

文章编号 1004-924X(2023)17-2555-09

面向领域自适应的部分最优传输高光谱图像分类

王碧琳¹, 王生生^{1*}, 张 哲²

(1. 吉林大学 计算机科学与技术学院, 吉林 长春 130012;

2. 中国科学院 苏州生物医学工程技术研究所, 江苏 苏州 215163)

摘要:针对高光谱遥感图像分类时有标注的源域训练数据与无标注目标域数据分布不一致的问题,提出基于部分最优传输的无监督领域自适应方法,实现对处于不同数据分布的高光谱遥感地物像素级分类。利用深度卷积神经网络将样本映射到潜在高维空间,根据部分最优传输理论建立样本传输方案,最小化域间分布差异,构建适配模型。采用类感知采样技术和质量分数因子自适应调整策略,促进域间类别对齐,建立全局最优传输。在两组公开高光谱遥感图像数据集上进行实验,从总体分类精度 OA(%)、类别平均分类精度 AA(%)、分类一致性检验 Kappa($\times 100$)等 3 个评价指标对像素分类结果量化比较。实验结果显示,在两组迁移任务上,相较于仅使用源域数据的基线模型,总体分类准确率分别提升 2.21% 和 2.75%,相较于原始最优传输策略提升 1.71% 和 2.01%,表明模型能够有效提升高光谱遥感影像中像素级地物的分类精度。

关键词:计算机视觉;神经网络;领域自适应;最优传输;高光谱图像

中图分类号:P236 文献标识码:A doi:10.37188/OPE.20233117.2555

Partial optimal transport-based domain adaptation for hyperspectral image classification

WANG Bilin¹, WANG Shengsheng^{1*}, ZHANG Zhe²

(1. College of Computer Science and Technology, Jilin University, Changchun 130012, China;

2. Suzhou Institute of Biomedical Engineering and Technology, Chinese Academy of Sciences, Suzhou 215163, China)

* Corresponding author, E-mail: wss@jlu.edu.cn

Abstract: Hyperspectral image classification is a major task in remote sensing data processing. To solve the problem of inconsistent distribution of labeled source and unlabeled target domains, an unsupervised domain adaptive method based on partial optimal transport is proposed to achieve pixel-level classification of hyperspectral ground objects under different data distributions. Specifically, a deep convolution neural network is used to map the sample to the potential high-dimensional space, and the sample transportation scheme is established based on the partial optimal transport theory to minimize the distribution discrepancy between domains. Class-aware sampling and the mass factor adaptive adjustment strategy are used to promote the class alignment between domains and establish a global optimal transport. Experiments were con-

收稿日期:2023-02-15;修订日期:2023-03-13.

基金项目:国家重点研发计划资助项目(No. 2020YFA0714103);吉林省发展和改革委员会创新能力建设项目(No. 2021FGWCXNLJSSZ10, No. 2019C053-3)

ducted on two open-source hyperspectral image datasets, and the classification accuracies were compared quantitatively from the three evaluation matrices of overall accuracy (OA, %), average accuracy (AA, %), and Kappa ($\times 100$). Compared with the source-only method, the improved classification accuracies with the proposed method for OA and AA were 2.21% and 2.75%, respectively, and compared with the original optimal transport, the improved accuracies were 1.71% and 2.01%, respectively. These results show that the proposed model can effectively improve pixel-level classification accuracy in hyperspectral images.

Key words: computer vision; neural network; domain adaptation; optimal transport; hyperspectral image

1 引言

随着航天技术和电子信息科学的发展,遥感器分辨率及信息处理能力不断提高,遥感技术已被广泛应用于气象观测、精准农业和土地利用规划等多个领域^[1-3]。高光谱图像由多空间平台的成像光谱仪采集,结合光谱仪和光学相机的优点,实现目标区域的大范围细粒度成像,采集图像数据中包含丰富光谱-空间结构信息。基于像素空间关系及多波段光谱信息,高光谱图像分类技术致力于实现图像中地物精准分类,逐像素分配语义标签,对后续多种复杂地球信息的分析研究具有重要意义。

由于时空环境变化和图像采集设备不同,高光谱图像通常处于不同数学概率分布,数据特征偏移明显。在已有标注的源域数据集上训练的模型难以直接有效迁移到新捕获的无标注目标域数据。数据标注工作依赖专业设备和领域内专家,耗时费力,难以收集足够的标注数据。标注数据的缺乏对构建高精度高光谱图像分类模型带来了巨大挑战。

为解决域偏移导致的模型迁移困难问题,领域自适应技术通过缩减源域数据与目标域数据间的分布差异实现模型适配。当前领域自适应技术通常采用基于深度学习的方法,构建神经网络模型提取样本高维特征,衡量特征分布差异,利用神经网络迭代反馈促使域对齐^[4]。Liu等^[5]提出建立特征提取器与多个域鉴别器对抗学习模型结构,引入基于概率分布的最大均值差异方法,有效提升模型特征比较能力。Miao等^[6]提出联合分布对齐框架,采用变分自编码器学习在共享空间中学习域不变表示,实现细粒度跨域比对。Fang等^[7]提出将领域自适应与自信学习相

结合,选取高置信度的目标域样本作为训练数据,并逐步增加高置信度样本的比例,从而提升分类准确性。Liang等^[8]提出多源 few-shot 学习方法,从源域融合同质和异质数据内提取特征,提升分类模型的泛化能力。Makkar等^[9]基于对抗学习提取一致特征,采用半监督方法扩展可用标签,模型在多类别大尺度遥感图像上取得了优异效果。

为进一步减小源域和目标域的分布差异,缓解域偏移,结合高光谱遥感图像性质,本文提出一种基于部分最优传输的域适应方法,引入类感知批量样本采样技术和质量分数因子自适应调整策略,促进同类别像素样本间建立传输映射,缓解类别错误对齐。在建立传输方案时考虑目标域样本伪标签置信度,通过计算熵可靠性自适应调整传输质量分数,促进构建全局最优映射,优化传输方案,减小分布差异,提升分类模型精度。

2 基本原理

2.1 无监督领域自适应

神经网络模型训练依赖于大规模有标注样本。然而,由于数据分布不同,在已有标注的源域训练集上学习的模型通常难以在新出现的无标注目标域数据上取得同样优异的表现。为了充分利用已有的数据信息,提高模型在多源分布数据上的鲁棒性,无监督领域自适应(Unsupervised Domain Adaptation, UDA)方法通过基于对抗或基于散度的方法对域间差异进行准确度量,挖掘域不变信息或减小域间分布差异,从而使源域模型同样适用于目标域数据。基于以上

构想, Ben-David 等提出了无监督领域自适应的优化泛化误差界^[10]。具体公式如下:

$$\epsilon_T(h) \leq \epsilon_S(h) + \frac{1}{2} d_{H\Delta H}(\tilde{D}_S, \tilde{D}_T) + \lambda, \quad (1)$$

其中: $h \in H$ 为假设函数空间中分类函数。函数 h 在目标域数据上的分类误差 $\epsilon_T(h)$ 由源域分类误差 $\epsilon_S(h)$ 、源域与目标域间分布差异 $d_{H\Delta H}$ 以及常数项 λ 约束。因此, 无监督领域自适应算法的关键是在保证分类函数 h 适配于源域样本的同时最小化源域与目标域间的分布差异。进一步, 对源域与目标域分布间差异的准确度量至关重要。

2.2 最优传输

最优传输 (Optimal Transport, OT) 理论在 18 世纪由 Gaspard Monge 提出, 旨在通过优化寻找概率测度间变换。Kantorovich 将求解多个数学分布之间的变换问题松弛化为求解满足条件的联合概率分布, 从而有效衡量不同分布间的差异^[11-12]。假设存在两组处于不同分布的样本点 $X: = \{x_i\}_{i=1}^n$ 和 $Y: = \{y_i\}_{i=1}^n$ 组成的两个离散概率分布 $\mu_n: = \frac{1}{n} \sum_{i=1}^n \delta_{x_i}$ 和 $\nu_n: = \frac{1}{n} \sum_{i=1}^n \delta_{y_i}$, 则分布 μ_n 与 ν_n 间的最优传输优化问题定义如下:

$$OT(\mu_n, \nu_n): = \min_{\pi \in \Pi(\mu_n, \nu_n)} \langle C, \pi \rangle, \quad (2)$$

其中: C 是分布间的传输成本矩阵, π 为分布间的概率耦合。在域适应问题中, 为最小化域间分布差异, 建立全局最优传输方案准确度量域间距离, 在样本间建立传输, 通过反向传播更新高维特征, 实现样本级别分布对齐。

3 部分最优传输域适应图像分类算法

3.1 问题定义

假设存在两组由成像光谱仪采集的处于不同分布的高光谱遥感图像数据, 两组数据中包含相同的地物类别。图像数据中任意像素位置均包含多个光谱多段信息, 在模型构建及训练中, 将图像中像素逐一作为数据样本。源域 H_S 为有标注样本集 $X_S = \{x_s^i\}_{i=1}^M$, 包含 M 个像素样本, 对应像素位置的标签为 $Y_S = \{y_s^i\}_{i=1}^M$ 。目标域 H_T 为无标注样本集 $X_T = \{x_t^i\}_{i=1}^N$, 包含 N 个像素样本。源域与目标域像素地物类别空间 $Y_{S(T)} \in \{1, 2, \dots, C\}$ 相同, 均包含 C 个类别。源域分布与目标域分布分别表示为 P_{X_S} 和 P_{X_T} 。

3.2 算法原理

根据基于散度的领域自适应方法框架, 利用度量函数衡量域间差异, 通过不断缩减源域与目标域间距离学习域不变特征, 实现模型迁移。域适应模型构建中需要解决的关键问题在于如何准确衡量复杂分布间差异, 以及如何通过调整特征提取器参数实现源域与目标域特征在高维空间中对齐。

针对以上问题, 本文提出基于部分最优传输的领域自适应模型, 算法框架如图 1 所示。对于传入的源域与目标域数据, 采用共享多层卷积神经网络 G_θ 作为特征提取器, 将数据映射到潜在高维特征空间。对于提取到的数据特征, 采用基




图 1 基于部分最优传输的领域自适应模型整体框架

Fig. 1 Framework of proposed domain adaptive model base on partial optimal transport

于部分最优传输的度量函数,通过类感知样本采样以及质量分数因子自适应调整策略,构建样本间最优传输方案,准确衡量域间差异。进一步,利用两个不同的由全连接网络构造的分类器 F_φ 和 F_ψ 之间的对抗学习,挖掘难以辨别的样本特征从而实现特征对齐。通过分类器 F_φ 计算源域样本分类损失,保证模型在域不变特征上具备分类能力。

3.2.1 部分最优传输

对于离散样本集,最优传输算法通过建立样本间的全局映射,根据样本间传输成本矩阵,计算最优全局传输方案,从而准确度量离散分布间差异。然而,高光谱图像数据通常包含数以万计离散样本点,直接建立全局映射面临严重运算存储问题和难以接受的计算复杂度。因此,在实际计算中,通常采用批量样本采样方法,在每次迭代中仅使用原始数据集中的小部分样本参与训练,从而提升模型迭代效率。在此情况下,每次映射仅有部分像素样本参与,无法保证域间最优样本匹配同时采样在当前批量,导致计算得到的最优映射存在偏差,域间样本对齐,影响模型到目标域数据的适配效果。

针对以上问题,部分最优传输(Partial Optimal Transport, POT)算法^[13]通过在传输过程中设置质量分数因子控制样本质量映射,避免局部次优传输导致的负迁移。依照定义,离散概率测度 μ_n 与 ν_n 间的部分最优传输优化问题如下:

$$POT_s(\mu_n, \nu_n) = \min_{\pi \in \Pi_s(\mu_n, \nu_n)} \langle C, \pi \rangle, \quad (3)$$

其中:质量分数因子 $0 \leq s \leq 1$,分布间传输空间定义 $\Pi_s(\mu_n, \nu_n) := \{\pi \in R_+^{|\mu| \times |\nu|} : \pi 1_{|\nu|} \leq \mu, \pi^T 1_{|\mu|} \leq \nu, 1^T \pi 1 = s\}$, s 控制样本传输比例。对于批量训练模型,期望 s 值随最优映射存在比例正比例变化。假设当前设置采样批量大小为 k ,则建立在当前采样样本集合 $\tilde{X}_S$ 与 $\tilde{X}_T$ 间相对应的部分最优传输损失定义如下:

$$L_{POT}(\tilde{X}_S, \tilde{X}_T) = \frac{1}{k} \sum_{i=1}^k POT_s(P_{\tilde{X}_S}, P_{\tilde{X}_T}). \quad (4)$$

3.2.2 类感知样本采样

基于部分最优传输理论构建域间差异损失,为进一步促进最优传输的建立,预先避免由于域间样本类别不一致导致的传输干扰,提出类感知

样本采样方法(Class-aware Sampling, CS),通过显式采样控制每次迭代中批量样本的类别,期望存在相同类别的域间样本,为类级别特征对齐以及建立最优匹配传输奠定基础。首先,在训练过程中利用源域数据训练的分类器 F_φ 计算目标域样本类别的伪标签:

$$\hat{y}_T^i = F(G(x_T^i; \theta); \varphi). \quad (5)$$

随后,根据源域样本对应标签 y_S^i 及生成的目标域伪标签 $\hat{y}_T^i$,在每次迭代数据采样时,预先设定当前批量选取类别集合 $\tilde{C} \subseteq C$,固定类别样本的采样数量并逐一采样,保证源域与目标域在当前迭代时满足样本类别及数量比例相同。

3.2.3 质量分数因子自适应调整

已有基于部分最优传输的方法通常在不同域适应任务中采用显式设置质量分数因子的方式,在模型开始训练前固定因子数值,通过多次训练观测不同质量分数因子下的模型分类效果,确定最优数值^[13]。然而,由于数据集规模不同、分布差异不同,难以预先准确估计质量分数因子的具体选取区间,并且批量采样的训练方式进一步加剧了固定因子数值难以适配到全部最优传输建立的情况,导致分布差异度量准确性严重受到质量分数因子的限制。

为解决以上问题,这里提出一种基于目标域样本分类预测熵可靠性的方法,自适应调整质量分数因子 s 的取值(s -adapt)。假设最优传输映射存在比例受当前批量样本类别匹配度的影响,考虑目标域样本预测伪标签的可信度,将目标域样本分类输出向量的熵正则化结果融入质量分数因子的计算中,每次迭代前更新质量分数因子 s ,实现自适应调整,计算公式如下:

$$s = \exp \left\{ -\frac{1}{k} \sum_{i=1}^k \sum_{j=1}^C -\hat{y}_T^i \log \hat{y}_T^j \right\}, \quad (6)$$

其中: $\hat{y}_T^i$ 表示第 i 个目标域样本属于第 j 个类别的概率。当目标域样本的预测结果稳定到固定类别时, s 趋近于 1,即在类别集合 $\tilde{C}$ 引导下选取目标域样本类别的可信度更高时,提升质量分数因子数值,在更多源域与目标域样本间实现传输,期望在当前迭代中建立全局最优映射。

3.3 优化目标函数

基于深度学习卷积神经网络构建分类模型,

期望在反向传播时更新特征提取器和分类器参数,特征在潜在高维空间实现对齐,在建立损失函数中综合考虑模型分类能力、域特征间分布差异检测能力,对模型训练中建立的各项损失函数进行介绍。

对于特征提取器 G_θ 得到的特征,根据无监督领域自适应泛化误差^[10],需要确保分类器可以对模型挖掘到的域不变特征准确分类。因此,基于交叉熵损失函数 L_{ce} 计算源域样本分类损失:

$$L_{cls}(\tilde{X}_S) = \sum_{i=1}^k l_{ce}(F(G(x_S^i; \theta); \varphi), y_S^i). \quad (7)$$

进一步,采用基于边际差异 MDD 的域差异测度^[14],设置两个分类函数 F_φ, F_ϕ , 计算分类器间对抗损失,利用分类结果一致性损失度量域间差异, $\text{disp}(\cdot)$ 函数表示分类器结果差异,计算公式如下:

$$L_{adv}(\tilde{X}_S, \tilde{X}_T) = \sup \left| \text{disp}_{\tilde{X}_T}(F_\varphi, F_\phi) - \text{disp}_{\tilde{X}_S}(F_\varphi, F_\phi) \right|. \quad (8)$$

结合以上目标函数,模型整体优化问题由三部分组成,分别是源域样本分类损失 L_{cls} 、域间分布差异损失 L_{POT} 以及源分类器间对抗损失 L_{adv} 。整体优化目标函数如下:

$$\min L = L_{cls} + \alpha L_{POT} + \beta L_{adv}, \quad (9)$$

其中: α, β 为平衡因子,平衡各个损失项在模型训练中所占的比例。

4 实验与结果

4.1 数据集

为验证本文模型的有效性,在两组公开高光谱遥感图像数据集上进行实验,包括 Pavia 数据集和 Houston 数据集。

4.1.1 Pavia 数据集

Pavia 数据集^[15]由反射光学光谱传感器 ROSIS 于 2003 年在意大利北部上空采集,其中包含 Pavia University (UP) 和 Pavia Center (PC) 两组数据,波长为 $0.43 \sim 0.86 \mu\text{m}$,空间分辨率为 1.3 m/pixel ,均为城市地图像。UP 数据实验过程中,将 UP 与 PC 分别作为源域与目标域数据,并移除 UP 中最后一个光谱波段,使 UP 与 PC 拥有相同的光谱波段数量,均为 102,同时选取共有的 7 种地物类别用于构建分类模型。伪彩色图

像及对应的地物类别标签如图 2 所示。表 1 显示了 Pavia 数据集中包含的地物类别及对应的样本数量。




图 2 Pavia 数据集的伪彩色图和地物标签

Fig. 2 Pseudocolor images and corresponding ground truths with color indexes of Pavia dataset

表 1 Pavia 数据集中的地物类别及样本数

Tab. 1 Land cover classes and numbers of samples in Pavia dataset

类别	样本数量	
	UP(源域)	PC(目标域)
牧场	18 649	3 090
阴影	947	2 863
砖块	3 682	2 685
沥青道路	6 631	9 248
树木	3 064	7 598
沥青	1 330	7 287
裸露土壤	5 029	6 584
总计	39 332	39 355

4.1.2 Houston 数据集

Houston 数据集^[16]包括 Houston2013 (H13) 与 Houston2018 (H18) 两组数据,由不同传感器于不同年份在美国休斯敦上空采集,空间分辨率分别为 2.5 m/pixel 与 1 m/pixel ,包含波段数量分别为 144 个和 48 个,波长均为 $380 \sim 1\,050 \text{ nm}$ 。实验过程中,将 Houston2013 与 Houston2018 分别作为源域与目标域数据,选取 Houston2013 数据中与 Houston2018 数据相对应的 48 个光谱波段和共有的 7 个类别。伪彩色图像及对应的地物类别标签如图 3 所示。表 2 显示了 Houston 数据集中包含的地物类别及对应的样本数量。




图3 Houston数据集的伪彩色图和地物标签
Fig.3 Pseudocolor images and corresponding ground truths with color indexes of Houston dataset

表 2 Houston 数据集中的地物类别及样本数
Tab.2 Land cover classes and numbers of samples in Houston dataset

类别	样本数量	
	H13(源域)	H18(目标域)
草地	345	1 353
道路	443	6 365
受压草地	365	2 766
水面	285	22
树木	365	2 766
居民建筑	319	5 347
非居民建筑	408	32 459
总计	2 530	53 200

4.2 实验分析

4.2.1 评价指标

为检验本文提出方法的有效性,采用总体精度 (Overall Accuracy, OA)、平均精度 (Average Accuracy, AA) 和 Kappa 系数 3 种指标评价模型的分类性能。其中,OA 计算正确分类样本个数 占所有样本数量的比例,评估模型对数据的整体 分类能力;AA 则分别在每个类别上计算精度,反 映模型对数据中各个类别的分类能力;Kappa 系 数则是基于混淆矩阵计算,用于一致性检验,当 模型出现强偏向性时,计算出的 Kappa 数值降 低,反映模型出现了类别预测偏向性。

4.2.2 实现细节

本文研究基于 Pytorch 框架,利用 Nvidia 2080Ti GPU 实现。在训练集和测试集构建过程

中,为有效利用空间关系信息提高网络特征的提 取能力,在构建样本时,将每个像素本身及其周 围两个像素看作一个样本,即每个样本尺寸均为 5×5 ,通道数为波段数量,样本标签为中心像素 所属类别。模型训练时,为了避免由于样本类别 不平衡导致的分类器偏移,参考 Fang 等^[7]提出模 型中的实验设置,对于有类别标注的源域样本, 在每个类别中随机采样 180 个样本用于模型训 练,而目标域中包含的全部样本均参与随机采 样,训练过程中不使用类别标签。特征提取器 G_θ 由多层卷积神经网络构成,将样本特征映射到 200 维,并利用平均池化及全连接映射将每个样 本表示为 128 维向量,用于后续训练分类网络。 分类网络 F_φ, F_ϕ 均为两层全连接层网络,进行 $128\rightarrow64\rightarrow C$ 过程映射,最终输出地物类别数 长度的向量作为分类结果。采用随机梯度下降 法训练模型,动量因子为 0.9,权重衰减系数为 0.000 5,学习率设置为 0.01,批量采样大小为 64,迭代轮次为 100。在平衡因子 α, β 的选取上, 利用网格搜索法调整参数,在固定其中一个参 数 $\alpha(\beta)$ 时,对另一个参数 $\beta(\alpha)$ 在 $\{0.05, 0.1, 0.5, 1, 5\}$ 内进行调整,选取模型 OA 最高时的参 数值。具体地,对于 Pavia 数据集和 Houston 数 据集,参数 (α, β) 分别设置为 $(1, 0.5)$ 和 $(1, 0.1)$ 时,模型 OA 最优。

4.2.3 分类结果

在 UP $\rightarrow$ PC, Houston2013 $\rightarrow$ Houston2018 两 组域适应迁移任务上进行实验。为验证本文提 出模型的效果,将分类结果与当前已有方法进行 对比,比较方法包括 TSVM^[17], DAN^[18], DANN^[19], ED-DMM-UDA^[20], CDA^[5] 以及 CL- DA^[7]。以上方法的实现细节及结果参照方法 CLDA^[7]文中结果。

两组迁移任务的量化像素级地物分类结果 如表 3 所示。可以看出,基于深度学习的方法优 于传统方法 TSVM,证明了神经网络结构能够有 效挖掘样本特征,基于对抗和散度的方法在高维 空间上对齐源域与目标域,提高了模型适配能 力。对于迁移任务 UP $\rightarrow$ PC,本文方法相较于 TSVM 方法提升 17.64%,相较于采用聚类的方法 ED-DMM-UDA、利用伪标签的方法 CDA、采 用自信学习进一步筛选伪标签的方法 CLDA 在

表 3 目标域上不同方法在 OA、AA 和 Kappa 上的分类结果

Tab. 3 Classification performance on OA, AA (%) and Kappa of different target domains

Method	UP→PC			H13→H18		
	OA (%)	AA (%)	$K(\times 100)$	OA (%)	AA (%)	$K(\times 100)$
TSVM	76.03±0.02	72.41±2.22	70.70±3.05	52.03±0.32	62.40±0.40	34.29±0.80
DAN	80.68±0.02	76.18±1.62	76.47±2.34	61.45±2.18	73.47±1.74	47.08±2.36
DANN	83.90±0.05	78.40±0.47	80.41±0.50	62.61±2.10	65.09±3.54	49.33±1.98
ED-DMM-UDA	82.50±0.50	77.80±0.56	78.73±0.54	66.09±1.83	74.48±1.66	53.10±2.18
CDA	89.78±3.03	88.80±5.05	87.71±3.66	68.44±0.77	75.31±1.58	55.65±0.77
CLDA	92.80±0.67	91.83±1.09	91.32±0.81	70.12±2.43	79.07±0.38	57.75±2.49
Ours	93.67±0.50	94.17±1.06	93.76±0.71	70.25±2.20	79.89±1.06	58.32±1.22

OA 上分别提升 11.7%、3.89% 和 0.87%，相应的 AA 及分类一致性 Kappa 结果同样得到了提升，证明了本文提出的类感知采样方法和随后的质量分数因子自适应调整方法充分利用了伪标签信息，指导域不变特征挖掘，实现了更加精确的类别特征对齐，提升了模型的分类精度。对于迁移任务 H13→H18，虽然本文方法相较于已有方法存在小幅度提升，但在分类精度上仍低于 80%，推测原因是当前源域与目标域的分布差异更为明显，因此从初始训练时取得的目标域样本的伪标签准确度不高，导致其指导的类感知采样及后续质量分数因子调整均受到较多错误标签的影响，建立的传输难以达到最优。从一致性检验系数 Kappa 值可以看出，模型对于分类类别具有较强的倾向性，后续考虑在模型构建中进一步针对各个地物类别特点优化特征提取器和最优传输算法。

图 4 展示了部分已有方法及本文提出方法的像素级地物分类效果。可以看出，本文方法的分类效果更加精细。较为明显的是，对于处于地物不同类别间边缘的像素，本文方法获得了更为清晰的地物轮廓边缘。由于处于边缘的像素通常存在更复杂的空间上下文关系，提取到的特征往往区别于地物中心位置的像素，因此，需要与源域建立更为准确的映射关系。本文提出的基于部分最优传输的域适应方法实现了类别级的样本传输，有助于缓解样本负迁移，提升了分类模型的稳定性。

4.2.4 消融实验

为了验证本文提出的基于部分最优传输的无监督领域自适应高光谱图像分类模型中各个




图 4 不同方法在 PC 数据上的分类效果

Fig. 4 Classification maps of PC dataset produced by different methods

模块的有效性，分别讨论部分最优传输算法 POT、类感知样本采样 CS 以及质量分数因子自适应调整算法 s-adapt 对模型分类的影响。在两组域适应迁移任务 UP→PC, H13→H18 上进行实验，实验结果如表 4 所示。基线方法采用模型中的源域分类损失和双分类器一致性损失进行训练，即式(9)中的 $L_{cls} + L_{adv}$ 。可以看出，相比于基线方法，在模型中加入原始最优传输方法 OT 作为度量函数计算域间差异损失，在两组迁移任务上分别提升 0.5% 和 0.74%。在此基础上，添加类感知采样法 CS 对分类结果进一步提升了

表 4 不同迁移任务消融实验分类结果 OA

Tab. 4 Ablation study classification results of OA with different transfer tasks (%)

Method	UP→PC	H13→H18
baseline	91.46	67.50
+OT	91.96	68.24
+OT+CS	92.85	69.27
+POT($s=0.5$)+CS	93.05	69.43
+POT(s -adapt)+CS	93.67	70.25

0.89% 和 1.03%, 证明了类感知采样方法通过建立特定类别间的传输可以更好地对齐特征。相比于传统 OT 算法, 采用部分最优传输 POT, 即使在固定质量分数因子 $s=0.5$ 的情况下, 模型分类精度仍有提升, 证明 POT 能够避免由于原始强制传输导致的样本错误迁移, 建立更加适宜的传输方案, 提升了模型的适配能力。当运用质量分数因子自适应调整策略 s -adapt 后, 质量分数因子随当前批量传输样本的熵可靠性自适应变化, 相比于固定 $s=0.5$, 分类模型精度分别提升了 0.62% 和 0.82%, 反映出质量分数因子 s 的取值对 POT 传输方案具有重要作用。

参考文献:

- [1] 杨坚华, 张浩, 花海洋. 并行路径与强注意力机制遥感图像建筑物分割[J]. 光学精密工程, 2023, 31(2): 234-245.
YANG J H, ZHANG H, HUA H Y. Parallel path and strong attention mechanism for building segmentation in remote sensing images[J]. *Opt. Precision Eng.*, 2023, 31(2): 234-245. (in Chinese)
- [2] 贾建鑫, 孙海彬, 蒋长辉, 等. 多源遥感数据的道路提取技术研究现状及展望[J]. 光学精密工程, 2021, 29(2): 430-442.
JIA J X, SUN H B, JIANG C H, *et al.* Road extraction technology based on multi-source remote sensing: [J]. *Opt. Precision Eng.*, 2021, 29(2): 430-442. (in Chinese)
- [3] 成丽波, 李昂臻, 贾小宁, 等. 小波多重分形遥感图像混合去噪[J]. 光学精密工程, 2022, 30(15): 1880-1888.
CHENG L B, LI A ZH, JIA X N, *et al.* Removing mixed noise from remote sensing images by wavelet multifractal method [J]. *Opt. Precision Eng.*, 2022, 30(15): 1880-1888. (in Chinese)
- [4] 熊林. 无监督领域自适应目标检测方法研究[D]. 成都: 电子科技大学, 2022.
XIONG L. *Research on Unsupervised Adaptive Target Detection Method*[D]. Chengdu: University of Electronic Science and Technology of China, 2022. (in Chinese)
- [5] LIU Z X, MA L, DU Q. Class-wise distribution adaptation for unsupervised classification of hyper-spectral remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(1): 508-521.
- [6] MIAO J J, ZHANG B, WANG B. Coarse-to-fine joint distribution alignment for cross-domain hyperspectral image classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 12415-12428.
- [7] FANG Z Q, YANG Y X, LI Z K, *et al.* Confident learning-based domain adaptation for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-16.
- [8] LIANG X J, ZHANG Y, ZHANG J P. Attention multisource fusion-based deep few-shot learning for hyperspectral image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 8773-8788.
- [9] MAKAR N, YANG L X, PRASAD S. Adversarial learning based discriminative domain adaptation for geospatial image analysis[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 15: 150-162.
- [10] BEN-DAVID S, BLITZER J, CRAMMER K, *et al.* Analysis of representations for domain adaptation [C]. *Proceedings of the 19th International Conference on Neural Information Processing Systems. December 4-7, 2006, Canada*. New York: ACM, 2006: 137-144.
- [11] VILLANI C. *Optimal Transport: Old and New* [M]. Berlin: Springer, 2009

5 结 论

本文提出基于部分最优传输的无监督领域自适应方法用于高光谱图像分类, 以缓解由于标注数据不足导致的模型训练困难的问题。研究部分最优传输算法在批量采样神经网络训练中的作用、类感知采样方法以及质量分数因子自适应调整算法对建立传输方案的影响, 并在两组公开的高光谱遥感数据上进行实验。实验结果表明, 相比于基线方法, 本文方法建立的分类模型在两组迁移任务上的地物分类结果分别提升 2.21% 和 2.75%, 验证了算法各个模块的有效性。

- [12] PEYRÉ G, CUTURI M. Computational optimal transport: with applications to data science [J]. *Foundations and Trends® in Machine Learning*, 2019, 11(5/6): 355-607.
- [13] NGUYEN K, NGUYEN D, VU-LE T A, *et al.* Improving mini-batch optimal transport via partial transportation [EB/OL]. 2021: *arXiv*: 2108.09645. <https://arxiv.org/abs/2108.09645>.
- [14] ZHANG Y, LIU T, LONG M, *et al.* Bridging theory and algorithm for domain adaptation [EB/OL]. 2019: *arXiv*: 1904.05801. <https://arxiv.org/abs/1904.05801>.
- [15] LICCIARDI G, PACIFICI F, TUIA D, *et al.* Decision fusion for the classification of hyperspectral data: outcome of the 2008 GRS-S data fusion contest[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(11): 3857-3865.
- [16] 2018 IEEE GRSS Data Fusion Contest [OL]. Available: <http://www.grss-ieee.org/community/technical-committees/data-fusion/>
- [17] JOACHIMS T. Transductive inference for text classification using support vector machines [C]. *International Conference on Machine Learning. June 27-30, 1999, Bled, Slovenia*. 1999, 99: 200-209.
- [18] LONG M S, CAO Y, WANG J M, *et al.* Learning transferable features with deep adaptation networks [C]. *Proceedings of the 32nd International Conference on International Conference on Machine Learning-Volume 37. July 6-11, 2015, Lille, France*. New York: ACM, 2015: 97-105.
- [19] GANIN Y, USTINOVA E, AJAKAN H, *et al.* Domain-adversarial training of neural networks[J]. *Advances in Computer Vision and Pattern Recognition*, 2017(9783319583464): 189-209.
- [20] DENG B, JIA S, SHI D M. Deep metric learning-based feature embedding for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(2): 1422-1435.

作者简介:



王碧琳(1995—),女,黑龙江大庆人,博士研究生,2017年于吉林大学获得学士学位,主要从事计算机视觉、迁移学习及最优传输方面的研究。E-mail: blwang19@mails.jlu.edu.cn

通讯作者:



王生生(1974—),男,吉林长春人,教授,博士生导师,1997年、2000年、2003年于吉林大学分别获得学士、硕士和博士学位,主要研究方向为深度学习、计算机视觉及数据挖掘。E-mail: wss@jlu.edu.cn