

基于局部表征少样本学习的高光谱图像跨场景分类

张宇翔, 李 伟*, 张蒙蒙, 陶 然

(北京理工大学信息与电子学院, 北京 100081)

摘要: 在跨场景分类任务中, 大多数领域自适应方法(Domain Adaptation, DA)关注于源域数据和目标域数据由相同传感器获得且具有相同地物类别的迁移任务, 然而当目标数据中存在新类别时自适应性能会显著下降. 此外, 大多数高光谱图像分类方法采用全局表征机制, 即针对固定大小窗口的样本进行表征学习, 其地物类别表征能力有限. 本文提出了一种基于局部表征的少样本学习框架(Local representation Few Shot Learning, LrFSL), 尝试在少样本学习中构建局部表征机制突破全局表征能力上限. 在提出框架中, 对所有具有标签的源域数据和少量具有标签的目标域数据构建元任务, 依照元学习策略同步进行情景训练, 与此同时设计了域内局部表征模块(Intra-domain Local Representation block, ILR-block)用于挖掘样本中多个局部表征的语义信息, 设计了域间局部对齐模块(Inter-domain Local Alignment block, ILA-block)进行跨域逐类别分布对齐以缓解领域偏移对少样本学习的影响. 在三个公开高光谱图像数据集上的实验结果证明了该方法显著优于目前最先进的方法.

关键词: 高光谱图像; 跨场景; 少样本学习; 局部表征; 领域自适应

基金项目: 多光谱信息智能处理技术全国重点实验室资助项目(No.6142113220205); 北京理工大学研究生科研水平和创新能力提升专项计划(No.2023YCXZ008)

中图分类号: TP75; TP79

文献标识码: A

文章编号: 0372-2112(2025)01-0248-11

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20230937

Local Representation Few-Shot Learning for Hyperspectral Image Cross-Scene Classification

ZHANG Yu-xiang, LI Wei*, ZHANG Meng-meng, TAO Ran

(School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China)

Abstract: In cross-scene classification tasks, most domain adaptation (DA) methods typically focus on transfer tasks where the source domain data and the target domain data are obtained using the same sensor and share the same land cover class. However, the adaptive performance is significantly reduced when new classes are present in the target data. Moreover, many hyperspectral image (HSI) classification methods rely on a global representation mechanism, where representation learning is performed on samples with fixed-size windows, limiting their ability to effectively represent ground object classes. A framework called local representation few-shot learning (LrFSL) is proposed, which aims to overcome the limitations of global representation ability by constructing a local representation mechanism in few-shot learning. In this proposed framework, meta-tasks are created for all labeled source domain data and a few labeled target domain data, and scenario training is performed simultaneously using a meta-learning strategy. Additionally, an Intra-domain local representation block (ILR-block) is designed to extract semantic information from multiple local representations within each sample. Furthermore, the inter-domain local alignment block (ILA-block) is designed to align cross-domain class-wise distribution, thereby mitigating the impact of domain shift on few-shot learning. Experimental results on three publicly available HSI datasets demonstrate that the proposed method outperforms state-of-the-art methods by a significant margin.

Key words: hyperspectral image; cross-scene; few-shot learning; local representation; domain adaptation

Foundation Item(s): National Key Laboratory of Multispectral Information Intelligent Processing Technology under Grant (No.6142113220205); BIT Research and Innovation Promoting Project (No.2023YCXZ008)

1 引言

在实际遥感应用中,经常遇到训练集和测试集源自不同分布的场景,该问题被称为跨场景分类任务,其中训练样本和测试样本分别是已有充足标签的源域数据(Source Domain, SD)和有少量甚至没有标签的目标域数据(Target Domain, TD)^[1-3]. 该任务目的在于学习SD和TD的共享知识,并使用SD训练的模型迁移至TD. 高光谱图像在获取的过程中不可避免地受到各种因素的影响,比如传感器非线性的不同,同一地物类别在不同尺度,不同季节和天气条件下物质组成不同,这都会导致SD和TD中的同一地物在光谱反射率上存在差异^[4-6]. 因此,在直接利用源场景进行训练,对目标场景进行分类时,常常会遇到领域偏移问题.

领域自适应(Domain Adaptation, DA)作为迁移学习的一种方法能减少特征级的领域偏移并学习域不变模型,使得在源域上训练的模型适应到目标域. 目前,大多数DA框架的目标是将从SD学习到的同一类别的知识迁移到TD^[7-12]. 然而,当TD中存在新类别时自适应性能会显著下降. 近几年,少样本学习(Few-Shot Learning, FSL)由于其使用少量的训练样本识别全新类别的有效性,受到了广泛关注^[13-17]. FSL作为有监督的元学习方法采取情景训练的方式. 这种训练方法创建了模拟少样本学习的训练和测试场景的情节. 在训练阶段将数据集分解为不同的元任务去获取元知识,并学习模型对全新的类的少样本情景的泛化能力. 在测试阶段,面对全新的类别,不需要变动已有的模型,就可以完成分类. 元任务由支撑集和查询集构成,支撑集包含 C 类,每个类中有 K 样本,该任务称为 C -way K -shot^[18]. 查询集中样本的类别与同一个元任务中支撑集类别相同. 最近,FSL被用于高光谱图像分类中以缓解制作较大的训练集时耗时耗力问题^[19-21]. Liu等人^[22]提出了深度少样本学习(Deep FSL, DFSL)来对标签数据较少的高光谱图像进行分类,利用深度残差三维卷积网络提取空间光谱特征,学习度量空间,使用最近邻分类器对测试样本进行分类. 基于关系网络的少样本分类(Relation Network Few-Shot Classification, RN-FSC)采用微调的思想,选取少量TD样本作为微调数据集对SD训练模型进行微调,并利用TD剩余数据作为测试数据进行验证^[23].

目前大多数基于DA的高光谱图像跨域分类方法关注于相同传感器且类别相同的跨域情况^[24-27]. 未考虑到实际应用中更广泛的情况,即域间存在空间和谱间的分辨率差异(传感器不同),以及地物类别差异. 此外,目前的高光谱图像分类工作都是使用固定大小窗口的样本基于全局表征的方式去刻画地物类别的语义信息. 然而,全局表征机制缺乏关注局部表征的语义信

息,其表征能力有限. 因此,需要考虑利用样本内局部空-谱信息表征域内地物类别特性,进一步设计有效的局部表征少样本学习策略提高各个类内元知识的判别性.

为了解决以上问题,在文中提出了一种基于局部表征少样本学习的框架(Local representation Few Sample Learning, LrFSL). 首先,对SD和TD分别执行元学习情景训练策略,即构建SD和TD的元任务,分别经过映射层将SD和TD的特征映射至相同维度,在提取各自的空谱嵌入深度特征图后,对特征图进行划分获取局部嵌入特征. 进一步,结合有监督对比策略构建局部表征机制,设计域内局部表征模块(Intra-domain Local Representation block, ILR-block)用于源域和目标域各自的元任务训练,使用对比策略学习支撑集和查询集之间的局部相似性. 最后,设计了域间局部对齐模块(Inter-domain Local Alignment block, ILA-block),利用源域和目标域少量标记样本进行逐类别分布对齐.

本工作的主要贡献总结如下:(1)为了解决跨场景分类中多要素差异导致的域偏移问题,即域之间存在空谱结构差异以及类内差异的情况,提出了一种基于局部表征少样本学习策略;(2)构建局部表征机制,其仅使用样本局部信息也能够准确预测对应类别,突破了传统模型学习对应类别表征的能力上限,并且结合有监督对比策略进一步提升了关系子空间中特征的可分性;(3)为缓解现有少样本方法在源域和目标域存在域偏移时性能下降的问题,进一步设计局部最大均值差异损失,在元任务训练过程中将源域中的共享知识逐类别地转移到目标域中,实现了模型到不同场景的迁移.

2 局部表征少样本学习框架

本文提出的LrFSL框架流程图如图1所示,包括特征提取模块,域内局部表征模块(ILR-block)和域间局部对齐模块(ILA-block)三部分. 特征提取包括源域和目标域的映射层和权值共享的嵌入特征提取器,其中映射层将源域和目标域的原始特征映射到同一维度. 在域内局部表征模块中利用局部表征机制度量类原型与查询样本间的局部相似性,分别学习域内每个元任务中支撑样本和查询样本之间的潜在关系. 域间对齐模块通过局部最大均值差异减少领域偏移.

假设 $\mathbf{X}_s \in \mathbb{R}^{d_s}$ 和 $\mathbf{X}_t \in \mathbb{R}^{d_t}$ 分别是源域和目标域的数据,其中 d_s 和 d_t 表示维度, C_s 和 C_t 表示类别个数. 两个跨域少样本学习任务:源域少样本学习任务 T_s 和目标域少样本学习任务 T_t . 源域少样本学习任务中的所有数据都具有标签,将目标域少样本任务分解为带有少量标签的目标域训练数据 T_t^c 和无标签的目标域测试数据 T_t^{tc} .

一般情况下 $C_s > C_t$, 以保证训练样本的多样性. T_s 和 T_t^r 分别用于源域和目标域的少样本学习情景训练.

2.1 特征提取

由于源域和目标域传感器的不同导致样本光谱分辨率不一致. 因此, 首先构建空间卷积一致和谐间投影一致的映射模块进行维度转换, 接着使用深度残差三维卷积网络 (3D Convolutional Neural Network, 3DCNN) 提取空间光谱嵌入特征, 如图 1 所示. 其中, 源域和目标域对应的两个映射层均采用二维卷积网络实现, 记

作 $M_s(\cdot)$ 和 $M_t(\cdot)$, 其卷积核大小为 9×9 , 输入维度是源域和目标域原始光谱维度, 输出光谱维度 d_{map} 设置为 100. 深度残差 3DCNN 网络结构如图 2 所示, 记为 $f_{emb}(\cdot)$, 由两个 3D 残差块 (三个 3D 卷积层和一个直连层), 两个最大池化层和一个 3D 卷积层组成. 卷积核大小为 $3 \times 3 \times 3$, $f_{emb}(\cdot)$ 的输出维数为嵌入特征维数, 表示为 d_{emb} (所有实验中设置为 128). 源域和目标域的样本经过特征提取获得空谱嵌入深度特征图, 分别记作 Z_s 和 Z_t , 其空间大小记为 $W \times H$.

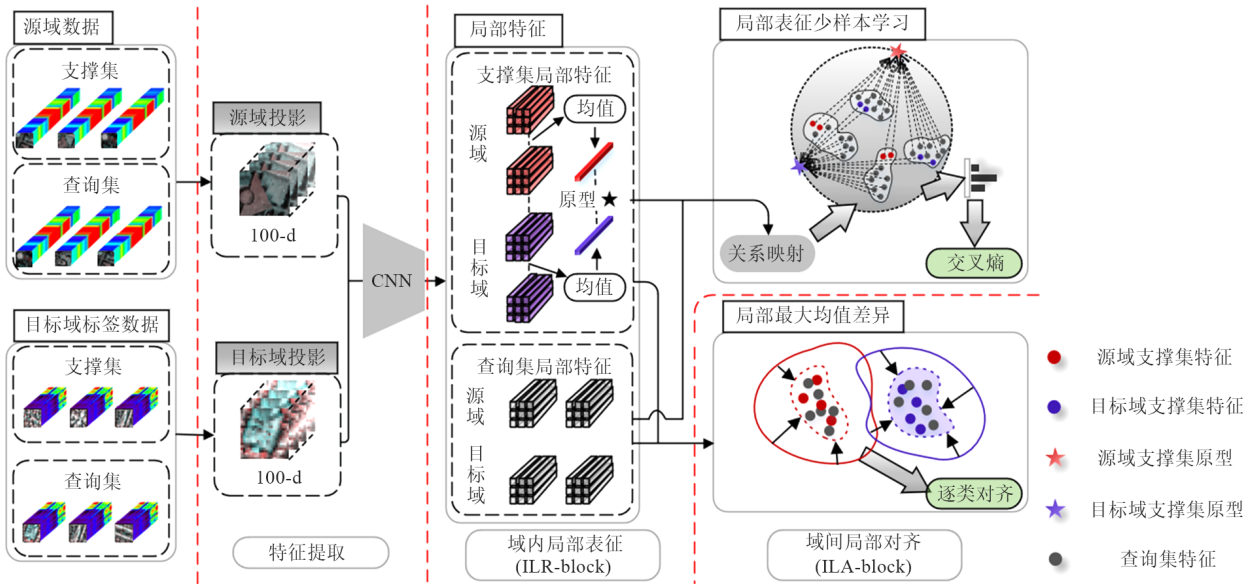


图 1 LrFSL 框架图, 包括特征提取、域内局部表征和域间局部对齐

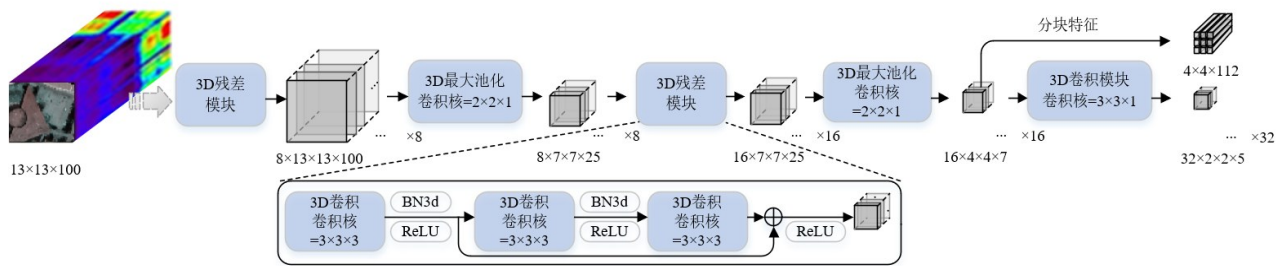


图 2 深度残差 3DCNN 网络结构图

2.2 域内局部表征(ILR-block)

传统高光谱图像分类方法采用全局表征的方式, 刻画样本对应地物类别的语义信息. 在模型遇到表征瓶颈时从未考虑使用样本内局部空-谱信息挖掘地物类别特性, 突破全局表征能力上限. 为此, 我们构建局部表征机制, 即在只给出一个样本内局部空-谱信息时, 也能够准确预测对应地物类别. 全局表征和局部表征示意图如图 3 所示.

结合有监督对比策略构建域内局部表征模块 (ILR-block), 并实现基于局部表征的少样本学习, 如图 1 所



图 3 全局和局部表征机制

示. 首先, 对空谱嵌入深度特征 Z_s 和 Z_t 进行空间局部特征划分, 进行元任务情景训练, 利用有监督对比学习策略度量样本间相似度并进行分类. 在每次迭代中, 源域和目标域同时执行情景训练. 以源域为例, 将嵌入特

征 Z_s 拆解成多个局部嵌入特征 z_s^{wh} , 并划分支撑集 S_s 和查询集 Q_s , 其中支撑集作为有标签的训练集. 在每次迭代过程中, 通过关系映射模块将查询集嵌入特征和每个类原型(即支撑集嵌入特征的平均值)映射至关系子空间, 度量它们之间的相似度进行少样本学习, 并驱使对比损失最小化. 关系映射模块具体结构如图 4 所示, 由 2D 卷积-2D 批归一化-激活函数-全连接层串联组成, 其中卷积核大小为 1×1 , 全连接层的输入维度设定为 512, 输出维度设定为 256. 在获取关系子空间特征 r_s^{wh} 后, 利用监督对比损失度量查询集局部关系特征与支撑集类原型关系特征之间的相似度:

$$L_{\text{block}}^s = - \sum_{i=0}^N \frac{1}{|P(i)|} \sum_{p \in P(i)} \log \frac{\exp(r_i^T r_p^+ / \tau)}{\sum_{a \in A(i)} \exp(r_i^T r_a^- / \tau)} \quad (1)$$

其中, 对于小批量中的每个支撑集类原型关系特征 r_i , $P(i)$ 是其正样本集合, $|P(i)|$ 是正样本个数, r_p 是其中正样本, 由类内查询集局部关系特征构成, $A(i)$ 是负样本集合, r_a 是其中负样本, 为类外查询集局部关系特征. 在局部表征少样本学习中, 将关系空间中属于同类的关系特征放入正样本集合, 不同类的特征放入负样本集合. 通过有监督对比学习优化模型, 促进属于同类的样本更接近, 不同类的样本更远, 使得模型从同类样本中学习逐类别的跨域共享表示. 通过局部表征机制充分挖掘样本内鲁棒表征, 提高各个类内元知识判别性. 目标域的局部表征少样本学习与源域类似, 但需要注意的是 L_{block}^t 是在对 T_t^r 进行数据增强后构造元任务计算得到的.




图 4 关系映射模块结构图

2.3 域间局部对齐(ILA-block)

考虑到少样本学习情景训练过程中领域漂移对分类性能的影响, 在 LrFSL 框架中设计了域间局部对齐模块(ILA-block)缓解条件分布差异, 如图 1 所示. 该模块输入源域和目标域中所有局部嵌入特征 z_s^{wh} 和 z_t^{wh} , 将其投影到希尔伯特空间, 利用可用的标签逐类别计算局部最大均值差异损失:

$$L_{\text{Immd}} = \sum_{c=1}^C \left\| \frac{1}{n_s} \sum_{i=1}^{n_s^c} \phi(z_s^i) - \frac{1}{n_t} \sum_{j=1}^{n_t^c} \phi(z_t^j) \right\|_H^2 \quad (2)$$

其中, n_s^c 表示第 c 类源域局部嵌入特征数量, n_t^c 表示第 c 类目标域局部嵌入特征数量, 计算再现核希尔伯特空

间中源域与目标域逐类别的平均差值, 该损失越小, 两个域条件分布差异越小, 以此缓解高光谱数据的源域及目标域特征的条件分布差异性.

LrFSL 框架的总体损失函数定义如下:

$$L_{\text{total}} = L_{\text{block}} + L_{\text{Immd}} \quad (3)$$


通过计算总体损失函数回传梯度更新模型权重. 在对目标域测试阶段, 将 T_t^r 作为支撑集, T_t^t 作为查询集, 通过嵌入特征提取器获取目标域支撑集原型特征和查询集局部特征, 并使用最近邻分类器进行标签预测.

3 实验结果及分析

本节考虑到实际应用中源域和目标域来自不同传感器且包含不同的地物类别, 以 Chikusei 数据集作为源场景, Pavia University、Indian Pines 和 Salinas 三个数据集作为目标场景, 验证提出方法的有效性. 比较算法采用了领域自适应算法和基于少样本学习的算法, 包括 3D 卷积神经网络(3DCNN), 深度子域适应网络(Deep Sub-domain Adaption Network, DSAN)^[8], 动态对抗自适应网络(Dynamic Adversarial Adaption Network, DAAN)^[24], 分布传播图网络(Distribution Propagation Graph Network, DPGN)^[28], 深度少样本学习(Deep Few-Shot Learning, DFSL)^[22], 关系网络少样本分类(RN-FSC)^[23].

3.1 实验数据

源场景: Chikusei 数据集包含 128 个波段, 光谱范围从 363 nm 到 1 018 nm, 图像大小 $2\,517 \times 2\,335$ 像素, 空间分辨率为 2.5 m. 有 19 个类别, 包括城市和农村. 伪颜色图和地面真值图如图 5 所示.



(a) Chikusei 伪彩色图像 (b) Chikusei 地面真值图



图 5 Chikusei 伪彩色图像与地面真值图

3.2 目标场景

(1) Pavia University 数据集. 该数据由德国航空公司利用反射光学系统成像光谱仪(Reflective Optics Spectrographic Imaging System, ROSIS)在意大利 Pavia 大学校园区域采集, 隶属于城市环境数据. 该数据光谱覆盖范围为 430~860 nm, 包括 103 个光谱波段, 图像的大小

为 610×340 像素,空间分辨率为 1.3 m,包含 9 个类别。

(2) Indian Pines 数据集. 该数据使用机载可见/红外成像光谱仪 (Airborne Visible/Infrared Imaging Spectrometer, AVIRIS) 传感器获得. 图像包含农作物和天然植被, 145×145 像素, 光谱的波长范围为 400~2 500 nm, 220 个光谱波段, 空间分辨率为 20 m. 实验中在去除水波带后共使用了 202 个波段. 在原始标签真值中有 16 种不同的土地覆盖类别, 其中大多数代表不同类型的农作物。

(3) Salinas 数据集: 该数据也是由 AVIRIS 传感器收集, 总共 224 个波段覆盖了加利福尼亚州 Salinas 山谷地区. 该数据包含了裸露的土壤, 蔬菜和葡萄园, 512×217 的像素, 空间分辨率为 3.7 m. 地面真值包含 16 个类。

3.3 实验设置

LrFSL 输入设置为 13×13 大小, 采用 Adam 作为优化策略, 学习率设置为 1×10^{-2} , 正则化参数 λ_1 为 1. 嵌入特征提取器的 ℓ_2 -norm 正则化系数默认为 0, 其他模块设置为 1×10^{-4} 用于权值衰减, 训练迭代次数为 10 000 次. 对于情景训练中 G -way K -shot 元任务, SD 和 TD 对应的 G 均设置为 TD 的类别个数, Pavia University 元任务中为 9, Indian Pines 元任务中为 16, Salinas 元任务中为 16. K 表示在每次迭代中随机选取 K 个有标签的样本组成支撑集进行模型训练, 所有实验中 SD 和 TD 的 K 均设为 1. 此外, 查询集中的样本数设置为 19. 需要注意的是, SD 中有 19 个类, 在构建元任务时, 从 SD 中随机抽取 G 个类. 此外, 在所有实验中, 从 TD 的每类中选取 5 个标记样本用于 TD 的情景训练. 但由于 5 个有标签的样本太少, 无法构造 TD 的支撑集 S_i 和查询集 Q_i , 因此采用加入高斯随机噪声的方法进行数据增强。

3.4 评价指标

本文采用总体精度 (Overall Accuracy, OA), 类别精度 (Class-specific Accuracy, CA) 和 Kappa 系数 (Kappa Coefficient, KC) 用于评估分类性能. 以上评价指标均借助混淆矩阵 (Confusion Matrix, CM) 获取, 假设高光谱图像中地物类别数目为 c , 那么混淆矩阵 \mathbf{M} 的大小为 $c \times c$, 表示如下:

$$\mathbf{M} = \begin{bmatrix} m^{11} & m^{12} & \dots & m^{1c} \\ m^{21} & m^{22} & \dots & m^{2c} \\ \vdots & \vdots & \ddots & \vdots \\ m^{c1} & m^{c2} & \dots & m^{cc} \end{bmatrix} \quad (4)$$

其中, \mathbf{M} 中行表示实际各个类别的样本数, 列表示模型预测的各个类别的样本数, 因此, \mathbf{M} 矩阵中 m^{ii} 表示第 i 类样本被预测为 i 类的样本数, m^{ij} 表示第 i 类样本被错误预测为第 j 类的样本数, \mathbf{M} 对角线元素值的加和则为所有正确预测的样本数。

高光谱分类任务中, 总体分类精度是被广泛认可的评价指标, 直接评判分类结果优劣, 总体分类精度定义为所有正确分类的样本与总样本的数目比值, 是对分类模型宏观表现的评估标准. 假设样本的总数目为 N , 总体分类精度公式化如下:

$$OA = \frac{\sum_{i=1}^c m^{ii}}{N} \quad (5)$$

类别分类精度等同于机器学习中的准确率, 其表示不同类别各自的分类精度, 类别分类精度定义为第 i 类正确预测的样本与第 i 类被错误预测为其他类别的样本的数目比值, 公式化如下:

$$CA = \frac{m^{ii}}{\sum_{j=1}^c m^{ij}} \quad (6)$$

总体分类精度虽然能够直接反映整体分类正确的比例, 同时计算非常简单, 但当实际数据中存在样本不平衡情况, 模型对某些类别有“偏向性”时, 该评价标准不能真实地反映模型分类性能, 缺乏各类别分类结果的衡量. Kappa 系数是一种能够惩罚模型“偏向性”的评价指标, 对“偏向性”强的模型即使总体分类精度很高也会打低分, 计算式如下:

$$Kappa = \frac{N \left(\sum_{i=1}^c m^{ii} \right) - \sum_{i=1}^c \left(\sum_{j=1}^c m^{ij} \sum_{j=1}^c m^{ji} \right)}{\left(N^2 - \sum_{i=1}^c \left(\sum_{j=1}^c m^{ij} \sum_{j=1}^c m^{ji} \right) \right)} \quad (7)$$

3.5 消融实验

为探究本文各模块在提出方法中对跨场景分类精度的影响, 在骨干网络为深度残差三维卷积网络前提下, 分别添加域内局部表征模块 (ILR-block) 和域间局部对齐模块 (ILA-block), 进行模型消融实验. 模型消融实验结果如表 1 所示. 很明显, 总体上域内局部表征模块和域间局部对齐模块在 LrFSL 中协同作用使得模型在异质异类迁移任务上的性能获得了显著的改进. 在不使用以上两个模块时, 结合少样本学习的骨干网络在三个数据集上的性能下降 3% 左右. 当在骨干网络中加入域内局部表征模块时, 分类性能提升 2%~3%, 这表明基于局部表征的少样本学习策略相比于传统的全局表征机制, 能够充分挖掘域内样本间的局部相似性, 通过局部空-谱信息表征域内样本, 提升类内元知识判别性. 此外, 引入域间局部对齐模块相比于骨干网络分类性能提升约 1%. 骨干网络在缺少域间对齐策略时, 在目标场景上很难达到预期的性能, 同时少样本学习情景训练过程中领域漂移对分类性能也具有一定的负面影响, 基于局部最大均值差异的域间局部对齐模块能够一定程度缓解源域和目标域间的域间差异问题。

分析域间局部对齐模块中局部特征在不同对齐策略下的分类性能,表2展示了在采用最大均值差异损失(Maximum Mean Difference, MMD)和局部最大均值差异损失(Local Maximum Mean Difference, LMMD)两种对齐策略下的分类精度. 在三个数据集上 LMMD 的表现均优于 MMD,但分类精度仅相差 1% 左右,这表明局部表征机制提取的局部特征在不同对齐策略下均具有性能效益.

为证明提出的局部表征机制相比于全局表征机制在特征表征能力方面的改进,提升模型分类性能,进行了表征机制消融实验,如表3所示. 在采用全局

表征机制时我们去除了域内局部表征模块中的局部特征,直接将全局特征输入关系映射模块和域间局部对齐模块计算有监督对比损失以及局部最大均值差异损失. 从表3中可以看出,在三个数据集上局部表征机制相比于全局表征机制分类精度有 1%~2% 的提升.

特征提取模块参数消融实验如表4所示,包括光谱维度 d_{map} (源域数据和目标域数据投影后的维度),以及特征维数 d_{emb} (深度残差 3DCNN 网络输出的嵌入特征维度),对于三个数据集 d_{map} 和 d_{emb} 的最优值均设置为 100 和 128.

表 1 模型消融实验

单位:%

消融设置		Pavia University		Pavia University		Salinas	
ILR-block	ILA-block	OA	KC	OA	KC	OA	KC
×	×	81.76	76.42	65.03	60.45	87.53	86.12
√	×	83.61	78.35	68.26	64.47	89.63	88.36
×	√	82.45	77.78	66.40	62.06	88.24	87.58
√	√	84.47	79.84	69.38	65.47	90.59	89.55

表 2 特征对齐策略消融实验

单位:%

特征对齐策略	Pavia University		Indian Pines		Salinas	
	OA	KC	OA	KC	OA	KC
MMD	83.75	78.91	68.60	64.88	88.70	87.93
LMMD	84.47	79.84	69.38	65.47	90.59	89.55

表 3 表征机制消融实验

单位:%

表征机制	Pavia University		Indian Pines		Salinas	
	OA	KC	OA	KC	OA	KC
全局表征	82.97	78.03	67.52	63.80	89.11	88.03
局部表征	84.47	79.84	69.38	65.47	90.59	89.55

表 4 特征提取模块参数消融实验

目标域 OA/%	光谱维度 d_{map}			特征维数 d_{emb}			
	50	100	200	32	64	128	256
Pavia University	72.50	84.47	83.17	80.40	82.33	84.47	83.72
Indian Pines	58.01	69.38	67.47	67.09	68.21	69.38	69.13
Salinas	82.81	90.59	89.22	87.95	88.36	90.59	89.94

3.6 实验结果

为了评估 LrFSL 在跨传感器跨地物类别迁移任务上的表现,以下实验中使用 6 种相关算法进行比较,3DCNN、DAAN、DSAN、DPGN、DFSL、RN-FSC. 训练样本设置如下:3DCNN 作为监督方法,需要训练样本和测试样本具有相同维数和相同类别,因此在目标域中每个类别只选择 5 个标记样本作为训练集,其余作为测试集. 对于无监督域自适应方法,加入与 LrFSL 一致的投影层 DAAN 和 DSAN,使用所有带标签的源域数据和不带标签的目标域数据进行训练. 对于基于少样本学习的方法 DPGN、DFSL 和 RN-FSC,训练样本的选择与

LrFSL 相同. 具体来说,DPGN 只使用源域构建元任务进行训练,不使用目标域,DFSL 和 RN-FSC 使用基于图形表示的波段选择在源域和目标域中选择 100 个波段,以保证输入维度的一致性. 此外,分别从 {0.001, 0.01, 0.1, 1, 10, 100} 中选取各个对比方法的最优学习率和正则化参数,并通过交叉验证找到相应的最优参数.

表 5~表 7 列出了上述方法在 3 个目标场景中的 CA、OA 及 KC. 对于所有分类方法,每个类别随机选取 5 个标记样本作为目标域中的监督样本,并展示 10 次实验的平均准确率和标准差.

(1) 与仅使用少量目标域样本进行训练的 3DCNN 相比,利用源域标记样本和设计域对齐块的 DAAN、DSAN、DFSL、RN-FSC 和 LrFSL 分类精度提高了 5%~9%. 这表明当目标域中标记样本较少时,将源域知识转移到目标域中有助于提高模型在目标域上的分类精度.

(2) 基于少样本学习的方法 DFSL、RN-FSC 和

表 5 针对目标场景 Pavia University 数据的不同方法的 CA 和 OA (从 TD 中选取 5 个监督样本)

单位: %

No.	Class	3DCNN	DAAN	DSAN	DPGN	DFSL	RN-FSC	LrFSL
1	Asphalt	51.31	93.38	91.15	84.09	69.05	69.42	81.11±3.35
2	Meadows	70.69	95.10	94.10	62.90	85.45	92.70	87.06±2.24
3	Gravel	36.10	43.26	29.16	0.05	56.83	49.95	61.91±4.56
4	Trees	68.03	92.30	96.90	89.10	89.52	92.09	94.93±1.82
5	Sheets	92.91	99.63	99.63	99.70	99.29	98.45	99.49±0.72
6	Bare soil	43.67	54.32	27.36	56.33	70.50	57.66	76.21±4.93
7	Bitumen	69.74	11.28	58.35	65.94	71.36	69.36	87.00±5.26
8	Bricks	57.52	0.46	54.02	66.54	58.29	64.07	84.89±5.35
9	Shadow	97.77	88.38	94.72	0.00	97.02	98.81	90.51±3.94
OA		62.57	76.54	78.43	64.42	78.23	79.84	84.47±1.41
KC		53.33	68.10	70.58	55.42	70.02	72.41	79.84±1.70

表 6 针对目标场景 Indian Pines 数据的不同方法的 CA 和 OA (从 TD 中选取 5 个监督样本)

单位: %

No.	Class	3DCNN	DAAN	DSAN	DPGN	DFSL	RN-FSC	LrFSL
1	Alfalfa	92.68	39.13	97.83	95.12	97.44	96.65	98.05±3.75
2	Corn-notill	38.44	26.82	28.29	47.15	38.34	45.95	52.00±5.83
3	Corn-nimtill	44.85	90.96	94.70	27.03	43.35	41.25	58.90±2.71
4	Corn	36.64	91.14	97.89	56.47	68.45	59.06	86.55±3.04
5	Grass-pasture	71.13	68.53	90.89	39.75	70.21	65.90	77.01±3.79
6	Grass-tree	72.69	13.29	38.08	61.38	76.38	69.51	86.86±5.68
7	Grass-pasture-mowed	100.00	25.00	96.43	100.00	99.77	99.65	96.96±3.46
8	Hay-windrowed	83.93	59.83	81.59	92.39	75.67	76.91	93.53±2.01
9	Oats	33.33	20.00	100.00	100.00	99.00	100.00	100.00±0.00
10	Soybean-notill	64.84	49.49	52.37	57.91	47.90	26.05	60.71±3.08
11	Soybean-miitill	58.04	45.87	38.17	41.18	57.80	65.36	63.91±2.12
12	Soybean-clean	23.64	91.57	96.12	47.96	38.13	26.31	52.36±3.94
13	Wheat	91.00	15.12	14.63	89.00	98.04	99.28	98.75±1.66
14	Woods	53.97	99.60	98.66	78.65	83.08	75.66	83.83±4.05
15	Buildings-Grass-Trees-Drives	56.96	67.36	57.51	46.72	62.86	69.90	81.21±5.76
16	Stone-Steel-Towers	100.00	96.77	94.62	98.86	99.94	99.88	98.98±1.79
OA		55.93	57.45	60.74	53.68	58.94	57.84	69.38±2.14
KC		50.65	52.66	56.69	48.12	54.22	53.01	65.47±2.35

LrFSL 的性能比 DAAN 和 DSAN 等无监督领域自适应方法提高了 4%~8%, 这是因为少样本学习中构建元任务进行情景训练的学习方法具有更强的泛化能力, 能学习到更完整的源域知识. 这表明采用元学习思想训练

的少样本学习方法可以较好地解决标记样本较少的问题.

(3) 由于 LrFSL 中设计了基于局部表征机制的少样本学习策略, 其性能明显优于只关注全局表征的

DPGN、DFSL 和 RN-FSC. 此外, LrFSL 性能明显优于只关注少样本学习的方法, 在三个目标域数据上 OA 均有约 3%~8% 的提高. 这是源于域间局部对齐模块有效减小了源域和目标域之间的域漂移, 使得在少样本学习的情景训练过程中领域漂移的负面影响有所缓解.

为了进一步直观比较, 图 6~图 8 展示了 3 个目标域的地面真值图, 以及每个类别选择 5 个标记样本对应的

分类图. 与其他方法相比, 本文提出的 LrFSL 在分类图的某些区域获得了更小的噪声和更准确的分类结果, 例如 Pavia University 数据中的第 7 类 (Bitumen) 和第 8 类 (Bricks), Indian Pines 数据中的第 6 类 (Grass-tree) 和第 15 类 (Buildings- Trees-Drives), Salinas 数据中的第 10 类 (Corn senesced green weeds) 和第 15 类 (Vinyard untrained).

表 7 针对目标场景 Salinas 数据的不同方法的 CA 和 OA (从 TD 中选取 5 个监督样本)

单位: %

No.	Class	3DCNN	DAAN	DSAN	DPGN	DFSL	RN-FSC	LrFSL
1	Brocoli green weeds 1	98.95	99.75	92.83	87.72	94.86	96.45	99.34±0.99
2	Brocoli green weeds 2	97.02	96.16	99.49	99.49	98.68	99.15	98.98±1.59
3	Fallow	83.55	50.86	61.13	79.76	93.65	85.85	88.66±2.79
4	Fallow rough plow	92.18	99.71	98.71	98.34	99.39	98.49	99.11±0.78
5	Fallow smooth	83.38	86.56	99.22	80.13	90.60	82.67	93.93±4.36
6	Stubble	89.67	99.92	99.97	99.92	97.64	97.29	97.49±2.82
7	Celery	99.16	96.51	97.29	99.86	99.33	99.39	98.56±1.45
8	Grape untrained	68.15	91.79	89.22	50.84	78.34	71.59	80.51±5.18
9	Soil vinyard develop	98.23	83.15	85.44	89.03	90.19	88.16	98.29±2.47
10	Corn senesced green weeds	33.13	70.99	78.92	81.24	61.84	69.72	84.33±6.27
11	Lettuce romaine 4wk	75.47	46.25	99.34	89.46	96.45	89.29	98.69±1.11
12	Lettuce romaine 5wk	94.29	95.49	71.35	99.17	93.11	94.03	97.91±2.74
13	Lettuce romaine 6wk	98.47	99.34	99.67	99.56	99.50	99.45	98.19±1.99
14	Lettuce romaine 7wk	92.90	98.60	72.52	98.87	97.53	96.58	98.43±1.70
15	Vinyard untrained	62.29	57.18	62.36	59.75	77.46	69.30	80.33±5.39
16	Vinyard vertical trellis	97.45	83.40	74.60	77.69	85.98	81.86	91.51±5.59
OA		80.43	84.06	85.35	78.67	87.67	83.84	90.59±1.36
KC		78.36	82.23	83.66	76.42	86.02	81.75	89.55±1.50

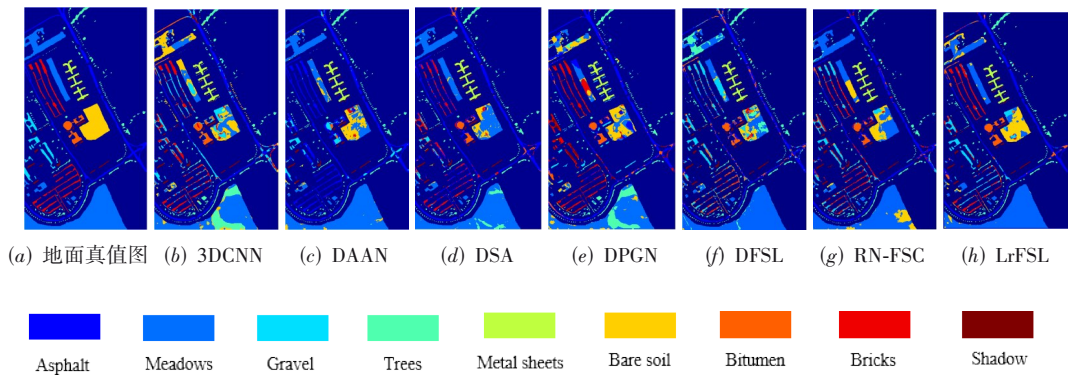


图 6 Pavia University 目标场景分类图

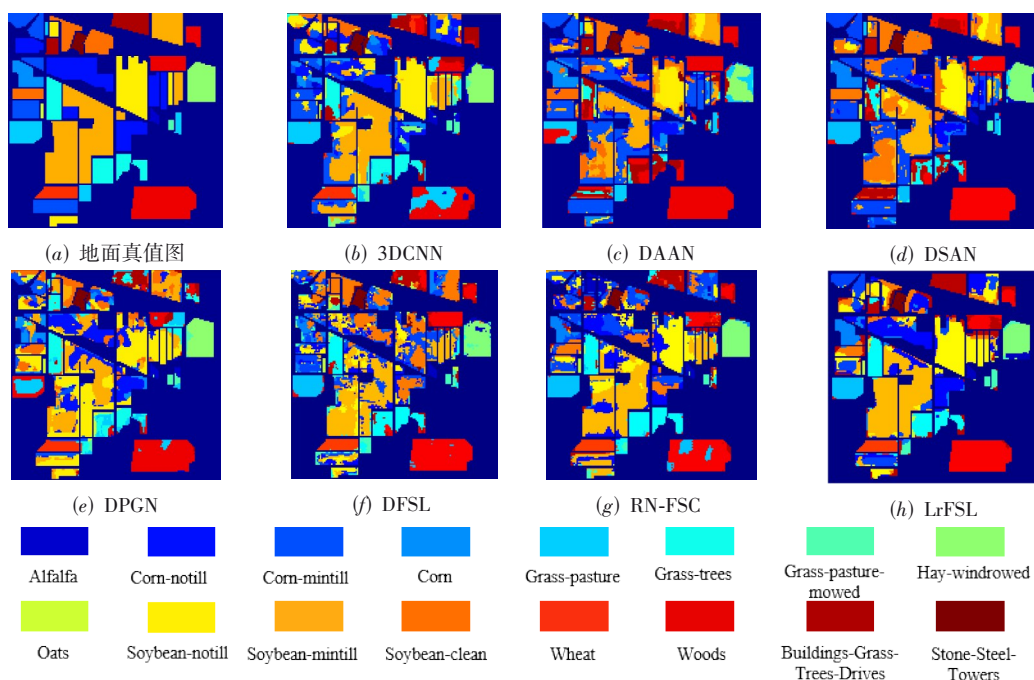


图7 Indian Pines目标场景分类图

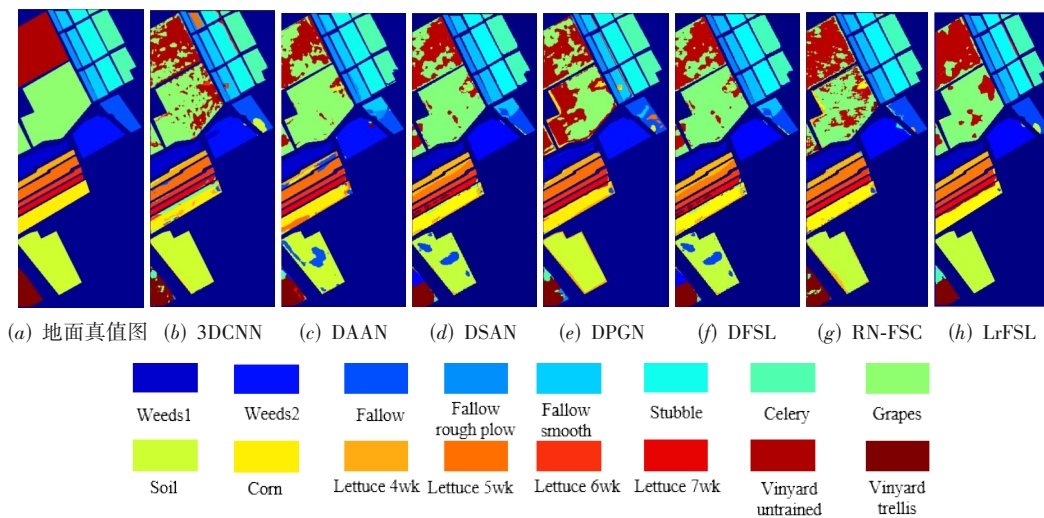


图8 Salinas目标场景分类图

4 结论

本文提出了基于局部表征的少样本学习框架LrFSL,解决了不同传感器的空间分辨率和光谱分辨率的差异以及不同地物类别的差异等问题. LrFSL在源域所有标记样本可用,目标域有少量标记样本的条件下进行跨域少样本学习. 首先,构建局部表征机制,设计域内局部表征模块挖掘样本中多个局部表征的语义信息,突破传统全局表征能力上限. 进一步,考虑到域偏移对于少样本学习潜在的负面影响,设计域间局部对齐模块实现跨域逐类别分布对齐. 在三个数据集上进行了大量的实验,证明所提出方法的性能相比

于最先进的模型,在跨域少样本学习任务中取得了显著提升.

参考文献

- [1] TUIA D, PERSELLO C, BRUZZONE L. Domain adaptation for the classification of remote sensing data: An overview of recent advances[J]. IEEE Geoscience and Remote Sensing Magazine, 2016, 4(2): 41-57.
- [2] ELSHAMLI A, TAYLOR G W, BERG A, et al. Domain adaptation using representation learning for the classification of remote sensing images[J]. IEEE Journal of Selected

- Topics in Applied Earth Observations and Remote Sensing, 2017, 10(9): 4198-4209.
- [3] ZHANG J, LIU J, PAN B, et al. Domain adaptation based on correlation subspace dynamic distribution alignment for remote sensing image scene classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(11): 7920-7930.
- [4] YANG J F, CHEN H L, XU Y C, et al. Domain adaptation for degraded remote scene classification[C]//2020 16th International Conference on Control, Automation, Robotics and Vision (ICARCV). Piscataway: IEEE, 2020: 111-117.
- [5] KWAK G H, PARK N W. Unsupervised domain adaptation with adversarial self-training for crop classification using remote sensing images[J]. Remote Sensing, 2022, 14(18): 4639.
- [6] WANG J J, MA A L, ZHONG Y F, et al. Cross-sensor domain adaptation for high spatial resolution urban land-cover mapping: From airborne to spaceborne imagery[J]. Remote Sensing of Environment, 2022, 277: 113058.
- [7] QU Y, BAGHBADERANI R K, LI W, et al. Physically constrained transfer learning through shared abundance space for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(12): 10455-10472.
- [8] ZHU Y C, ZHUANG F Z, WANG J D, et al. Deep subdomain adaptation network for image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(4): 1713-1722.
- [9] LIU T Z, ZHANG X R, GU Y F. Unsupervised cross-temporal classification of hyperspectral images with multiple geodesic flow kernel learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(12): 9688-9701.
- [10] LUO C, MA L. Manifold regularized distribution adaptation for classification of remote sensing images[J]. IEEE Access, 2018, 6: 4697-4708.
- [11] SUN H, LIU S, ZHOU S L, et al. Unsupervised cross-view semantic transfer for remote sensing image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(1): 13-17.
- [12] HUANG Y, PENG J T, CHEN N, et al. Cross-scene wetland mapping on hyperspectral remote sensing images using adversarial domain adaptation network[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 203: 37-54.
- [13] SUN Q R, LIU Y Y, CHUA T S, et al. Meta-transfer learning for few-shot learning[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2019: 403-412.
- [14] HOU R B, CHANG H, MA B P, et al. Cross attention network for few-shot classification[C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. New York: ACM, 2019: 4003-4024.
- [15] SUNG F, YANG Y X, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 1199-1208.
- [16] SNELL J, SWERSKY K, ZEMEL R, et al. Prototypical networks for few-shot learning[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM, 2017: 4080-4090.
- [17] SUN X, WANG B, WANG Z R, et al. Research progress on few-shot learning for remote sensing image interpretation[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 2387-2402.
- [18] HUANG H W, WU Z K, LI W B, et al. Local descriptor-based multi-prototype network for few-shot learning[J]. Pattern Recognition, 2021, 116: 107935.
- [19] ZHANG C Y, YUE J, QIN Q M. Global prototypical network for few-shot hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 4748-4759.
- [20] LIU S J, SHI Q, ZHANG L P. Few-shot hyperspectral image classification with unknown classes using multitask deep learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(6): 5085-5102.
- [21] ZHANG Y X, LI W, ZHANG M M, et al. Graph information aggregation cross-domain few-shot learning for hyperspectral image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(2): 1912-1925.
- [22] LIU B, YU X C, YU A Z, et al. Deep few-shot learning for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(4): 2290-2304.
- [23] GAO K L, LIU B, YU X C, et al. Deep relation network for hyperspectral image few-shot classification[J]. Remote Sensing, 2020, 12(6): 923.
- [24] ZHANG M M, ZHAO X D, LI W, et al. Cross-scene joint classification of multisource data with multilevel domain adaptation network[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(8): 11514-11526.
- [25] 万升, 杨健, 宫辰. 基于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.

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. (in Chinese)

- [26] ZHANG Y X, LI W, TAO R, et al. Cross-scene hyperspectral image classification with discriminative cooperative alignment[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(11): 9646-9660.


- [27] YU C H, WANG J D, CHEN Y Q, et al. Transfer learning with dynamic adversarial adaptation network[C]//2019 IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE, 2019: 778-786.

- [28] YANG L, LI L L, ZHANG Z L, et al. DPGN: Distribution propagation graph network for few-shot learning[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020: 13387-13396.

作者简介



张宇翔 男, 1995年1月出生于青海省西宁市. 北京理工大学信息与电子学院博士研究生. 主要研究方向为高光谱图像跨域分类. 中国电子学会会员编号: E190159510M.
E-mail: zyx829625@163.com



张蒙蒙 女, 1994年6月出生于山东省济宁市. 现为北京理工大学信息与电子学院副研究员. 主要研究方向为高光谱图像处理.
E-mail: mengmengzhang@bit.edu.cn



李伟 男, 1985年2月出生于湖北省随州市. 现为北京理工大学信息与电子学院教授. 主要研究方向为高光谱图像处理.
E-mail: liw@bit.edu.cn



陶然 男, 1964年11月出生于安徽省芜湖市. 现为北京理工大学信息与电子学院教授. 主要研究方向为分数域信号与信息处理及其应用. 中国电子学会会员编号: E190002261F.
E-mail: rantao@bit.edu.cn