

中图法分类号: TP751 文献标识码: A 文章编号: 1006-8961(2024)08-2175-13

论文引用格式: Ma X R, Ha L, Shen D B, Mei L and Wang H Y. 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]

融合特征优化的跨数据集高光谱图像分类

马晓瑞^{1*}, 哈林¹, 谌敦斌¹, 梅亮², 王洪玉¹

1. 大连理工大学信息与通信工程学院, 大连 116024; 2. 大连理工大学光电工程与仪器科学学院, 大连 116024

摘要: 目的 高光谱图像分类可实现对地物目标的逐像素识别, 是对地观测中的关键技术。由于采集环境变迁与成像设备差异等因素的影响, 不同高光谱图像特征分布偏移, 影响现有模型的跨数据集分类精度。针对此, 提出了一种融合特征优化的无监督跨数据集高光谱图像分类方法。方法 提出了基于奇异值抑制的特征均衡策略实现数据内独立优化, 通过限制奇异值正则项兼顾特征的可迁移性与可鉴别性; 提出了基于隐式增广的特征匹配策略实现数据间特征协同优化, 引导源域特征逼近目标域提高模型的泛化性; 设计了基于隐式鉴别器的对抗学习框架实现数据间特征类别级优化, 提高了预测多样性, 实现跨数据集分类。结果 实验在 Pavia 数据集组和 HyRANK 数据集组上进行, 与多种最新的跨数据集高光谱图像分类方法进行了对比, 在 Pavia 数据集组中, 相比于性能第 2 的模型, 总体精度、平均精度和 κ 系数分别提高了 1.75%、3.55% 和 2.17%; 在 HyRANK 数据集组中, 相比于性能第 2 的模型, 总体精度、平均精度和 κ 系数分别提高了 6.58%、13.10% 和 7.96%。同时进行了消融实验, 研究了各个模块对高光谱图像分类效果的影响。实验结果表明, 每一模块在提高高光谱图像分类效果方面都是有效的。结论 本文提出的融合特征优化的跨数据集高光谱图像分类方法可以在无监督的条件下显著提高跨数据集高光谱图像分类精度, 提高分类预测的多样性, 得到更好的分类效果。

关键词: 高光谱图像分类; 跨数据集分类; 特征优化; 领域自适应; 无监督分类; 域对抗网络

Cross-dataset hyperspectral image classification based on fusion feature optimization

Ma Xiaorui^{1*}, Ha Lin¹, Shen Dunbin¹, Mei Liang², Wang Hongyu¹

1. School of Information and Communication Engineering, Dalian University of Technology, Dalian 116024, China;

2. School of Optoelectronic Engineering and Instrumentation Science, Dalian University of Technology, Dalian 116024, China

Abstract: Objective Hyperspectral image is a 3D data cube of “space-spectrum integration”. Its high-resolution spectral information can realize fine-grained land cover identification, and its wide-coverage spatial information can complete accurate land cover mapping. Therefore, hyperspectral images with spatial information and spectral information are widely used in tasks related to land cover classification. Thus, hyperspectral image classification is an important research topic in remote sensing field and a key supporting technology for many Earth observation tasks, such as smart cities, precision agriculture, and modern national defense. In recent years, many classification methods for hyperspectral images have been

收稿日期: 2023-08-21; 修回日期: 2023-12-12; 预印本日期: 2023-12-19

* 通信作者: 马晓瑞 maxr@dlut.edu.cn

基金项目: 国家自然科学基金项目(62271102); 辽宁省科技计划项目(2022JH1/10800100); 大连市科技创新基金项目(2022JJ11CG002)

Supported by: National Natural Science Foundation of China (62271102); Science and Technology Plan Project of Liaoning Province, China (2022JH1/10800100)

proposed to mine spatial and spectral information based on different deep networks, and they have achieved unprecedented high-precision classification results. However, due to various factors such as the change in acquisition environment and the difference in imaging sensors, the feature distribution of different hyperspectral images is shifted, which leads to the difficulty of cross-dataset classification. For this reason, existing classification methods usually retrain the model to deal with new hyperspectral image dataset, which is label intensive and time consuming. In the era of remote sensing big data, developing classification methods for cross-dataset hyperspectral images is important. Therefore, this study investigates classification methods for cross-dataset hyperspectral images to achieve large-scale Earth observation missions. **Method** This study proposes an unsupervised classification method for cross-dataset hyperspectral images based on feature optimization. The proposed method consists of three main modules. First, a feature balancing strategy is proposed to optimize the intra-dataset features independently. During the adversarial domain adaptation process, the transferability and discriminability of features are contradictory, and most existing methods sacrifice the feature discriminability of target dataset, which results in blurred class boundaries and affects classification performance. In the proposed method, a regularization term with singular value of the feature vectors from the source and target datasets is minimized to enhance the transferability and discriminability of the learned features. By extracting better features, this method achieves more accurate classification results on the target dataset. Second, a feature matching strategy is proposed to optimize the inter-dataset features collaboratively. No labeled sample is available in the target dataset, and feature discrepancies are obvious between the source dataset and the target dataset. Thus, the model cannot accurately match the two datasets, which leads to inadequate generalization. In the proposed method, an implicit feature augmentation strategy is performed to guide the source features to the target space, which improves the generalization performance of the model. By utilizing the underlying relationships between different datasets, this method adapts better to the target dataset and improves the overall performance of the classification model. Finally, an adversarial learning framework based on implicit discriminator is designed to optimize inter-dataset class-level features. Existing adversarial learning methods often construct an additional discriminator or use a binary classifier as a discriminator. The former focuses only on feature confusion between datasets and ignores class-level information, and the latter considers only class-level differences, which leads to ambiguous predictions. In the proposed method, by reusing the task classifier as an implicit discriminator, inter-dataset alignment and cross-dataset class recognition are achieved. By further optimizing the adversarial learning method, this approach can further enhance the classification performance of the model on the target dataset. **Result** All experiments in this study are executed on a desktop computer with Intel Core i7 4.0 GHz CPU, GeForce GTX 1080Ti GPU, and 32 GB memory. PyTorch, which is a widely used deep learning framework, is used in the experiment. The experiments are conducted on Pavia and HyRANK datasets. The evaluation indexes include overall accuracy (OA), average accuracy (AA), and κ coefficient. In addition, the classification results are intuitively represented by classification maps. The experimental results are compared with various recent classification methods for cross-dataset hyperspectral images trained with all labeled source samples and unlabeled target samples. The proposed method is optimized by a small-batch SGD optimizer with a momentum of 0.9. The learning rates for the Pavia and HyRANK datasets are set to 0.0001 and 0.001, respectively. The maximum number of iterations is set to 2000. In the Pavia datasets, OA, AA, and κ values increase by 1.75%, 3.55%, and 2.17%, respectively, compared with the model with the second performance. In the HyRANK datasets, OA, AA, and κ values increase by 6.58%, 13.10%, and 7.96%, respectively, compared with the second-ranked model. Experimental results show that, compared with other methods, the classification maps produced by the proposed method are closer to the ground truth, and evaluation indexes of some categories are significantly improved. Moreover, the ablation experiment is conducted to study the effect of each module of the proposed method, which proves that each module is effective in improving the cross-dataset classification effect of hyperspectral images. **Conclusion** In this study, a feature-optimized classification method for cross-dataset hyperspectral images is proposed. The proposed method provides a novel solution for unsupervised classification of cross-dataset hyperspectral images. By combining feature equalization, feature matching, and adversarial learning techniques, the method improves the generalization capability and classification performance of the model. Thus, it is an effective approach for cross-dataset image classification tasks. The proposed method is verified on two hyperspectral datasets, and the experimental results show that the proposed method can significantly improve the accuracy of cross-dataset hyperspec-

tral images under unsupervised conditions compared with related methods.

Key words: hyperspectral image classification; cross-dataset classification; feature optimization; domain adaptation; unsupervised classification; domain adversarial network

0 引言

高光谱图像为“空谱合一”的三维数据立方体,其高分辨率的光谱信息可实现精细的地物目标识别,联合其大幅宽的空间信息可完成地物分布精准制图。为此,兼顾空间信息与光谱信息的高光谱图像广泛应用于对地观测任务中。高光谱图像分类可实现对地物目标的逐像素识别,是智慧城市、精准农业和现代国防等诸多对地观测任务的关键支撑技术(李德仁等,2012)。

受高光谱遥感优势驱动,高光谱图像分类技术日益发展,大量高性能方法频繁涌现。由于空间分辨率的限制,早期高光谱图像分类方法基于光谱特征开发分类模型(Tarabalka等,2010;华晔等,2012; Tuia等,2010; Li等,2010; Belgiu和Drăguț,2016)。随着高光谱成像技术与传输技术的发展,高光谱图像的空间分辨率大幅提高,空间信息为高精度分类提供了新的发展空间。众多学者相继提出了联合空间和光谱信息的空谱分类方法,具有代表性的方法如稀疏表示(Chen等,2013)、空谱联合滤波器(Fauvel等,2013)和神经网络(Chen等,2014,2015;刘启超等,2021;吴鸿昊等,2021;程嵩阳等,2021)等。上述分类方法针对高光谱图像空谱信息挖掘与利用展开研究,取得了前所未有的高精度分类结果。然而,由于采集环境变迁与传感器差异等一系列因素的影响,不同高光谱图像特征分布偏移,导致模型在跨数据集分类时面临挑战。随着遥感数据源日渐丰富,人们对大规模对地观测任务的需求持续增加,开发具有跨数据集能力的高光谱图像分类方法至关重要。

领域自适应方法是跨数据集高光谱图像分类的主要解决方案之一。一些领域自适应方法依赖目标域的有限标记样本提高跨数据集分类性能(Zhou和Prasad,2018; Qin等,2019; Saboori和Ghassemian,2020),然而,获取目标域样本依赖人力成本与时间代价。针对上述问题,无监督域自适应方法不断涌现(Li等,2020),典型方法有赵春晖等人(2021)的密

集卷积域自适应模型,彭江涛等人(2020)的稀疏矩阵变换与关联对齐法相结合的跨数据集分类方法。对抗领域自适应方法可以更有效地实现域关联,如基于自注意力生成对抗适应网络的领域自适应方法(Zhao等,2020)、主动领域自适应模型(Saboori和Ghassemian,2021)、无监督联合对抗域自适应框架(Tang等,2022)、双分类器对抗网络(Wang等,2023)和结合对抗性学习和自信学习的无监督域自适应框架(Fang等,2022)等。以上跨数据集分类方法能够有效地将知识从源域迁移到目标域,使跨数据集高光谱图像分类方法的性能有很大的提升。

尽管已取得了重要的进展,对抗性域自适应仍存在以下问题:1)由于特征的可迁移性和可鉴别性相互矛盾(Chen等,2019),大部分模型牺牲目标数据的可鉴别性,导致类别边界模糊;2)由于不存在目标样本标签,模型无法精准匹配特征偏移的数据,导致泛化能力不足;3)由于现有方法依赖额外构造的鉴别器,无法兼顾数据间特征混淆与类别间特征差异,导致跨数据分类精度有限。

为了解决上述问题,本文提出一种融合特征优化的跨数据集高光谱图像分类方法,主要贡献如下:1)为了解决可迁移性与可鉴别性之间的矛盾,设计了基于奇异值抑制的特征均衡模块,利用光谱惩罚限制最大奇异值实现均衡特征,通过数据内特征优化学习可迁移性特征的同时提高特征可鉴别性;2)为了解决目标域标签不足导致无法精准匹配的问题,设计了基于隐式增广的特征匹配模块,通过源域特征隐式增广引导源特征逼近目标域风格,通过数据间特征协同优化提高模型在目标域上的泛化能力;3)为了兼顾数据间特征混淆与类别间特征差异,设计了基于隐式鉴别器的对抗学习框架,复用分类器作为鉴别器实现对抗学习,通过数据间类别级优化实现数据对齐和跨数据类识别。本文方法区别于传统对抗性领域自适应方法大多只考虑数据间特征匹配的情况,通过数据内和数据间特征双重优化,缓解跨数据集高光谱图像分类特征偏移问题,同时通过类级特征优化,得到更准确的分类结果。

1 研究方法

本文所提出的融合特征优化的跨数据集高光光谱图像分类方法的总体模型框架如图1所示。生成器G包括空谱特征挖掘模块F、特征均衡模块B和特征匹配模块M,通过空谱特征挖掘模块F提取源数据和目标数据的特征,对所提取到的特征通过特征均衡模块B批量进行光谱惩罚限制最大奇异值,保持可迁移性的同时提高特征可鉴别性,再通过特征匹配模块M对源特征与目标特征进行分布适配,提高模型在未标记目标数据上的泛化能力。

本文约定源样本与源特征对应源数据,目标样本与目标特征对应目标数据。假设源样本集表示为 $D_s = \{\mathbf{x}_i^s, y_i^s\}_{i=1}^{N_s}$, 有 N_s 个已标记样本。目标样本集表示为 $D_t = \{\mathbf{x}_j^t\}_{j=1}^{N_t}$, 有 N_t 个未标记样本。设整个生成器的嵌入函数为 f , 对于任意样本 \mathbf{x} 经过生成器后可得输入样本的特征表示 $\mathbf{r} = f(\mathbf{x})$ 。生成器内包含的特征挖掘模块F、域内特征均衡模块B和域间特征匹配模块M得到的输出依次为 $\hat{\mathbf{r}} = f_1(\mathbf{x})$ 、 $\tilde{\mathbf{r}} = f_2(\hat{\mathbf{r}})$ 和

$\mathbf{r} = f_3(\tilde{\mathbf{r}})$ 。分类模块C用来预测类别信息并作为隐式的鉴别器与生成模块对抗训练,以进行充分的特征对齐与类别区分。通过分类器可以得到样本属于每个类的分类概率,假设分类的嵌入函数为 g , 则其分类预测为 $\mathbf{z} = g(\mathbf{r})$ 。

1.1 空谱特征挖掘模块

高光谱图像具有“图谱合一”的特点,有成百个连续的光谱通道,为此,空谱特征挖掘至关重要。由于高光谱图像单个像素与其周围的邻域像素往往表现出高度的相关性,本文将需要处理的中心像素与其周围的邻域像素作为一个数据立方体,输入到空谱特征挖掘模块F,利用残差网络(residual network, ResNet)(He等,2016)学习高光谱图像的空谱信息。

ResNet是由若干个残差块组成的网络。通过数据预处理以及使用批量归一化(batch normalization, BN)层来解决梯度爆炸问题。其核心思想为让神经网络某些层跳过下一层神经元的连接,隔层相连,弱化每层之间的强联系,从而减轻深度网络中的退化问题。高光谱数据立方体经过ResNet,残差块将其输入与输出叠加后激活得到输出,完成了高光谱图像空谱特征的初步挖掘。

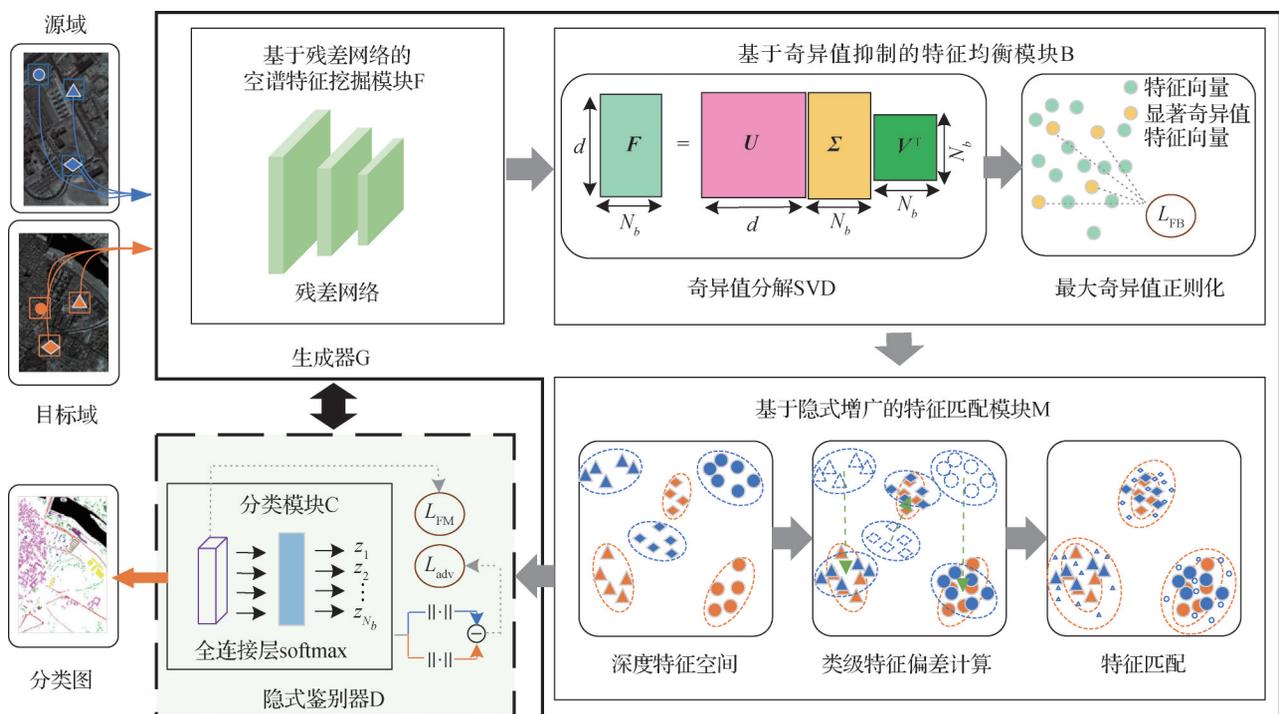


图1 本文方法框架

Fig. 1 The framework of the proposed method

1.2 特征均衡模块

在领域自适应的对抗性学习过程中,可迁移知识往往从最大奇异值对应的特征向量中获得,而其他特征向量会被过度惩罚,这些被过度惩罚的特征向量可能携带对特征可鉴别性至关重要的信息。因此,对抗性领域自适应方法优秀的可迁移性是以削弱可鉴别性为代价获得的。为此,本文设计了特征均衡模块B来抑制最大奇异值,从而相对加强其他特征向量,在保持特征可迁移性的同时提高可鉴别性。

首先,用奇异值分解(singular value decomposition, SVD)(Golub和Reinsch, 1970)的方法计算源特征矩阵 $F_s = [\hat{r}_1^s, \dots, \hat{r}_{N_s}^s]$ 和目标特征矩阵 $F_t = [\hat{r}_1^t, \dots, \hat{r}_{N_t}^t]$ 的所有奇异值和特征向量

$$F_s = U_s \Sigma_s V_s^T, F_t = U_t \Sigma_t V_t^T \quad (1)$$

式中, U 、 V 分别为特征矩阵分解得到的左、右奇异矩阵, N_b 为批处理的大小。根据奇异值矩阵 Σ_s 和 Σ_t 得到源特征矩阵和目标特征矩阵的 M 个最大奇异值,再通过对特征向量批量进行光谱惩罚作为这 M 个最大奇异值的正则化项,具体为

$$L_{FB} = \sum_{i=1}^M ((\sigma_i^s)^2 + (\sigma_i^t)^2) \quad (2)$$

式中, σ_i^s 和 σ_i^t 分别是 Σ_s 和 Σ_t 中的第 i 个最大奇异值。为了减小计算复杂度,提高训练的效率,每个批处理中默认 $M = 1$ 。通过抑制最大奇异值均衡源域和目标域的特征,以此来提高特征的可鉴别性。

1.3 特征匹配模块

至此,已通过特征挖掘模块F初步提取源数据和目标数据的空谱特征,又通过特征均衡模块B提高可鉴别性。为了进一步提高模型在目标数据上的泛化能力,设计了特征匹配模块M,使源特征朝着目标特征的方向趋近,从而实现数据间特征匹配。

对于数据集中的每一个类别 k ,模块M利用数据间特征均值差 $\Delta\mu_k = \mu_k^s - \mu_k^t$ 和目标特征类内协方差 D_k^t 构建一个多元高斯分布来表示数据间该类别特征差异, μ_k^s 和 μ_k^t 分别表示源数据和目标数据的特征均值,用伪标签来代替目标类别标签。然后,从构建的分布 $N(\lambda\Delta\mu_k, \lambda D_k^t)$ 中随机采样特征漂移的方向来增强源特征, $\lambda = (t/T)\lambda_0$ 控制增强的强度, t 和 T 分别为当前迭代次数和最大迭代次数, λ_0 为超参数,随着训练推进, λ 逐渐从0增加到 λ_0 。最后,当建

立起 K 个类别的采样分布后,每个源样本的特征 \tilde{r}_i^s 沿着建立好的分布随机进行匹配,生成增强源特征 $\tilde{r}_{i,\text{aug}}^s$, 遵循分布为 $\tilde{r}_{i,\text{aug}}^s \sim N(\tilde{r}_i^s + \lambda\Delta\mu_{y_i^s}, \lambda D_{y_i^s}^t)$, 增广 N_a 次,得到一个增强的特征集,在该增强特征集上利用交叉熵损失训练模型,使源监督分类器适配目标数据,具体为

$$L_{N_a}(\mathbf{W}, \mathbf{b}) = \frac{1}{N_s} \sum_{i=1}^{N_s} \frac{1}{N_a} \sum_{m=1}^{N_a} -\log \left(\frac{\exp(\mathbf{w}_{y_i^s}^T \tilde{r}_{i,\text{aug}}^{s,m} + b_{y_i^s})}{\sum_{k=1}^K \exp(\mathbf{w}_k^T \tilde{r}_{i,\text{aug}}^{s,m} + b_k)} \right) \quad (3)$$

式中,权重矩阵 $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_K]^T \in \mathbf{R}^{K \times q}$, 偏置向量 $\mathbf{b} = [b_1, b_2, \dots, b_K]^T \in \mathbf{R}^K$, q 是特征嵌入维数, \mathbf{R} 表示实数空间。

增广次数与计算代价直接相关,为在小代价下取得预期的性能,本方法在 N_a 趋于无穷时,通过推导式(3)的上限来隐式生成无限次增广的源特征。根据 Jensen 不等式(Chandler, 1987)和对数函数的凹特性 $\mathbb{E}[\log(X)] \leq \log(\mathbb{E}[X])$, 可推导出

$$\lim_{N_a \rightarrow \infty} L_{N_a} \leq L_\infty = -\frac{1}{N_s} \sum_{i=1}^{N_s} \log \frac{\exp X_i^{s,y_i^s}}{\sum_{k=1}^K \exp X_i^{s,k}} \quad (4)$$

$$X_i^{s,k} = z_i^{s,k} + \lambda(\mathbf{w}_k^T - \mathbf{w}_{y_i^s}^T) \Delta\mu_{y_i^s} + \frac{\lambda(\mathbf{w}_k^T - \mathbf{w}_{y_i^s}^T) D_{y_i^s}^t (\mathbf{w}_k - \mathbf{w}_{y_i^s})}{2}$$

式中, $z_i^{s,k}$ 是源样本分类输出的第 k 个元素。

对于目标数据,互信息测量两个随机变量的相关性。目标特征和预测之间的强相关性会使提取的特征具有更强的可鉴别性。因此,对目标数据采用互信息最大化,具体为

$$L_{MI} = \sum_{k=1}^K \hat{z}^k \log \hat{z}^k - \frac{1}{N_t} \sum_{j=1}^{N_t} \sum_{k=1}^K z_j^{t,k} \log z_j^{t,k} \quad (5)$$

式中, $\hat{z} = \sum_{j=1}^{N_t} z_j^t / N_t$, 由于目标数据未标记,用目标预测的平均值代替。

数据间特征匹配模块的损失函数为

$$L_{FM} = L_\infty + \beta L_{MI} \quad (6)$$

式中, β 为权衡参数。该方法为隐式增强,引入的额外计算开销几乎可忽略不计,更轻量通用。

1.4 对抗性领域自适应

为实现跨数据集分类,本文设计基于隐式鉴别器的生成对抗网络,以特征挖掘模块F、特征均衡模

块B和特征匹配模块M构造生成器G,复用分类器C作为隐式鉴别器D,定义鉴别函数为核范数,通过最大化域鉴别损失,实现数据对齐和类识别。

分类器C由一个全连接层和一个softmax激活函数组成,可以实现类识别,同时,复用该分类器作为鉴别器实现特征级跨数据对齐。假设分类模块C的预测矩阵 $Z \in \mathbf{R}^{N_b \times K}$,其中元素 z_i^k 满足

$$\sum_{k=1}^K z_i^k = 1, z_i^k \geq 0, \forall i \in 1, \dots, N_b, k \in 1, \dots, K \quad (7)$$

式中, K 为类别数, N_b 为批处理的样本数。其自相关矩阵 $R = Z^T Z \in \mathbf{R}^{K \times K}$,基于此,定义整体类内相关性 I_a 与整体类间相关性 I_e ,具体为

$$I_a = \sum_{i,j=1}^K R_{ij}, I_e = \sum_{i \neq j} R_{ij} \quad (8)$$

源数据预测会产生较大的 I_a 和较小的 I_e ,而对无标签的目标数据预测通常会生成较小的 I_a 和较大的 I_e ,可利用 $I_a - I_e$ 表示数据差异。可推出

$$I_a - I_e = 2 \|Z\|_F - N_b \quad (9)$$

由于权重2和偏置 N_b 均为常数,可定义鉴别器嵌入函数 $d = \|Z\|_F$ 。

通过Frobenius范数构造的鉴别器能够与生成模块进行对抗性训练,有助于提高特征的可迁移性和可鉴别性。然而,Frobenius范数倾向于将具有少量样本的类别推到包含大量样本的邻近类别中,可能会减少预测的多样性(Cui等,2021)。因此,用核范数代替Frobenius范数,即 $d = \|Z\|_*$,以提高预测的多样性。此时,通过最大化对抗损失 L_{adv} 估计域差异,具体为

$$L_{adv} = \frac{1}{N_s} \sum_{i=1}^{N_s} d(f(\mathbf{x}_i^s)) - \frac{1}{N_t} \sum_{j=1}^{N_t} d(f(\mathbf{x}_j^t)) \quad (10)$$

至此,网络的整体优化目标函数为

$$\min_{D,G} \left\{ L_{FM} + \gamma L_{FB} + \max_D L_{adv} \right\} \quad (11)$$

式中, γ 为权衡参数。

综上,本方法利用特征挖掘模块F、特征均衡模块B和特征匹配模块M构造生成器G,F初步提取高光谱图像的空谱特征,B和M对特征进一步处理以获得可迁移性和可鉴别性。复用分类器C作为隐式鉴别器D,以核范数作为鉴别函数鼓励目标数据类内和类间的相关性接近源数据的相关性,保证了预测的多样性和确定性。

2 实验与分析

2.1 实验数据与实验设置

本文实验使用了Pavia数据集组(包括Pavia University场景与Pavia Center场景)和HyRANK数据集组(包括Dioni数据集和Loukia数据集),图2和图3展示了本实验所用数据集组的伪彩色图像和带有颜色标识的地面真值图。

1)Pavia数据集组。由ROSIS传感器拍摄于意大利北部帕维亚地区。包含Pavia University和Pavia Center两个场景的数据集,空间分辨率1.3 m,光谱分辨率4 nm。去除噪声波段后,Pavia University数据包含103个光谱波段,空间尺寸为610×340像素,Pavia Center数据包含102个光谱波段,空间尺寸为1096×715像素。选取二者共有的7类地物作为跨数据分类目标任务,Pavia University作为源数据集,包含39332个样本,Pavia Center作为目标数据集,包含39355个样本,两个数据集均选择了102个波段。

2)HyRANK数据集组。由美国宇航局EO-1卫星上搭载的Hyperion传感器获取,包含Dioni和Loukia两个数据集,空间分辨率30 m,波段覆盖范围400~2500 nm,包含176个光谱波段,空间尺寸分别为250×1376像素和249×945像素,两个数据集含有相同的14个类别。去掉2个未被标记的类别,剩余12类地物用做分类任务,Loukia数据集作为源域数据集,有10317个样本,Dioni作为目标域数据集,包含20024个样本。

本文实验均在CPU为Intel Core i7 4.0 GHz, GPU为GeForce GTX 1080Ti,内存为32 GB的台式电脑上进行。实验中使用了目前应用广泛的深度学习框架PyTorch。评价指标包括分类的总体精度(overall accuracy, OA)、平均精度(average accuracy, AA)和 κ 系数。此外,通过分类结果图来更直观地表示分类结果。

2.2 参数分析

为了全面评估提出模型的有效性,分析影响训练进度和分类效果的参数,包括数据参数批处理大小、网络参数ResNet的层数与输入数据块空间尺寸,以及损失函数参数 λ_0 、 β 和 γ 。

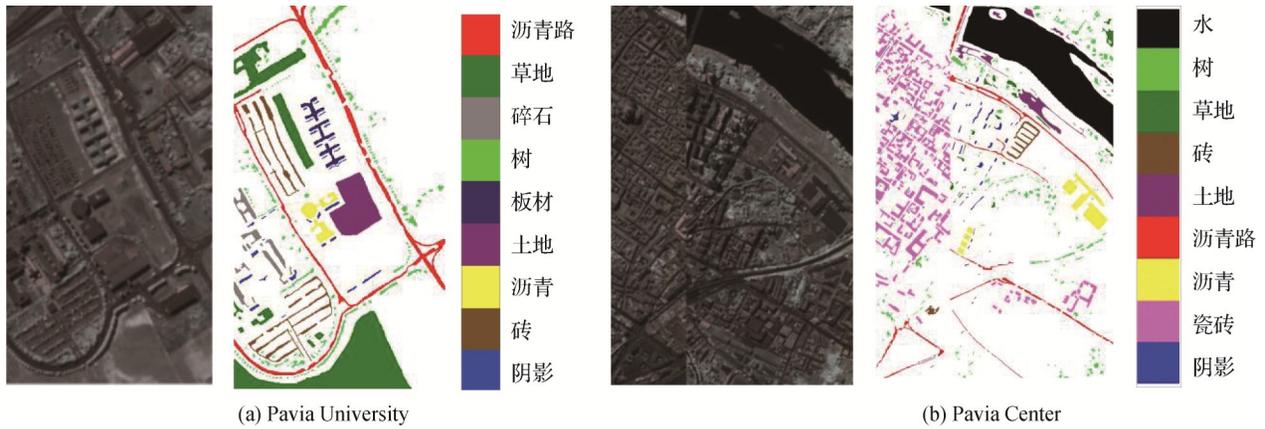


图 2 Pavia数据集组的伪彩色图像和带颜色标识的地面真值图

Fig. 2 Pseudocolor images and ground-truths with color identification for Pavia dataset group
(a) Pavia University; (b) Pavia Center)

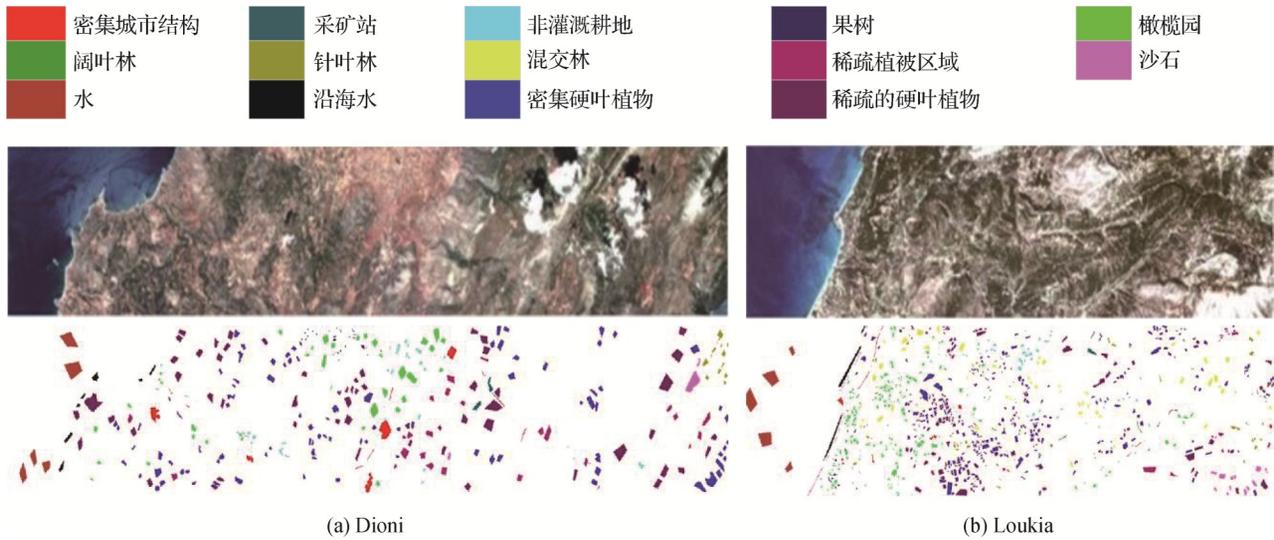


图 3 HyRANK数据集组的伪彩色图像和带颜色标识的地面真值图

Fig. 3 Pseudocolor images and ground-truths with color identification for HyRANK dataset group ((a) Dioni; (b) Loukia)

2. 2. 1 批处理大小

学习率和批量大小影响深度学习模型的收敛状态和泛化性能,学习率过大会导致模型不收敛,过小则收敛很慢或无法学习,而大的批量会导致模型泛化性能下降。在本实验中,采用指数变换策略控制学习率,批量大小则从 8, 16, 32, 64, 128 中选取。实验结果如图 4 所示, Pavia Center、Dioni 数据集在批量大小为 32 时效果最好。

2. 2. 2 ResNet 层数和数据块尺寸

ResNet 层数关系到网络特征提取的能力,层数过少无法充分学习到特征信息,而层数过多则会导致训练速度过慢甚至产生过拟合现象。输入数据块的尺寸决定了有多少空间信息用于分类,随着尺寸的增大,可用的空间信息逐渐增多,但也同时增

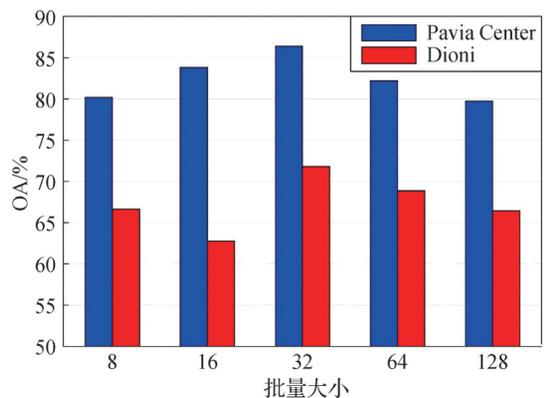


图 4 不同批量大小下的准确率
Fig. 4 Accuracy with different batch size

加了网络复杂度。以 Dioni 数据集为例分析 ResNet 层数对分类效果的影响, Pavia Center 数据集分析数据块尺寸对分类效果的影响。实验结果如表 1 所

示,6层的 ResNet 网络能很好地提取 Pavia Center 数据集的特征,由于 HyRANK 数据集组类间的相似度大且样本分布不均衡,导致跨数据分类难度大,需要提取更精细的特征,因此,该数据集组更适用 8 层的 ResNet 网络。输入数据块的尺寸与高光谱图像的空间分辨率密切相关。由于 Pavia Center 数据集的空间分辨率比 HyRANK 数据集组的小,适用于输入较小的数据块尺寸,因此,Pavia Center 数据集的输入数据块尺寸为 7×7 ,HyRANK 数据集组的输入数据块尺寸为 13×13 。

2.2.3 损失函数参数

参数 λ_0 和 β 为特征匹配模块的参数, λ_0 控制特征匹配的强度, β 关系到互信息损失所占的权重。考虑 $\{0.1, 0.25, 0.5, 0.75, 1.0\}$ 的 λ_0 的集合,通过实验研究特征匹配损失所占比重对分类准确率的影响,结果如图 5 所示。当 λ_0 取 0.25 时 Pavia Center 数据集和 Dioni 数据集分类的效果最好。

对 Dioni 数据集和 Pavia Center 数据集分别考虑 $\{0.01, 0.05, 0.1, 0.5, 1\}$ 和 $\{0.1, 0.5, 1, 2, 5\}$ 的 β 的集合,通过实验研究互信息损失所占比重对分类准确率的影响,结果如图 6 所示。 β 为 0.1 时 Dioni 数据集分类的效果最好, β 为 2 时 Pavia Center 数据

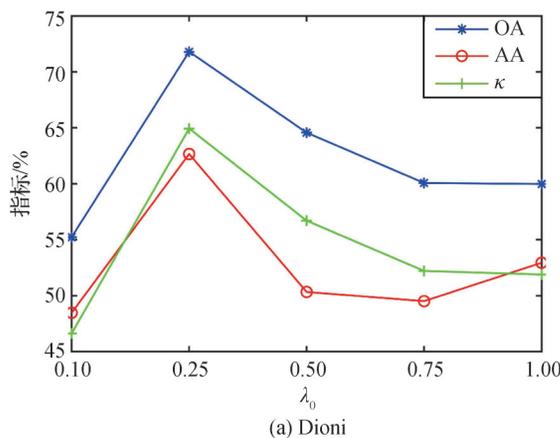


表 1 不同 ResNet 层数和数据块尺寸下的分类精度
Table 1 Classification accuracy for different number of ResNet layers and data block sizes

数据集	层数(数据块尺寸)	OA/%	AA/%	κ /%
Dioni	6(13×13)	70.33	58.53	62.57
	8(13×13)	71.80	62.66	64.94
	10(13×13)	68.63	54.27	60.53
	18(13×13)	63.63	49.23	54.80
Pavia Center	6(7×7)	86.83	86.47	84.21
	6(9×9)	85.63	85.63	82.80
	6(11×11)	85.26	82.10	82.30
	6(13×13)	84.90	81.73	81.87

注:加粗字体表示各项指标在不同数据集的最优结果。

集分类的效果最好。

参数 γ 衡量特征均衡模块的贡献,由于不同数据集特征可迁移能力和可鉴别能力均有所不同,因此,所对应的 γ 值也不同。考虑 $\{0.000001, 0.00001, 0.0001, 0.001, 0.01\}$ 的 γ 的集合,在两组数据集上进行实验,观察目标域的分类效果,结果如图 7 所示,Pavia Center 数据集在 $\gamma = 0.0001$ 时分类效果最好,Dioni 数据集在 $\gamma = 0.001$ 时分类效果最好。

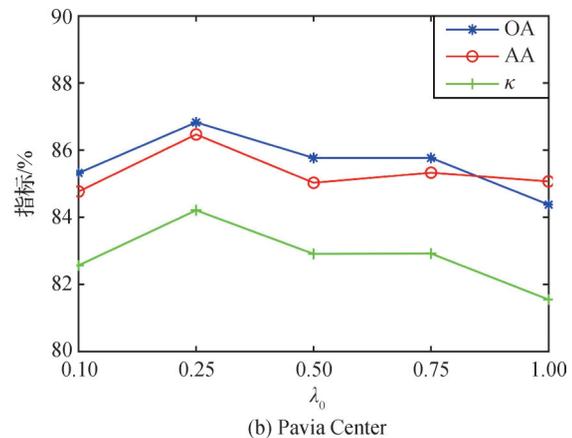


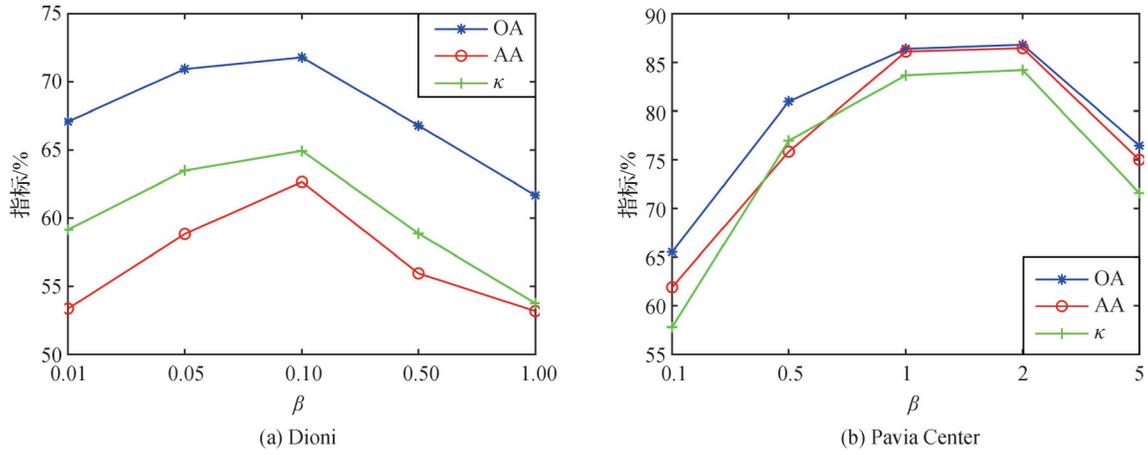
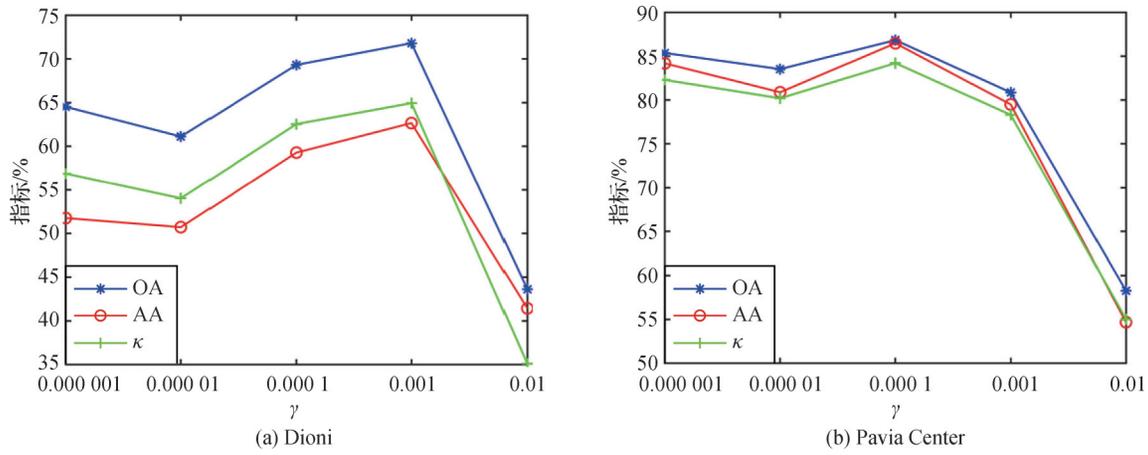
图 5 参数 λ_0 对模型分类效果的影响分析

Fig. 5 Analysis of the influence of the parameter λ_0 on the classification effect of the model ((a) Dioni; (b) Pavia Center)

2.3 对比实验与分析

为了对本文跨数据集分类方法的性能进行全面分析,与如下算法进行对比:1)无自适应网络(no adaptation network, NA):将在源域上训练得到的模型直接用于目标域样本的分类,与本文所提出的方法具有相同的特征提取和分类结构;2)关联对齐法

(correlation alignment, CORAL):通过对源域和目标域进行线性变换来将它们各自协方差矩阵对齐(Sun 等, 2016);3)条件域对抗网络(conditional domain adversarial network, CDAN):将特征和预测的类别联合起来进行优化,输入到鉴别器中,并通过熵来控制样本的重要性(Long 等, 2018);4)辅助目标域导

图6 参数 β 对模型分类效果的影响分析Fig. 6 Analysis of the influence of the parameter β on the classification effect of the model ((a) Dioni; (b) Pavia Center)图7 参数 γ 对模型分类效果的影响分析Fig. 7 Analysis of the influence of the parameter γ on the classification effect of the model ((a) Dioni; (b) Pavia Center)

向分类器(auxiliary target domain oriented classifier, ATDOC):对目标数据引入一个辅助分类器以减轻域偏移,用类质心表示目标域,通过分类器生成面向目标的伪标签(Liang等,2020);5)对抗域适应网络(adversarial domain adaptation network, ADA):一种对抗性的领域自适应方法,变分自编码器作为生成器,由多个分类器作为鉴别器,生成器和鉴别器通过对抗性学习,可以在保持不同类别边界的同时对齐源域和目标域(Ma等,2021);6)拓扑结构与语义信息迁移网络(topological structure and semantic information transfer network, TST):将图卷积网络引入高光光谱图像跨场景分类中,提高模型的空间感知能力,从数据统计分布和拓扑结构信息两个层面进行域对齐(Zhang等,2023b);7)单源域扩展网络(single-source domain expansion network, SDE):基于域泛化的思想,采用生成式对抗性学习进行源数据训练和

目标数据测试,保证域扩展的可靠性和有效性(Zhang等,2023a)。

2.4 实验结果

为了进行科学的研究,对比算法中SDE方法采用全部的标记源样本进行训练,其余算法使用所有已标记的源样本和未标记的目标样本进行训练。ATDOC和CDAN方法所用的特征提取器均为ResNet网络,批处理大小和网络层数与本文中所提出的方法相同。根据参数分析结果设置实验参数,超参数 λ_0 在所有数据集中均取0.25,超参数 β 和 γ 在Pavia数据集组分别设置为2和0.0001,在HyRANK数据集组分别设置为0.1和0.001。网络优化采用动量为0.9的小批量SGD(stochastic gradient descent)优化器,Pavia数据集组和HyRANK数据集组的学习率分别设置为0.0001和0.001。实验中,设置最大迭代次数为2000次。

分类的总体精度、平均精度和 κ 系数如表2所示。根据表2结果显示,相比其他方法,本文方法在无监督条件下能为目标域数据产生最佳的分类性能。由于SDE的跨数据高光谱图像分类方法采用域泛化思想,训练过程中只用到了已标记的源数据,目标数据未参与训练,因此,分类效果相对较差。不同方法下Pavia Center数据集的分类结果如图8所示。为了方便观察,取Dioni数据集分类效果图中 $250 \times$

($776 \sim 1\,376$)像素区域进行展示,不同方法下其分类结果如图9所示。根据分类结果图可以看出,相比其他方法,本文的方法得到的分类效果图更接近地面真值图,且可以明显改善某些类别的准确率,如图8中黄色区域。根据图9显示,由于Dioni数据集类别间相似度较高,其他方法分类时容易将多个类别分为一类,而本文方法可以明显提高预测的多样性,得到更好的分类效果。

表2 不同方法下所有目标高光谱数据集的分类精度

Table 2 Classification accuracy for all target hyperspectral datasets under different methods

方法	Pavia Center 数据集			Dioni 数据集		
	OA/%	AA/%	κ /%	OA/%	AA/%	κ /%
NA	77.22	77.80	72.80	65.09	50.78	57.08
CORAL	49.21	49.03	40.75	32.99	33.40	22.98
CDAN	72.14	74.70	66.82	65.22	49.56	56.98
ATDOC	84.36	83.36	81.34	60.69	40.75	50.48
ADA	85.08	82.92	82.04	55.78	33.22	46.42
TST	65.97	66.79	59.72	63.09	48.50	54.78
SDE	81.13	81.97	77.43	64.48	47.07	55.53
本文	86.83	86.47	84.21	71.80	62.66	64.94

注:加粗字体表示各列最优结果。

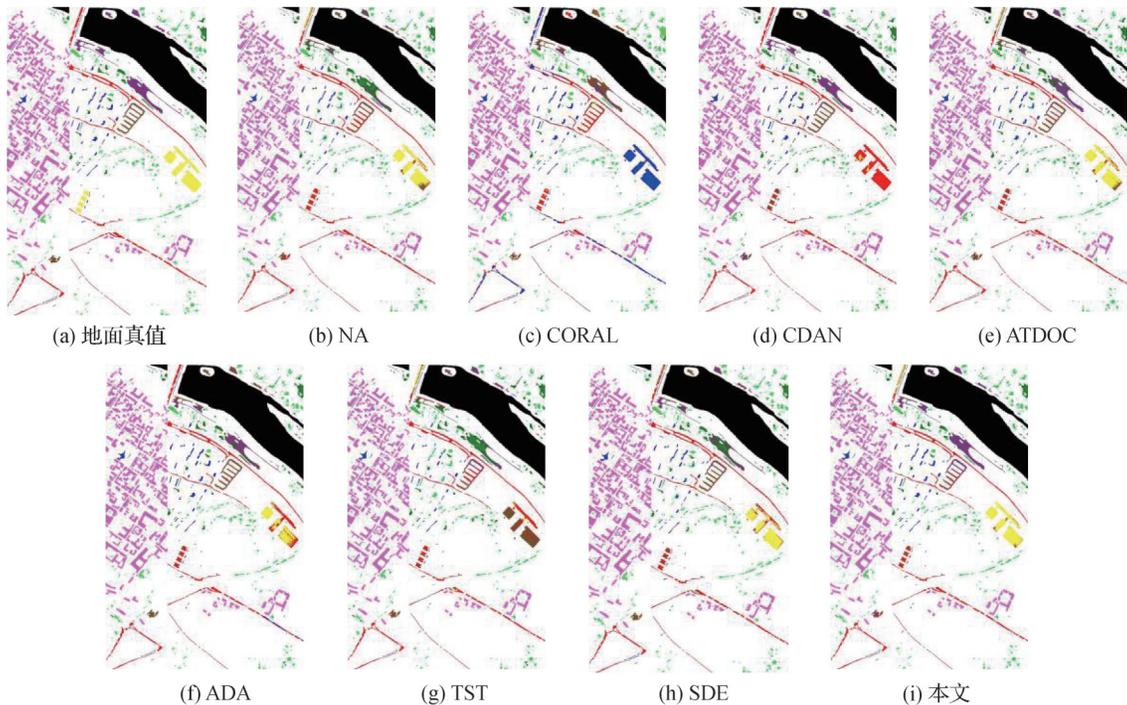


图8 不同方法在Pavia Center数据集的分类效果图

Fig. 8 Classification maps of Pavia Center dataset with different methods

((a) ground truth; (b) NA; (c) CORAL; (d) CDAN; (e) ATDOC; (f) ADA; (g) TST; (h) SDE; (i) ours)

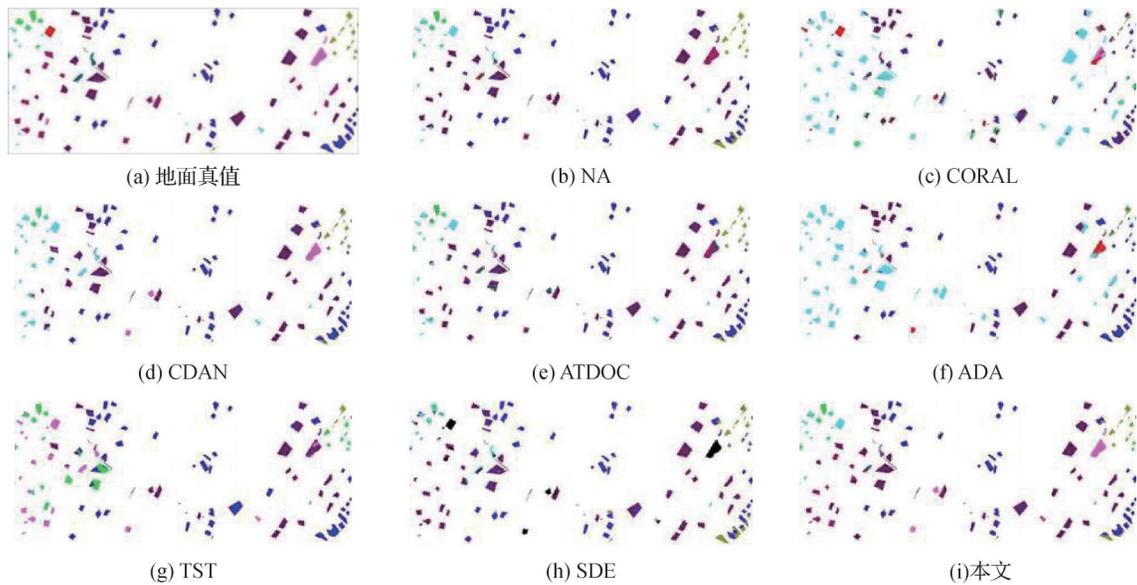


图9 不同方法在Dioni数据集的分类效果图

Fig. 9 Classification maps of Dioni dataset with different methods

((a) ground truth; (b) NA; (c) CORAL; (d) CDAN; (e) ATDOC; (f) ADA; (g) TST; (h) SDE; (i) ours)

此外,为了研究各个模块对高光谱图像分类效果的影响,在Dioni数据集上进行了消融实验,表3所示为实验结果,根据结果显示,特征匹配模块(feature matching module, FM)使本文的对抗域自适应网络(adversarial domain adaptation network, AD_Net)的总体精度提高了10.29%,而特征均衡模块(feature balance module, FB)使AD_Net的总体精度提高了20.35%。在AD_Net和FB的基础上加入FM后,总体精度增加7.08%,在AD_Net和FM的基础上加入FB后,总体精度增加了17.14%。总体而言,本文方法平均提高了27.43%的总体精度,表明每一模块在提高高光谱图像分类效果方面都是有效的。

表3 各模块对Dioni数据集准确率的影响

Table 3 Effect of each module on the accuracy of the Dioni dataset

序号	AD_Net	FB	FM	OA/%	AA/%	κ /%
1	√	-	-	44.37	42.62	35.62
2	√	-	√	54.66	52.72	46.65
3	√	√	-	64.72	51.09	55.62
4	√	√	√	71.80	62.66	64.94

注:加粗字体表示各列最优结果,“√”表示使用相应模块,“-”表示未使用。

3 结论

本文提出了一种融合特征优化的跨数据集高光谱图像分类方法,设计基于隐式鉴别器的对抗性领域自适应网络框架,复用任务特定分类器作为隐式鉴别器,同时实现数据对齐和类别区分。设计特征均衡模块和特征匹配模块,在提高特征的可鉴别性的同时提高模型在目标数据上的泛化能力,有效地缓解了数据分布偏移问题。在两组高光谱数据集上验证本文所提出的算法,实验结果表明,与相关方法相比,本文方法可以在无监督的条件下显著提高跨数据集高光谱图像分类精度。然而,本文方法只在源数据集和目标数据集含有相同的土地覆盖类型时适用,无法处理更多更复杂的领域自适应任务。因此,下一步将研究如何在源数据和目标数据各含有私有类的情况下进行无监督跨数据集分类。

参考文献(References)

- Belgiu M and Drăguț L. 2016. Random forest in remote sensing: a review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114: 24-31 [DOI: 10.1016/j.isprsjprs.2016.01.011]
- Chandler D. 1987. *Introduction to Modern Statistical Mechanics*. New

- York: Oxford University Press
- Chen X Y, Wang S N, Long M S and Wang J M. 2019. Transferability vs. discriminability: batch spectral penalization for adversarial domain adaptation//Proceedings of the 36th International Conference on Machine Learning. Long Beach, USA: PMLR: 1081-1090
- Chen Y, Nasrabadi N M and Tran T D. 2013. Hyperspectral image classification via kernel sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1): 217-231 [DOI: 10.1109/TGRS.2012.2201730]
- Chen Y S, Lin Z H, Zhao X, Wang G and Gu Y F. 2014. Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6): 2094-2107 [DOI: 10.1109/JSTARS.2014.2329330]
- Chen Y S, Zhao X and Jia X P. 2015. Spectral-spatial classification of hyperspectral data based on deep belief network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6): 2381-2392 [DOI: 10.1109/JSTARS.2015.2388577]
- Cheng S Y, Xiong Y J, Yao Y and Li Q L. 2021. Hyperspectral image classification using an inverted feature pyramid network with U-Net. *Journal of Image and Graphics*, 26(8): 1994-2008 (程嵩阳, 熊玉洁, 姚瑶, 李庆利. 2021. 结合倒置特征金字塔和U-Net的高光谱图像分类. *中国图象图形学报*, 26(8): 1994-2008 [DOI: 10.11834/jig.210194])
- Cui S H, Wang S H, Zhuo J B, Li L, Huang Q M and Tian Q. 2021. Fast batch nuclear-norm maximization and minimization for robust domain adaptation [EB/OL]. [2023-08-21]. <https://arxiv.org/pdf/2107.06154.pdf>
- Fang Z Q, Yang Y X, Li Z K, Li W, Chen Y S, Ma L and Du Q. 2022. Confident learning-based domain adaptation for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1-16 [DOI: 10.1109/TGRS.2022.3166817]
- Fauvel M, Tarabalka Y, Benediktsson J A, Chanussot J and Tilton J C. 2013. Advances in spectral-spatial classification of hyperspectral images. *Proceedings of the IEEE*, 101(3): 652-675 [DOI: 10.1109/JPROC.2012.2197589]
- Golub G H and Reinsch C. 1970. Singular value decomposition and least squares solutions. *Numerische Mathematik*, 14(5): 403-420 [DOI: 10.1007/BF02163027]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]
- Hua Y, Zhang T, Xi H W, Wang Y F and Huang X L. 2012. Research on method of hyperspectral remote sensing image classification based on decision tree. *Computer Technology and Development*, 22(6): 198-202 (华晔, 张涛, 奚后玮, 王玉斐, 黄秀丽. 2012. 基于决策树的高光谱遥感影像分类方法研究. *计算机技术与发展*, 22(6): 198-202 [DOI: 10.3969/j.issn.1673-629X.2012.06.051])
- Li D R, Tong Q X, Li R X, Gong J Y and Zhang L P. 2012. Current issues in high-resolution Earth observation technology. *Science China Earth Sciences*, 55(7): 1043-1051 (李德仁, 童庆禧, 李荣兴, 龚健雅, 张良培. 2012. 高分辨率对地观测的若干前沿科学问题. *中国科学: 地球科学*), 42(6): 805-813 [DOI: 10.1007/s11430-012-4445-9]
- Li J, Bioucas-Dias J M and Plaza A. 2010. Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning. *IEEE Transactions on Geoscience and Remote Sensing*, 48(11): 4085-4098 [DOI: 10.1109/TGRS.2010.2060550]
- Li Z K, Tang X Y, Li W, Wang C Y, Liu C W and He J R. 2020. A two-stage deep domain adaptation method for hyperspectral image classification. *Remote Sensing*, 12(7): #1054 [DOI: 10.3390/rs12071054]
- Liang J, Hu D P and Feng J S. 2020. Domain adaptation with auxiliary target domain-oriented classifier//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 16627-16637 [DOI: 10.1109/CVPR46437.2021.01636]
- Liu Q C, Xiao L and Yang J X. 2021. Parallel implementation of content-guided deep convolutional network for hyperspectral image classification. *Journal of Image and Graphics*, 26(8): 1926-1939 (刘启超, 肖亮, 杨劲翔. 2021. 面向高光谱图像分类的内容引导卷积深度网络并行实现. *中国图象图形学报*, 26(8): 1926-1939 [DOI: 10.11834/jig.200411])
- Long M S, Cao Z J, Wang J M and Jordan M I. 2018. Conditional adversarial domain adaptation//Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal, Canada: Curran Associates Inc.: 1647-1657
- Ma X R, Mou X R, Wang J, Liu X K, Geng J and Wang H Y. 2021. Cross-dataset hyperspectral image classification based on adversarial domain adaptation. *IEEE Transactions on Geoscience and Remote Sensing*, 59(5): 4179-4190 [DOI: 10.1109/TGRS.2020.3015357]
- Peng J T, Sun W W, Wei T H and Fan W Q. 2020. A modified correlation alignment algorithm for the domain adaptation of GF-5 hyperspectral image. *Journal of Remote Sensing*, 24(4): 417-426 (彭江涛, 孙伟伟, 魏天慧, 范文琦. 2020. 高分五号高光谱影像的关联对齐域适应与分类. *遥感学报*, 24(4): 417-426 [DOI: 10.11834/jrs.20209212])
- Qin Y, Bruzzone L and Li B. 2019. Tensor alignment based domain adaptation for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(11): 9290-9307 [DOI: 10.1109/TGRS.2019.2926069]
- Saboori A and Ghassemian H. 2020. Robust transfer joint matching distributions in semi-supervised domain adaptation for hyperspectral images classification. *International Journal of Remote Sensing*, 41(23): 9283-9307 [DOI: 10.1080/01431161.2020.1797221]

- Saboori A and Ghassemian H. 2021. Adversarial discriminative active deep learning for domain adaptation in hyperspectral images classification. *International Journal of Remote Sensing*, 42(10): 3981-4003 [DOI: 10.1080/01431161.2021.1880663]
- Sun B C, Feng J S and Saenko K. 2016. Return of frustratingly easy domain adaptation//*Proceedings of the 30th AAAI Conference on Artificial Intelligence*. Phoenix, USA: AAAI Press: 2058-2065
- Tang X B, Li C C and Peng Y X. 2022. Unsupervised joint adversarial domain adaptation for cross-scene hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5536415 [DOI: 10.1109/TGRS.2022.3202363]
- Tarabalka Y, Fauvel M, Chanussot J and Benediktsson J A. 2010. SVM- and MRF-based method for accurate classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 7(4): 736-740 [DOI: 10.1109/LGRS.2010.2047711]
- Tuia D, Camps-Valls G, Matasci G and Kanevski M. 2010. Learning relevant image features with multiple-kernel classification. *IEEE Transactions on Geoscience and Remote Sensing*, 48(10): 3780-3791 [DOI: 10.1109/TGRS.2010.2049496]
- Wang H Y, Cheng Y H, Liu X M and Kong Y. 2023. Bi-classifier adversarial network for cross-scene hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 20: #5504005 [DOI: 10.1109/LGRS.2023.3266407]
- Wu H H, Wang L G and Shi Y. 2021. Convolution neural network method for small-sample classification of hyperspectral images. *Journal of Image and Graphics*, 26(8): 2009-2020 (吴鸿昊, 王立国, 石瑶. 2021. 高光谱图像小样本分类的卷积神经网络方法. *中国图象图形学报*, 26(8): 2009-2020) [DOI: 10.11834/jig.210103]
- Zhang Y X, Li W, Sun W D, Tao R and Du Q. 2023a. Single-source domain expansion network for cross-scene hyperspectral image classification. *IEEE Transactions on Image Processing*, 32: 1498-1512 [DOI: 10.1109/TIP.2023.3243853]
- Zhang Y X, Li W, Zhang M M, Qu Y, Tao R and Qi H R. 2023b. Topological structure and semantic information transfer network for cross-scene hyperspectral image classification. *IEEE Transactions on Neural Networks and Learning Systems*, 34(6): 2817-2830 [DOI: 10.1109/TNNLS.2021.3109872]
- Zhao C H, Li T and Feng S. 2021. Hyperspectral image classification based on dense convolution and domain adaptation. *Acta Photonica Sinica*, 50(3): #0310001 (赵春晖, 李彤, 冯收. 2021. 基于密集卷积和域自适应的高光谱图像分类. *光子学报*, 50(3): #0310001) [DOI: 10.3788/gzxb20215003.0310001]
- Zhao W Z, Chen X, Chen J G and Qu Y. 2020. Sample generation with self-attention generative adversarial adaptation network (SaGAAN) for hyperspectral image classification. *Remote Sensing*, 12(5): #843 [DOI: 10.3390/rs12050843]
- Zhou X and Prasad S. 2018. Deep feature alignment neural networks for domain adaptation of hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 56(10): 5863-5872 [DOI: 10.1109/tgrs.2018.2827308]

作者简介

马晓瑞,女,副教授,硕士生导师,主要研究方向为遥感图像分类、目标检测与识别。E-mail:maxr@dlut.edu.cn

哈林,女,硕士研究生,主要研究方向为遥感图像分类。

E-mail:halin@mail.dlut.edu.cn

湛敦斌,男,博士研究生,主要研究方向为遥感图像目标检测。E-mail:sdb_2012@163.com

梅亮,男,教授,博士生导师,主要研究方向为光学遥感、激光雷达成像。E-mail:meiliang@dlut.edu.cn

王洪玉,男,教授,博士生导师,主要研究方向为遥感图像分类、目标检测与识别。E-mail:whyu@dlut.edu.cn