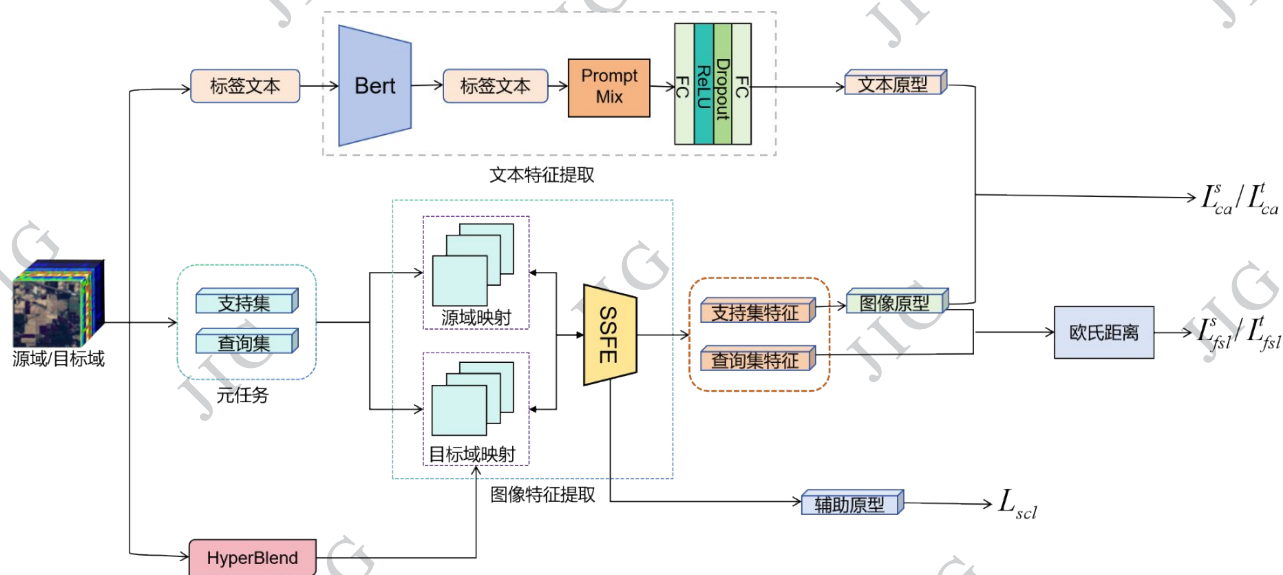


图 1 DP-CDFSL 模型架构图

Fig. 1 DP-CDFSL Model Architecture Diagram

数据输入阶段,源域与目标域高光谱图像分别划分为支持集与查询集,构成元学习任务。假设源域支持集  $S_s$  包含  $N_s$  个样本,目标域支持集  $S_t$  包含  $N_t$  个样本,查询集  $Q_s$  和  $Q_t$  分别包含  $M_s$  和  $M_t$  个样本,所有图像块的空间尺寸为  $H \times W$ ,光谱波段数为  $B$ 。目标域支持集进一步经 HyperBlend 模块增强,通过图像混合与随机掩码生成多样化训练样本。语义层面, PromptMix 机制为目标域生成多样化文本提示,与源域标准标签文本共同输入 BERT,并经过映射网络生成文本原型。文本原型特征  $v_s$  和  $v_t$  的维度均为  $[C, D_t]$ ,其中  $C$  为类别数,  $D_t$  为文本特征维度。特征提取阶段,源域与目标域特征分别通过域特定映射模块处理,随后输入共享的光谱-空间特征提取器 (SSFE)。SSFE 输出源域支持集特征  $z_s^{sup}$ , 维度为  $[N_s, D]$  与查询集特征  $z_s^{que}$ , 维度为  $[M_s, D]$ 、目标域查询集特征  $z_t^{que}$ , 维度为  $[M_t, D]$  与支持集特征  $z_t^{sup}$ , 维度为  $[N_t, D]$ 。此外,还生成辅助原型,为后续跨域对齐与分类提供特征表示。其中,源域和目标域的支持特征会进一步生成图像原型  $P_s$  和  $P_t$ , 维度为  $[C, D]$ 。在损失计算与模型训练环节: FSL 损失 ( $L_{fsl}^s, L_{fsl}^t$ ) 通过计算图像原型与查询特征的欧氏距离得到,用于在源域和目标域分别执行少样本学习,实现源域知识向目标域的迁移; 跨模态对齐损失 ( $L_{ca}^s, L_{ca}^t$ ) 通过拉近图像原型与文本原型的距离实现,帮助图像特征提取器获取标签文本的语义先验,其中,跨模态对齐损失采用 InfoNCE 损失 (info noise-contrastive estimation loss), 监督对比损失采用监督对比损失 (supervised contrastive loss, SupCon)。目标域损失 ( $L_{sc1}^t$ ) 基于增强特征计算,计算多样化损失 ( $L_{div}$ ), 通过缩小同类特征距离、扩大异类特征距离,学习掩码鲁棒的判别特征。

最终,模型总损失为

$$L = L_{fsl} + \lambda_1 L_{ca} + \lambda_2 L_{sc1} + \lambda_{div} L_{div}$$


式中,  $L_{fsl} = L_{fsl}^s + L_{fsl}^t$ ,  $L_{ca} = L_{ca}^s + L_{ca}^t$ ,  $L$  表示模型的总损失,  $L_{fsl}$  表示少样本学习损失,  $L_{ca}$  表示跨模态对齐损失,  $L_{sc1}$  表示监督对比损失,  $L_{div}$  表示多样性正则化损失,  $\lambda_1, \lambda_2, \lambda_{div}$  为正则化参数。

测试阶段,仅需利用训练好的目标映射层和图像特征提取器提取测试样本的图像嵌入特征,再通过最近邻分类器,依据特征距离完成新类别样本的分类预测。

## 1.2 HyperBlend 数据增强模块

如图 2 所示,针对跨域小样本高光谱图像分类中目标域样本稀缺、域间差异显著,以及模型局部特征组合与缺失特征推断能力不足的问题,提出核心创新模块——HyperBlend 数据增强模块,通过“组合+缺失”的序列化增强策略,生成兼具多样性与挑战性的训练样本。

该模块以目标域高光谱图像为输入,具体流程是先随机选取两张同类别的图像,保证生成样本的类别标签不变,避免语义噪声的引入。提取其光谱-空间特征图,分别记为特征图 A 和特征图 B,从特征图 A 中裁剪一个占整体面积 10% - 30% 的局部特征块,将其拼接至特征图 B 的对应位置,形成结构增强的混合图像。促使模型摆脱对全局结构的依赖,强化对局部语义组合规律的学习与判别能力。随后,以 0.3 的概率对混合图像施加随机矩形掩码 (掩码边长占比 10% - 30%), 遮挡相应区域的光谱-空间特征,模拟真实场景中因遮挡、噪声或云层引起的信息缺失,提升模型在特征不完整条件下的鲁棒推理能力。裁剪和掩码的比例范围 (如 10%-30%) 是可调的,通过实验确定合适的参数,避免生成过于失真或无意义的样本。



经过上述处理生成的图像

图 2 数据增强模块

Fig. 2 Data Enhancement module

将输入后续目标映射模块,用于特征提取、跨模态对齐及监督对比学习。总体而言,HyperBlend 模块通过“先组合、后掩码”的协同增强机制,有效缓解目标域样本数量有限和特征多样性不足的问题,显著提升模型在跨域场景中对局部特征的适应能力与对缺失信息的推断性能。

## 1.3 文本特征提取——PromptMix 机制

图 3 展示了 PromptMix 机制的工作流程 (以健康的玉米叶片为例)。其为每个类别生成多样化的文本提示,以增强语义表示的丰富性与鲁棒性。提出的“多样性语义提示”是指针对高光谱图像分类中的

每个地物类别,利用预训练语言模型,通过一组人工预定义的、表述各异的文本模板,生成多个语义相近但表达方式不同的文本描述。

具体而言,流程从输入类别标签(如“健康的玉米”)开始,通过三个预定义的、类别无关的文本模板并行生成多样文本提示。这些模板旨在从不同角度描述类别,例如:“这是一张{类别}的高光谱图像”(侧重场景描述),“图像中的物体是{类别}”(侧重物体识别),“{类别}的遥感影像”(侧重数据来源),模板的设计融合了自然语言处理技巧与遥感领域知识,其质量是生成高质量语义提示的基础。生成的提示文本随后经由预训练BERT模型编码为语义特征 $V_i$ 。对于文本提示质量的评价,采用间接的、基于任务性能的评估方式。文本提示的效用最终通过其是否能提升下游高光谱图像分类的准确率来综合衡量。在加入PromptMix机制后,模型在多个数据集上的分类性能总体准确率(overall accuracy, OA),平均准确率(average accuracy, AA)和Kappa系数(Kappa coefficient, Kappa)均获得进一步提升,这有力地证明了所生成语义特征的有效性。

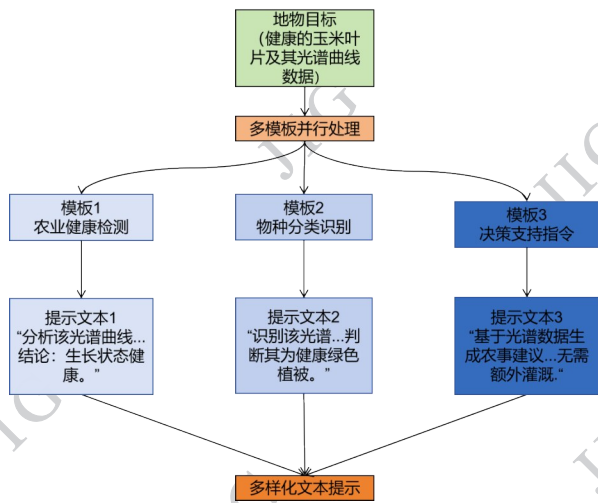


图3 PromptMix机制流程图

Fig. 3 Flowchart of the PromptMix mechanism

在训练过程中,系统会随机选择这些提示特征作为类别原型,以引入语义多样性。为进一步确保不同提示之间的差异性,防止语义表示坍塌,我们引入了多样性正则化损失 $L_{div}$ 。通过最大化不同提示特征之间的差异,从模型优化的层面主动约束和保障了“多样性”的质量,促使模型学习到更具判别力的、丰富的类别语义原型。实现从单一类别标签到

多样化语义特征的高效映射,有效支持小样本跨域分类中的语义增强需求。

#### 1.4 算法流程

DP-CDFSL算法的计算步骤如算法1所示。

##### 算法1 DP-CDFSL训练过程

**输入:** 源域数据集 $D_s$ ; 支持集 $S_s$ , 维度为 $[N_s, H, W, B]$ 和查询集 $Q_s$ , 维度为 $[M_s, H, W, B]$

目标域数据集 $D_t$ ; 标注支持集 $S_t$ , 维度为 $[N_t, H, W, B]$ 和查询集 $Q_t$ , 维度为 $[M_t, H, W, B]$

源域语义标签集 $T_s$

目标域语义标签集 $T_t$

目标多样性提示集 $P_t$

训练回合数 $E$

**输出结果:** 优化后的映射网络和编码器参数

模型总损失 $L$

**算法流程:**

1) 初始化映射网络 $f_{src}$ 、 $f_{tar}$ 和编码器 $f_{enc}$

2) for episode=1 to E do

3) 为每个目标域类别生成多样性语义提示 $P_t$

4) 提取语义特征: $v_s = \text{BERT}(T_s), v_t = \text{BERT}(T_t \cup P_t)$ (维度为 $[C, D_i]$ )

5) 从 $D_s$ 采样小样本任务: $(S_s, Q_s)$

6) 从 $D_t$ 采样小样本任务: $(S_t, Q_t)$

7) 提取源域支持特征: $z_s^{sup} = f_{enc}(f_{src}(S_s), v_s)$ (维度为 $[N_s, D]$ )

8) 提取源域查询特征: $z_s^{que} = f_{enc}(f_{src}(Q_s))$ (维度为 $[M_s, D]$ )

9) 提取目标域支持特征: $z_t^{sup} = f_{enc}(f_{tar}(S_t), v_t)$ (维度为 $[N_t, D]$ )

10) 提取目标域查询特征: $z_t^{que} = f_{enc}(f_{tar}(Q_t))$ (维度为 $[M_t, D]$ )

11) 计算源域原型: $P_s = \text{mean}(z_s^{sup})$

12) 计算目标域原型: $P_t = \text{mean}(z_t^{sup})$

13) 计算小样本损失: $L_{fsl} = L_{ca}(z_s^{que}, P_s) + L_{ca}(z_t^{que}, P_t)$

14) 计算跨模态对齐损失: $L_{ca} = L_{infoNCE}(v_s, z_s^{sup}) + L_{infoNCE}(v_t, z_t^{sup})$

对比增强学习

15) 生成目标域增强视图: $\tilde{X}_t^1, \tilde{X}_t^2 = \text{矩阵掩码增强}(X_t)$ (维度为 $[N_t, H, W, B]$ )

16) 计算监督对比损失: $L_{supCon} = L_{SupCon}(f_{enc}(f_{tar}(\tilde{X}_t^1)), f_{enc}(f_{tar}(\tilde{X}_t^2)))$

17) 计算多样性损失: $L_{div} = \lambda_{div} \cdot L_{diversity}(v_t)$

总损失优化

18) 总损失:  $L = L_{\text{ssl}} + 2.5 \times L_{\text{ca}} + 2.5 \times L_{\text{scf}} + 0.5 \times L_{\text{div}}$

19) 反向传播更新参数:  $\theta \leftarrow \theta - \eta \nabla_{\theta} L$

周期性评估

20) if episode %500 == then

21) 在目标域测试集上使用KNN分类器进行评估

22) 保存最佳模型参数

23) end if

24) end for

25) return 优化后的模型和最佳准确率

模型训练完成后,测试或推理时,仅需输入目标域的测试图像。模型利用已训练好的目标映射层和图像特征提取器,直接提取测试样本的图像嵌入特征。分类过程通过计算测试特征与在训练阶段已学习并固定的目标域类别原型之间的欧氏距离,采用最近邻分类器完成预测。这些类别原型是在训练过程中,通过 PromptMix 机制生成的多样化文本提示与目标域支持集图像特征进行跨模态对齐后得到的语义视觉联合表征。因此,在推理阶段无需再次输入或生成任何目标域的文本信息,简化部署流程,符合实际应用场景的需求。

## 2 实验与分析


### 2.1 数据集

#### 2.1.1 来源域数据集

使用的来源域数据集是实验 Chikusei(CH)高光谱数据集。CH数据集的伪彩色图像及真实地图分布如图4,详细的类别样本统计信息则列于表1。

#### 2.1.2 目标域数据集

目标域数据集有四个公开数据集,IP(Indian



(a) 伪彩色图像 (b) 真实地图


图4 Chikusei数据集

Fig. 4 Chikusei data set

表1 CH数据集的类别及样本个数

Table 1 The type and number of samples of theCHdataset

类别	类别名称	样本个数
1	Water	2345
2	Bare soil (school)	2859
3	Bare soil (park)	236
4	Bare soil (farmland)	48525
5	Natural plants	4297
6	Weeds in farmland	1108
7	Forest	20516
8	Grass	6515
9	Rice field (groom)	13369
10	Rice field (first stage)	1268
11	Row crops	5961
12	Plastic house	2193
13	Manmade (nan-dark)	1220
14	Manmade (dark)	7664
15	Manmade (blue)	431
16	Manmade (red)	222
17	Manmade grass	1040
18	Asphalt	801
19	Paved ground	145
总样本数		77592



(a) 伪彩色图像 (b) 真实地图

图5 IP数据集


Fig. 5 IP data set

Pines)数据集,HT(Houston)数据集,SA(Salinas)数据集,LK(WHU-Hi-LongKou)数据集。表2-表5列出了各数据集中各个类别的样本数量分布,图5-图8则展示了对应的伪彩色合成影像及其真实地图。

### 2.2 实验对比


为系统评估所提出的 DP-CDFSL (Dual-Prototype Cross-Domain Few-Shot Learning)方法在有

图6 HT数据集  
Fig. 6 HT data set



(a) 伪彩色图像


(b) 真实地图



(a) 伪彩色  
图像

(b) 真实地  
图

图7 SA数据集  
Fig. 7 SA data set



(a) 伪彩色  
图像

(b) 真实地  
图

图8 LK数据集  
Fig. 8 LK data set

表2 IP数据集中每个类别的样本数量

Table 2 The type and number of samples of the IP dataset

类别	类别名称	样本个数
1	Alfalfa	46
2	Corn notill	1428
3	Corn mintill	830
4	Corn	237
5	Grass pasture	483
6	Grass trees in farmland	730
7	Grass pasture mowed	28
8	Hay windrowed	478
9	Oats	20
10	Soybean notill	972
11	Soybean mintill	2455
12	Soybean clean	593
13	Wheat	205
14	Woods	1265
15	Buildings Grass Trees Drives	386
16	Stone Steel Towers	93
样本总数		10249

限标注样本条件下的分类性能及其在跨域高光谱图像分类任务中的有效性,本研究选取了八种具有代表性的先进方法进行全面对比。这些方法涵盖了从基础深度学习架构到最新跨域小样本学习策略的技术演进路径,能够多维度、多层次地检验 DP-CDFSL 的创新性、鲁棒性与泛化能力。

首先,在基线模型层面,选择了经典的光谱-空间残差网络(Spectral-Spatial Residual Network, SSRN)(Zilong等,2018)。该模型是早期在HSI分类中成功融合光谱与空间特征的深度学习代表,其性能可作为判断后续小样本方法是否实现有效提升的重要基准。

在跨域小样本学习方法中,本研究纳入了该领域发展过程中的多个关键节点工作。深度跨域小样本学习(Deep Cross-Domain Few-Shot Learning, DCFSL)(Li等,2021)是较早系统探索该问题的框架之一。随后,图信息聚合跨域小样本学习(Graph Information Aggregation Cross-Domain Few-Shot Learning, Gia-CFSL)(Zhang等,2022)引入图神经网络建模样本间关系,进一步提升了特征传递的效率。

表3 HT数据集的类别及样本个数  
Table 3 The type and number of samples

/of the HT dataset		
类别	类别名称	样本个数
1	Healthy grass	1251
2	Stressed grass	1254
3	Synthetic grass	697
4	Trees	1244
5	Soil	1242
6	Water	325
7	Residential	1268
8	Commercial	1244
9	Road	1252
10	Highway	1227
11	Railway	1235
12	Parking Lot 1	1233
13	Parking Lot 2	469
14	Tennis Court	428
15	Running Track	660
总样本数		15029

自适应域对抗小样本学习 (Adaptive Domain-Adversarial Few-Shot Learning, ADA-FSL) (Ye 等, 2023) 则通过动态对抗机制缓解域偏移, 代表了对抗训练在该方向上的有效应用。

近年来, 研究焦点转向更精细的特征与关系优化。面向跨域小样本高光谱图像分类的多级关系学习 (Multi-level Relation Learning for Cross-Domain Few-Shot Hyperspectral Image Classification, MLRL-FSL) (Liu 等, 2024) 从多层次建模样本和特征关系。基于特征解缠的跨域小样本高光谱图像分类 (Cross-domain Few-shot Learning based on Feature Disentanglement, FDFSL) (Qin 等, 2024) 致力于分离域不变与域特异性特征以提升可迁移性。面向小样本高光谱图像分类的光谱上下文感知频域对齐 (Spectral Context-aware Frequency Domain Alignment, SCFDA) (Ma 等, 2025) 创新性地 在频域进行特征对齐。用于鲁棒小样本高光谱图像分类的动量增强双原型学习框架 (Momentum-Enhanced Dual-Prototype Learning Framework, MEDPL) (Liu 等, 2025) 则利用动量机制稳定原型学习过程, 是近期性能突出的方法之一。

表4 SA数据集的类别及样本个数  
Table 4 The type and number of samples of the SA dataset

类别	类别名称	样本个数
1	Broccoli green weeds1	2009
2	Broccoli green weeds2	3726
3	Fallow	1976
4	Fallow rough plow	1394
5	Fallow smooth	2678
6	Stubble	3959
7	Celery	3579
8	Grapes untrained	11271
9	Soil vinyard develop	6203
10	Corn senesced green weeds	3278
11	Lettuce romaine 4wk	1068
12	Lettuce romaine 5wk	1927
13	Lettuce romaine 6wk	916
14	Lettuce romaine 7wk	1070
15	Vinyard untrained	7268
16	Vinyard vertical trellis	1807
样本总数		54129

表5 LK数据集的类别及样本个数  
Table 5 The type and number of samples

/of the LK dataset		
类别	类别名称	样本个数
1	Corn	34511
2	Cotton	8374
3	Sesame	3031
4	Broad-leaf soybean	63212
5	Narrow-leaf soybean	4151
6	Rice	11854
7	Water	67056
8	Roads and houses	7124
9	Mixed weed	5229
样本总数		204542

通过与上述覆盖不同技术路线的八种方法进行系统、公平的比较, 本研究能够全面验证 DP-CDFSL 在解决跨域小样本高光谱图像分类问题时, 在特征对齐效率、原型表示质量以及对极端有限标注数据

的利用能力等方面的综合优势与性能提升,从而严谨论证所提出方法的有效性与先进性。

表6 分类性能对比(IP)  
Table 6 Classification performance comparison(IP)

种类	SSRN	DCFSL	Gia-CFSL	ADA-FSL	MLRL-FSL	FDFSL	SCFDA	MEDPL	Ours
OA(%)	65.72 ±3.77	64.89 ±3.50	65.44 ±2.23	68.61 ±3.54	69.38 ±3.87	70.20 ±2.66	81.58 ±0.79	80.66 ±1.38	<b>85.38</b> <b>2.39</b>
AA(%)	79.22 ±1.61	75.74 ±2.44	76.08 ±1.48	80.34 ±1.96	80.70 ±1.22	80.42 ±1.95	89.00 ±1.19	88.43 ±1.27	<b>91.67</b> <b>1.35</b>
Kappa(%)	61.72 ±3.90	<b>60.36</b> ±3.96	61.02 ±2.53	64.76 ±3.78	65.70 ±4.11	66.48 ±2.94	79.19 ±1.97	78.14 ±1.54	<b>83.4912</b> <b>2.6238</b>

注:黑色加粗字体表示最优结果。

表6至表9分别展示了IP、LK、SA及LK数据集在每类五个标记样本下的分类性能。IP数据集上(表6),在16个类别中的13个类别上取得最高分类精度,且在类别2、3、10等相对最优方法优势显著。在整体指标上,所提方法在OA(85.38%±2.39)、AA

(91.67%±1.35)及KC(83.49%±2.62)上均优于所有对比方法。与SCFDA相比,在OA、AA和KC上分别提升3.8%、2.67%和4.3%,且各指标标准差较低,表现出良好的稳定性与鲁棒性。

表7 分类性能对比(LK)  
Table 7 Classification performance comparison(LK)

种类	SSRN	DCFSL	Gia-CFSL	ADA-FSL	MLRL-FSL	FDFSL	SCFDA	MEDPL	Ours
OA(%)	92.56 ±2.53	95.08 ±1.18	94.49 ±1.72	93.49 ±2.45	94.93 ±1.96	94.89 ±2.22	<b>96.27</b> <b>2.12</b>	96.10 ±3.47	<b>96.20</b> <b>1.71</b>
AA(%)	89.35 ±2.96	<b>91.10</b> ±2.18	90.46 ±2.32	92.58 ±1.66	93.94 ±1.74	90.55 ±2.82	<b>93.71</b> <b>2.44</b>	90.37 ±1.54	<b>94.27</b> <b>1.68</b>
Kappa(%)	90.39 ±3.21	93.58 ±1.52	92.82 ±2.21	91.59 ±3.09	93.43 ±2.49	93.35 ±2.84	<b>95.15</b> <b>2.72</b>	94.82 ±4.07	<b>95.0515</b> <b>2.1827</b>

注:黑色加粗字体表示最优结果。

表7对比了LK数据集的分类结果。DP-CDFSL方法在OA、AA、KC上分别达到96.20±1.27、94.27±1.68和95.0515±2.1827,相比传统最优方法SSRN分别提升3.64%、4.92%、4.7605%,与跨域最优方法SCFDA基本持平。

表8显示了SA数据集上的对比结果。DP-CDFSL方法在OA、AA、KC上分别为94.33%±0.42、97.20%±0.39和93.69%±0.46,与传统最优方法SSRN相比分别提升5.20%、2.41%和5.74%,与跨域最优方法MEDPL相比分别提升1.16%、0.84%、1.28%。

在HT数据集上的实验结果如表9所示。DP-CDFSL方法在此场景下同样展现出卓越的性能,其

总体精度、平均精度与Kappa系数分别为79.36%±1.94、81.36%±2.50和76.65%±3.03,均取得了当前最优的实验数值。相较于在该数据集上表现最佳的传统方法SSRN,DP-CDFSL在OA、AA和KC上分别实现了8.90%、6.39%和8.57%的大幅度性能超越,优势更为明显。与此同时,与当前主流的跨域小样本学习最优方法,如SCFDA和MEDPL等相比,DP-CDFSL所取得的各项指标与其性能相当,均达到了领域内的领先水平。这进一步验证了所提方法在不同数据集和跨域任务上均具备稳健且优越的泛化性能,其有效性不局限于单一数据分布,具有较强的实用价值与推广潜力。

图9-12展示了DP-CDFSL在四个高光谱数据集  
©中国图象图形学报版权所有

表8 分类性能对比(SA)

Table 8 Classification performance comparison(SA)

种类	SSRN	DCFSL	Gia-CFSL	ADA-FSL	MLRL-FSL	FDFSL	SCFDA	MEDPL	Ours
OA(%)	89.13 ±2.59	90.51 ±0.99	89.75 ±0.80	90.52 ±1.90	89.97 ±1.73	90.85 ±0.90	92.83 ±0.71	93.17 ±0.48	<b>94.33</b> <b>0.42</b>
AA(%)	94.79 ±0.55	94.52 ±0.66	93.10 ±1.19	95.30 ±0.99	93.82 ±1.54	94.35 ±0.98	96.23 ±0.82	96.36 ±0.66	<b>97.20</b> <b>0.39</b>
Kappa(%)	87.95 ±2.80	89.45 ±1.09	88.60 ±0.90	89.48 ±2.09	88.83 ±1.92	89.83 ±0.99	92.03 ±0.79	92.41 ±0.54	<b>93.6919</b> <b>0.4626</b>

注:黑色加粗字体表示最优结果。

表9 分类性能对比(HT)

Table 9 Classification performance comparison(HT)

种类	SSRN	DCFSL	Gia-CFSL	ADA-FSL	MLRL-FSL	FDFSL	SCFDA	MEDPL	Ours
OA(%)	70.46 ±1.24	74.22 ±2.92	72.26 ±3.60	74.77 ±2.85	76.63 ±2.28	78.57 ±1.98	79.68 ±1.91	<b>79.96</b> <b>2.12</b>	78.37 ±2.83
AA(%)	74.97 ±0.99	77.47 ±2.62	75.48 ±2.82	75.87 ±3.01	79.30 ±2.10	81.56 ±1.55	82.55 ±1.44	<b>82.86</b> <b>1.75</b>	81.36 ±2.50
Kappa(%)	68.08 ±1.33	72.16 ±3.16	70.05 ±3.89	72.72 ±3.08	74.75 ±2.47	76.86 ±2.12	78.08 ±2.04	<b>78.38</b> <b>2.28</b>	76.6590 ±3.0328

注:黑色加粗字体表示最优结果。

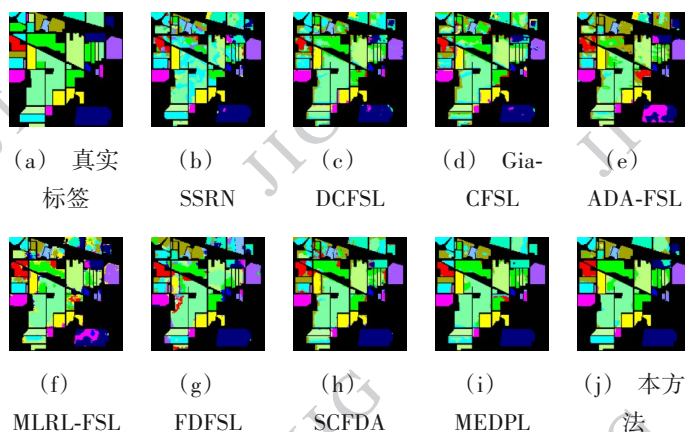


图9 不同分类方法在IP数据集上的分类效果图(OA=85.38%)

Fig. 9 Classification maps on IP dataset(OA=85.38%), including: (a)Ground-truth, (b) SSRN, (c) DCFSL, (d) Gia-CFSL, (e) ADA-FSL, (f) MLRL-FSL, (g) FDFSL, (h) SCFDA, (i) MEDPL and (j)Ours.

上的分类可视化结果。在IP数据集中,场景分类预测图表现出最优性能,在细节保留、类别内部均匀性及边界完整性方面均优于其他方法。

在HT数据集中,内部均匀性、边界完整性和细节保留方面均有显著提升,与真实标注图的吻合度最高。在SA数据集中,显著提升了地物内部同质

性,保持了更清晰的类别边界。LK数据集上,在语义分割结果中与真实标签最为接近,显著优于其他七种对比算法,展现了其在复杂场景下优越的分割精度和细节保持能力。可视化结果进一步表明,DP-CDFSL通过HyperBlend增强与PromptMix语义多样性机制,能够提取更具判别力的特征,从而在高

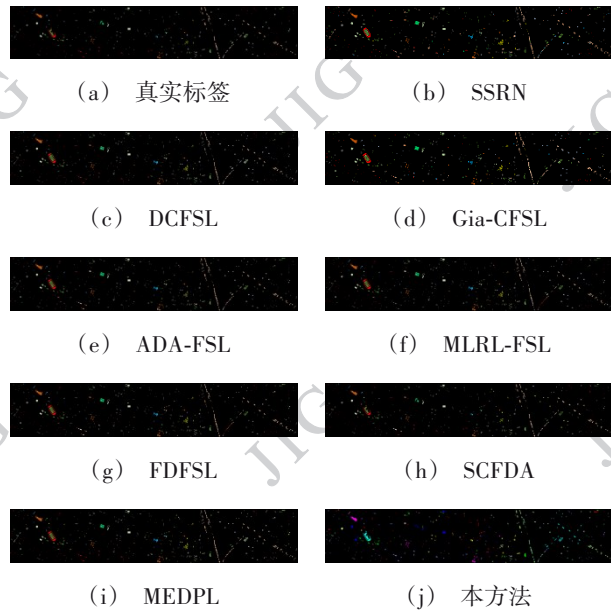


图10 不同分类方法在HT上的分类效果图(OA=78.37%)

Fig. 10 Classification maps on HT dataset(OA=78.37%), including: (a)Ground-truth, (b) SSRN, (c) DCFSL, (d) Gia-CFSL, (e) ADA-FSL, (f) MLRL-FSL, (g) FDFSL, (h) SCFDA, (i) MEDPL and (j)Ours.

光谱小样本分类任务中实现更准确、鲁棒的分类性能。

### 2.3 消融实验

为验证 HyperBlend 数据增强与 PromptMix 机制的有效性,设计了系统的消融实验(表10)。实验以性能具有竞争力的 CDFS-CASCL(Li 等人,2024)方法作为基线模型,逐步引入各组件以分析其贡献。

实验结果表明,在基线模型中引入 HyperBlend 模块后,模型在 IP 与 HT 数据集上分类精度显著提升,OA 分别从 81.72% 提高至 84.88%、从 76.63% 提高至 78.37% 说明能够有效增强模型对复杂与模糊特征的建模能力;而在 SA 和 LK 数据集上性能保持稳定,表明该增强策略未对原有性能产生负面影

响。进一步加入 PromptMix 机制构建完整 DP-CDFSL 模型后,所有数据集的性能均达到最优,IP 与 HT 的 OA 进一步提升至 85.38% 和 79.36%。

消融实验证明,HyperBlend 模块显著提升了模型对困难样本的特征利用与判别能力,PromptMix 机制通过在特征层面实施受语义约束的混合,有效增强了特征空间的多样性,并促进了模型对不同域间共享语义结构的挖掘与对齐。二者共同构成 DP-CDFSL 在跨域小样本高光谱分类任务中取得显著性能提升的关键基础。

### 2.4 可视化分析

图13展示了IP、HT、SA及LK数据集经所提方法学习特征后的t分布随机邻域嵌入(t-distributed stochastic neighbor embedding, t-SNE)二维可视化结果。

从图中可见,不同类别样本在低维空间中呈现出相对清晰的聚集分布,多数类别的边界较为分明,表明所学特征具有良好的类间判别力。尽管存在个别类别分布较广或局部重叠的情况,但整体聚类结构明显,不同数据集均呈现出较好的类别内聚性与类间分离性。该可视化结果有效验证了本文特征学习方法能够保留高维光谱-空间数据的关键判别结构,实现更具区分性的特征表示。

### 2.5 参数敏感性分析

为探究所提方法中关键超参数的敏感性,我们在 IP 数据集上对损失函数权重进行了调优实验,结果如表11所示。

实验发现,两项损失权重的最优取值均为 2.5。其中,当校准损失  $L_{ca}$  的权重  $\lambda_1$  设为 2.5 时,模型整体准确率达到 85.13%;而将对比损失  $L_{sc}$  的权重  $\lambda_2$  调整为 2.5 时,OA 进一步提升至 85.38%,为最优性能。在该数据集与任务设定下,为上述两项损失赋予相对较高的权重(即 2.5)能更有效地引导模型优

表10 DP-CDFSL 关键组成部分的消融实验结果

Table 10 Ablation study of key components of DP-CDFSL

模块		数据集			
HyperBlend	PromptMix	IP(%)	HT(%)	LK(%)	SA(%)
		81.72	76.63	96.27	93.13
✓		84.88	78.37	96.30	93.63
✓	✓	<b>85.38</b>	<b>79.36</b>	96.20	<b>94.33</b>

注:黑色加粗字体表示最优结果。




图 11 不同分类方法在 SA 上的分类效果图(OA=94.33%)

Fig. 11 Classification maps on SA dataset(OA=94.33%), including: (a)Ground-truth, (b) SSRN, (c) DCFSL, (d) Gia-CFSL, (e) ADA-FSL, (f) MLRL-FSL, (g) FDFSL, (h) SCFDA, (i) MEDPL and (j)Ours.




图 12 不同分类方法在 LK 上的分类效果图(OA=96.20%)

Fig. 12 Classification maps on LK dataset(OA=96.20%), including: (a)Ground-truth, (b) SSRN, (c) DCFSL, (d) Gia-CFSL, (e) ADA-FSL, (f) MLRL-FSL, (g) FDFSL, (h) SCFDA, (i) MEDPL and (j)Ours.

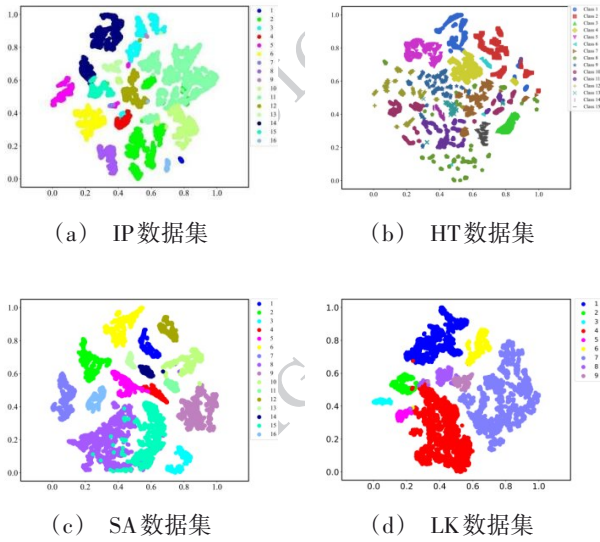


图13 在四个数据集上的二维特征可视化

Fig. 13 The two-dimensional feature visualization on four data-sets, including: (a) IP data set, (b) HT data set, (c) SA data set, and (d) LK data set.

化,且对比损失权重的调整对最终性能的提升贡献更为显著。

基于表12的综合分析表明,DP-CDFSL方法在计算效率与模型复杂度之间取得了极具竞争力的平

表12 每种数据集使用7种方法训练时间、测试时间和参数

数据集	指标	DCFSL	ADA-FSL	MLRL-FSL	FDFSL	MEDPL	DP-CDFSL
IP	训练时间(s)	1939.09	2501.45	3633.43	2453.21	1861.30	4220.49
	测试时间(s)	3.28	6.53	1.73	5.79	0.64	1.26
	参数(M)	4.28	3.21	6.07	5.28	0.19	0.31
HT	训练时间(s)	1382.88	3120.12	3636.96	3136.15	1326.05	3916.85
	测试时间(s)	3.13	21.25	8.97	26.78	2.43	1.49
	参数(M)	4.27	3.21	6.08	5.28	0.19	0.30
SA	训练时间(s)	2053.16	2980	2843.12	2857	1596.84	4286.63
	测试时间(s)	12.64	19.23	5.50	15.43	2.77	6.72
	参数(M)	4.28	3.21	6.04	5.28	0.18	0.31
LK	训练时间(s)	685.89	2563.4	2438.25	1832.52	1450.98	1340.59
	测试时间(s)	63.82	5.17	3.65	4.32	0.74	11.31
	参数(M)	4.28	3.21	6.08	5.28	0.19	0.30

然而,在推理阶段,DP-CDFSL展现出优异的测试效率,在IP和HT数据集上的测试时间仅次于最

表11 IP数据集参数优化

数据	$L_{ca}$ 权重 $\lambda_1$				
	0.5	1	1.5	2	2.5
OA (%)	85.11	84.99	85.25	85.22	85.13
数据	$L_{sel}$ 权重 $\lambda_2$				
	0.5	1	1.5	2	2.5
OA (%)	84.51	84.85	85.04	85.22	85.38

注:黑色加粗字体表示最优结果。

衡。具体而言,在训练阶段,该方法在IP、HT、SA三个数据集上均表现出最高的训练耗时,这与其双路径架构和复杂的跨域对齐机制直接相关,反映了为学习强判别性、域不变特征所必需的计算代价。然而,在推理阶段,DP-CDFSL展现出优异的测试效率,在IP和HT数据集上的测试时间仅次于最优的MEDPL方法,且显著优于多个参数量更大的对比模型,验证了其模型决策过程的高效性。同时,该方法在保持较强表征能力的前提下,将模型参数量控制在极低水平,在所有对比方法中仅高于MEDPL。

优的MEDPL方法,且显著优于多个参数量更大的对比模型,验证了其模型决策过程的高效性。同时,该

方法在保持较强表征能力的前提下,将模型参数量控制在极低水平,在所有对比方法中仅高于MEDPL。这种“高训练开销、低推理延迟、小模型体积”的特点,很好地契合了实际应用中对于一次性离线充分训练、低延迟在线推断以及轻量化部署的严格要求,体现了以离线计算资源换取在线性能优势的设计理念,在高光谱图像小样本分类任务中具有明显的实用价值。

### 3 结论

提出的多样性提示引导的跨域小样本高光谱图像分类方法(DP-CDFSL)从数据与语义两个层面协同增强模型泛化能力:在数据层面设计HyperBlend模块,通过对同类样本进行裁剪、拼接与随机掩码,生成语义一致且外观多样的训练样本;在语义层面提出PromptMix机制,利用预训练语言模型生成多样化文本提示,并引入多样性正则化损失以丰富类别语义原型。模型基于原型学习框架,融合分类损失、跨模态对齐损失、监督对比损失与多样性正则化损失进行端到端训练。

在IP、HT、SA与LK四个高光谱数据集上的实验表明,DP-CDFSL在整体分类精度(OA)、平均精度(AA)和Kappa系数(KC)上均优于当前主流方法,尤其在目标域样本稀缺条件下表现出显著优势,为高光谱图像小样本分类提供了有效解决方案。但也具有一定的局限性,方法假设源域和目标域存在共享的类别空间。如果地物类别完全不一致(即开放集或开集问题),则当前方法需要扩展,未来需要结合未知类别检测机制。未来工作将研究自适应提示生成与更高效的跨模态对齐策略,进一步提升模型在极端少样本场景下的适用性,推动其在遥感智能解译中的实际应用。

### 参考文献(References)

- Arshad T, Zhang J, Ullah I. 2024. A hybrid convolution transformer for hyperspectral image classification [J]. *European Journal of Remote Sensing*, 57(1) [DOI: 10.1080/22797254.2024.2330979]
- Liu Y, Hao A, Liu Y, et al. 2024. Review of Hyperspectral Image Classification Based on Deep Learning [J]. *International Journal of Pattern Recognition and Artificial Intelligence*, 38(14) [DOI: 10.1142/S021800142432001X]

- Li Z, Zhang C, Wang Y, et al. 2024. Cross-domain few-shot hyperspectral image classification with cross-modal alignment and supervised contrastive learning [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 1-19 [DOI: 10.1109/TGRS.2024.3407201]
- Li Z, Liu M, Chen Y, et al. 2021. Deep Cross-Domain Few-Shot Learning for Hyperspectral Image Classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 18 [DOI: 10.1109/TGRS.2021.3057066]
- Liu C, Yang L, Li Z, et al. 2024. Multi-level relation learning for cross-domain few-shot hyperspectral image classification [J]. *Applied Intelligence*, 54(5): 4392-4410 [DOI: 10.1007/s10489024053843]
- Liu, H, He, J, Zhang, X, & Li, Z. 2025. Momentum-Enhanced Dual-Prototype Learning Framework for Robust Few-Shot Hyperspectral Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 63, 1-16 [DOI: 10.1109/TGRS.2025.3638757]
- Ma S, He J, Gao Y, et al. 2025. Spectral context-aware frequency alignment for few-shot hyperspectral image classification [J]. *Knowledge-Based Systems*, 332 114908-114908. [DOI: 10.1016/J.KNOSYS.2025.114908]
- Ma Xiaorui, Ha Lin, Shen Dunbin, Mei Liang, Wang Hongyu. 2024. Cross-dataset hyperspectral image classification based on fusion feature optimization. *Journal of Image and Graphics*, 29(08):2175-2187 (马晓瑞,哈林,谌敦斌,梅亮,王洪玉.2024.融合特征优化的跨数据集高光谱图像分类. *中国图象图形学报*, 29(08):2175-2187) [DOI: 10.11834/jig.230503]
- Nguyen M T, Bui A K, Yoo M. 2026. SSUFormer: Spatial - spectral UnetFormer for improving hyperspectral image classification [J]. *Journal of Visual Communication and Image Representation*, 114104633-104633 [DOI: 10.1016/J.JVCIR.2025.104633]
- Nirala K R, Kumar G, Singh R, et al. 2025. 3DSPECSN: Adaptive 3D spatial patch based siamese network for robust hyperspectral image analysis [J]. *Computers and Electrical Engineering*, 126110520-110520 [DOI: 10.1016/J.COMPELECENG.2025.110520]
- Qin B, Feng S, Zhao C, et al. 2024. Cross-domain few-shot learning based on feature disentanglement for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 1-15 [DOI: 10.1109/TGRS.2024.3386256]
- SHI Yanxin, HE Jinrong, LI Zhaokui, ZENG Zhigao. 2021. Hyperspectral image classification model using 3D convolutional autoencoder. *Journal of Image and Graphics*, 26(8), 2021-2036 (石延新,何进荣,李照奎,曾志高. 2021. 3D卷积自编码器高光谱图像分类模型. *中国图象图形学报*, 26(08), 2021-2036) [DOI: 10.11834/jig.210146]
- Siyuan H, Rui L, Min Z, et al. Multi-layer feature fusion for hyperspectral image classification [J]. *International Journal of Remote Sensing*, 2023, 44(20): 6442-6467. [DOI: 10.1080/01431161.2023.2270109]
- Shi Cheng, Liu Ying, Zhao Minghua, Miao Qiguang, Chi-Man Pun. © 中国图象图形学报版权所有

2024. Contrastive semi-supervised adversarial training method for hyperspectral image classification networks. *Journal of Image and Graphics*, 29(07):1861-1874 (石程,刘莹,赵明华,苗启广,潘治文.2024.面向高光谱图像分类网络的对比半监督对抗训练方法.中国图象图形学报,29(07):1861-1874)[DOI: 10.11834/jig.230462]
- Stephen K. 2013. The Closed Nature of the "Open-Access" SSRN [J]. *International Journal of Legal Information*, 41 (3) : 326-334 [DOI: 10.1017/s0731126500011926]
- Tian Y, Wang Z. 2025. A spectral-preserving resampling for spatial upscaling of hyperspectral imagery[J]. *Science of Remote Sensing*, 12100330-100330 [DOI: 10.1016/J.SRS.2025.100330]
- Wen X, Yu X, Wang Y, et al. 2023. A Hybrid 3D - 2D Feature Hierarchy CNN with Focal Loss for Hyperspectral Image Classification[J]. *Remote Sensing*, 15(18) [DOI: 10.3390/RS15184439]
- Xu Yuanyuan, Kan Meina, Shan Shiguang, Chen Xilin. 2025. Dual-modality domain-agnostic prompts guided cross-domain image classification. *Journal of Image and Graphics*, 30(02) : 0503-0517 (许媛媛, 阚美娜, 山世光, 陈熙霖.2025.双模态域无关提示引导的图像分类域适应.中国图象图形学报, 30(02) : 0503-0517) [DOI: 10.11834/jig.240119]
- Xi B, Zhang W, Li J, et al. 2025. HyperCASR: Spectral-spatial Open-Set Recognition With Category-Aware Semantic Reconstruction for Hyperspectral Imagery[J]. *IEEE transactions on image processing: a publication of the IEEE Signal Processing Society*, PP [DOI: 10.1109/TIP.2025.3630327]
- Yang Lixia, Bao Yajun, Zhang Rui, Yang Shuyuan. 2026. Lightweight Res-3D-CNN with Transformer embedding for cross-domain hyperspectral image classification. *Journal of Image and Graphics*, 31 (3) : 0927-0943 (杨丽霞, 鲍雅君, 张瑞, 杨淑媛.2026.面向跨域高光谱图像分类的嵌入Transformer层的轻量型Res-3D-CNN.中国图象图形学报, 31 (3) : 0927-0943) [DOI: 10.11834/jig.250020]
- Ye Z, Wang J, Liu H, et al. 2023. Adaptive domain-adversarial few-shot learning for cross-domain hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 1-17. [DOI: 10.1109/TGRS.2023.3334289]
- Zilong Z, Jonathan L, Zhiming L, et al. 2018. Spectral - Spatial Residual Network for Hyperspectral Image Classification: A 3-D Deep Learning Framework [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 56 (2) : 847-858 [DOI: 10.1109/tgrs.2017.2755542]
- Zhang Yanbin, Du Jianmin, Bi Yuge, et al. 2013. Research on the Extraction Method of Desert Steppe Coverage Based on UAV Hyperspectral Remote Sensing [J]. *Journal of Optoelectronics Laser*, 34 (08) : 842-850 (张燕斌, 杜健民, 毕玉革等. 2023. 基于无人机高光谱遥感的荒漠草原覆盖度提取方法研究[J]. 光电子·激光, 34 (08) : 842-850)[DOI: 10.16136/j.joe.2023.08.0539.]
- Zhang Y, Li W, Zhang M, et al. 2022. Graph information aggregation cross domain few-shot learning for hyperspectral image classification [J]. *IEEE Transactions on Neural Networks and Learning Systems* [DOI: 10.1109/TNNLS.2022.3185795]
- Zhao R. 2024. Research on classification methods of hyperspectral remote sensing images with small samples. MA thesis. (赵茹. 2024. 小样本高光谱遥感图像分类方法研究[D]. 齐鲁工业大学)[DOI: 10.27278/d.enki.gsdqc.2024.001059]
- Zhang J. 2024. L. Research on hyperspectral remote sensing image classification methods based on deep learning. MA thesis, 2024 (张锦丽. 2024. 基于深度学习的高光谱遥感图像分类方法研究[D]. 桂林电子科技大学)[DOI: 10.27049/d.enki.gglde.2024.000404]
- Zhang Yuxiang, Li Wei, Zhang Mengmeng, et al. 2025. Cross-scene Classification of Hyperspectral Images Based on Few-shot Learning with Local Representation [J]. *Acta Electronica Sinica*, 53(01) : 248-258 (张宇翔, 李伟, 张蒙蒙等. 基于局部表征少样本学习的高光谱图像跨场景分类[J]. 电子学报, 53 (01) : 248-258 [10.12263/DZXB.20230937])

### 作者简介

何梦瑶,女,硕士研究生,主要研究方向为计算机视觉,小样本学习,高光谱图像分类等。E-mail:hemengyao@yau.edu.cn  
何进荣,通信作者,男,教授,主要研究方向为计算机视觉,小样本学习,高光谱图像分类等。E-mail:hejinrong@yau.edu.cn  
刘寒池,男,硕士研究生,主要研究方向为计算机视觉,小样本学习,高光谱图像分类等。E-mail:liuhanchi@yau.edu.cn