



武汉大学学报(信息科学版)

Geomatics and Information Science of Wuhan University

ISSN 1671-8860,CN 42-1676/TN

《武汉大学学报(信息科学版)》网络首发论文

题目： 多级空间特征的平衡测度学习遥感图像域适应分类
作者： 董燕妮, 秦学翔, 张玉香, 杜博
DOI: 10.13203/j.whugis20240212
收稿日期: 2024-06-10
网络首发日期: 2024-06-18
引用格式: 董燕妮, 秦学翔, 张玉香, 杜博. 多级空间特征的平衡测度学习遥感图像域适应分类[J/OL]. 武汉大学学报(信息科学版).
<https://doi.org/10.13203/j.whugis20240212>



网络首发: 在编辑部工作流程中,稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定,且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件,可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定;学术研究成果具有创新性、科学性和先进性,符合编辑部对刊文的录用要求,不存在学术不端行为及其他侵权行为;稿件内容应基本符合国家有关书刊编辑、出版的技术标准,正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性,录用定稿一经发布,不得修改论文题目、作者、机构名称和学术内容,只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约,在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版,以单篇或整期出版形式,在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z),所以签约期刊的网络版上网络首发论文视为正式出版。

DOI:10.13203/j.whugis20240212

引用格式：

董燕妮, 秦学翔, 张玉香, 等. 多级空间特征的平衡测度学习遥感图像域适应分类[J]. 武汉大学学报(信息科学版), 2024, DOI: 10.13203/j.whugis20240212 (DONG Yanni, QIN Xuexiang, ZHANG Yuxiang, et al. Balanced Metric Learning in Multilevel Spatial Features for Domain Adaptation in Remote Sensing Image Classification [J]. *Geomatics and Information Science of Wuhan University*, 2024, DOI: 10.13203/j.whugis20240212)

多级空间特征的平衡测度学习遥感图像域适应分类

董燕妮^{1,2}, 秦学翔^{1,2}, 张玉香³, 杜博⁴

1. 湖北珞珈实验室, 湖北 武汉 430079
2. 武汉大学资源与环境科学学院, 湖北 武汉 430079
3. 中国地质大学(武汉) 地球物理与空间信息学院, 湖北 武汉 430074
4. 武汉大学计算机学院, 湖北 武汉 430079

摘要：遥感图像域适应分类通常以光谱特征或简单的空间特征作为数据特征，通过对齐域间的特征分布来标注缺乏标签样本的域。域适应方法忽略了遥感图像更深层的空间特征，导致对空间局部信息的发掘不够；同时，域适应方法很少考虑类别非均衡的问题，导致小类样本的重要性被忽略。针对上述问题，提出了一种多级空间特征的平衡测度学习遥感图像域适应分类方法。首先，通过迭代均值滤波器提取遥感图像更深层的空间特征；然后，构建测度学习来对齐边缘分布，最小化类内距离和类间散度；最后，根据类的先验概率构建自适应权重，最大化平衡类间距离，以缓解类别不平衡的问题。所提方法在 Worldview-2 数据集和 Pavia 数据集上设计了 4 个任务来评估有效性，使用遥感图像分类任务中常用的总体精度、Kappa 系数、可视化结果和时间成本作为评价指标，通过实验分析不同参数对分类结果的影响以及各个组成部分对分类结果的影响。相较于次优的算法，所提方法的总体准确率提高了 1.64%~9.18%，Kappa 系数提高了 0.0231~0.1717。实验结果表明，所提方法不仅通过多级空间特征加强了局部特征的提取和有效利用，还有效缓解了类不平衡问题，使分类器取得了更好的预测效果。

关键词：遥感图像分类，域适应，测度学习，类不平衡，空间特征，多级空间特征

中图分类号：P237

文献标识码：A

Balanced Metric Learning in Multilevel Spatial Features for Domain Adaptation in Remote Sensing Image Classification

DONG Yanni^{1,2}, QIN Xuexiang^{1,2}, ZHANG Yuxiang³, DU Bo⁴

1. Hubei Luojia Laboratory, Wuhan 430079, China

项目资助：湖北珞珈实验室开放基金 (220100058)，国家自然科学基金 (62222116, 62171417)。

第一作者：董燕妮，博士，教授，研究方向为遥感图像智能解译。dongyanni@whu.edu.cn

通信作者：杜博，博士，教授，研究方向人工智能、数据挖掘、模式识别和计算机视觉和图像处理。dubo@whu.edu.cn

2. School of Resource and Environmental Sciences, Wuhan University, Wuhan 430079, China
3. School of Geophysics and Geomatics, China University of Geosciences, Wuhan 430074, China
4. School of Computer Science, Wuhan University, Wuhan 430079, China

Abstract: Objective: Domain adaptation classification of remote sensing images usually takes spectral features or simple spatial features as data features, and labels domains lacking labeled samples by aligning feature distributions among domains. The domain adaptation method ignores the deeper spatial features of remote sensing images, resulting in insufficient exploitation of spatially localized information. At the same time, the domain adaptation method seldom takes into account the problem of class imbalance, which leads to the importance of the small class of samples being ignored. **Methods:** To address the above problems, balanced metric learning in multilevel spatial features for domain adaptation in remote sensing image classification is proposed. First, deeper spatial features of remote sensing images are extracted by an iterative mean filter. Then, metric learning is constructed to align the marginal distributions and minimize the intraclass distance and interclass scatter. Finally, adaptive weights are constructed based on the prior probability of the classes to maximize the balanced interclass distances to alleviate the problem of class imbalance. **Results:** The proposed method first designed four tasks on the Worldview-2 dataset and Pavia dataset to evaluate the effectiveness. Then, the overall accuracy, kappa coefficient, visualization results, and time cost, which are commonly used in remote sensing image classification tasks, are used as the evaluation indicators. Secondly, a series of experiments are carried out to analyze the effects of different parameters on the classification results. Lastly, the individual components on the classification results. Compared with the suboptimal algorithm, the proposed method improves the overall accuracy by 1.64% to 9.18%, and the kappa coefficient by 0.0231 to 0.1717. **Conclusions:** The experimental results show that the proposed method not only enhances the extraction and effective utilization of local features through multilevel spatial features but also alleviates the problem of class imbalance effectively so that the classifier achieves a better prediction result.

Key words: remote sensing image classification, domain adaptation, metric learning, class imbalance, spatial features, multilevel spatial features

遥感图像 (Remote Sensing Image, RSI) 由于具有覆盖范围广、获取方式多样化等特点被广泛地应用在资源调查^[1]、精准农业^[2]等领域。RSI 的标注通常是十分昂贵且耗时的的工作。因此, 通过使用标记完整的域 (源域) 的知识辅助缺乏标记的域 (目标域) 标注的方法是一个重要的研究思路^[3]。传统的分类方法要求源域和目标域独立且同分布。然而, 受成像时间、空间位置等因素的影响, 源域和目标域通常来自不同的分布, 这使得

直接使用传统的方法可能无法达到令人满意的效果。

域适应可以很好地解决上述的问题, 旨在通过减小源域和目标域的特征分布, 实现将从源域的知识迁移到目标域, 从而完成对目标域的标注^[4-6]。迁移成分分析^[7] (Transfer Component Analysis, TCA) 是基于统计特征的域适应最为经典的算法之一, TCA 是以最大均值差异 (Maximum Mean Discrepancy, MMD) 作为度量准则来对齐

源域和目标域的边缘分布。联合分布对齐^[8] (Joint Distribution Adaptation, JDA) 同时对齐源域和目标域的边缘分布和条件分布。在 RSI 的域适应分类中, 图嵌入分布对齐^[9] (Graph Embedding and Distribution Alignment, GEDA) 使用均值滤波器来保存空间特征; 然后, 构建图和域间的类间和类内散度矩阵, 来保留判别信息; 同时, 通过分布对齐和子空间对齐来减小域间的特征差异。空谱加权核流形嵌入分布对齐^[10] (Spectral-Spatial Weighted Kernel Manifold Embedded Distribution Alignment, SSWK-MEDA) 通过使用灵活的均值滤波器

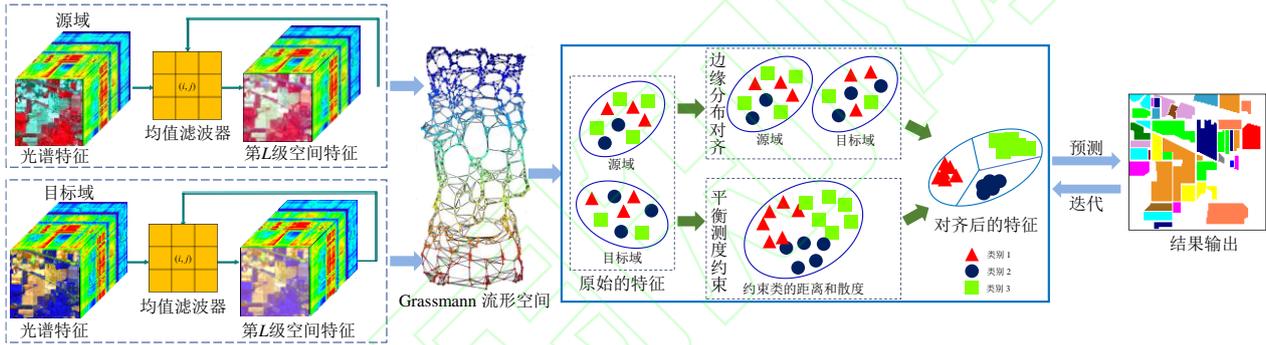


图 1 BML-MSF 流程图

Fig.1 Flowchart of BML-MSF

1 本文方法

BML-MSF 使用均值滤波器去提取空间特征; 接着, 通过迭代这个过程, 来发掘 RSI 更深层的空间邻域关系; 然后, 将得到的空间特征映射到 Grassmann 流形空间中, 一方面通过初步对齐域间的特征分布, 提高伪标签的分类精度; 另一方面利用 Grassmann 空间的几何结构增强测度约束; 接着, 使用 MMD 构建测度学习来约束源域和目标域的边缘分布、类内距离和类间散度; 最后, 根据类的先验概率构建平衡类间距离的权重, 以缓解类不平衡的问题; 本文的主要贡献: 1) 迭代均值滤波器获取多级空间特征, 更好地发掘 RSI 的空间特征; 2) 在构建类间距离的过程中, 添加类先验概率的

来保存局部的空间特征; 然后构建动态的空谱加权核, 实现对空间特征和光谱特征的同时利用; 最后通过 Laplacian 正则项、动态分布对齐等操作, 减小域间的特征差异。现有的方法存在两个缺点: 1) 侧重于处理光谱或简单的空间特征, 缺乏发掘更深层空间特征; 2) 大多数的工作缺乏对类别的非均衡性的处理。

为了更好地解决上述问题, 本文提出了多级空间特征的平衡测度学习 (Balanced Metric Learning in Multilevel Spatial Features, BML-MSF), 提升遥感图像分类的精度和泛化性, 如图 1 所示。

权重, 以缓解类不平衡的问题。

1.1 问题定义

本文的 RSI 域适应分类方法, 基于一个完全标注的源域 $D_s = \{\mathbf{X}_s^{spe}, \mathbf{Y}_s\}$ 和一个完全没有标注的目标域 $D_t = \{\mathbf{X}_t^{spe}\}$, 其中脚标 s 和 t 分别表示源域和目标域。 $\mathbf{X}_{s/t}^{spe} \in \mathbb{R}^{H_{s/t} \times W_{s/t} \times dim}$ 是源域和目标域的图像大小; $\mathbf{Y}_{s/t} \in \mathbb{R}^C$ 是源域和目标域的标签空间, C 代表类别数。其中源域有 n_s 个样本, 目标域有 n_t 个样本。本文的目标是学习一个分类器 f , 利用源域的知识标注目标域的样本^[11-12]。

1.2 多级空间特征的提取

根据地理学第一定律, 地物在空间上存在着相关性^[13-14]。本文遵循这种假设, 首先, 使用 3×3 的均值滤波器提取源域和目标域的空间特征, 得到第一级的空间特征; 然后, 在第一级空间特征的基础上, 再次使用均值

滤波器，得到第二级的空间特征；最后，迭代这个过程获得第 L 级空间特征，以保存局部的空间信息。这个过程如图 2 所示。第 L 级空间特征被称为多级空间特征。在后续工

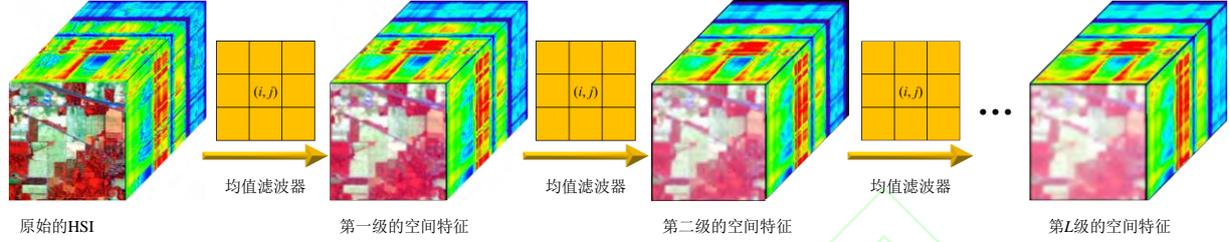


图 2 多级空间特征提取

Fig.2 Extraction of Multilevel Spatial Features

1.3 Grassmann 流形映射

Grassmann 流形空间的几何结构能够有效地对齐域间的特征分布。因此，本文通过测地线流式核^[15] (Geodesic Flow Kernel, GFK) 将 \mathbf{X}_s^{spa} 和 \mathbf{X}_t^{spa} 映射到 Grassmann 空间中,具有良好的分类性能和较低的时间成本,这有助于提高伪标签的分类精度和节省时间成本。关于更多的内容,请参考原始论文。在这里,仅介绍 GFK 的主要思想:

首先,使用 PCA 构建源域和目标域的子空间 \mathbf{P}_s 和 $\mathbf{P}_t \in \mathbb{R}^{dim \times d}$, 同时, \mathbf{P}_s 和 \mathbf{P}_t 被视为 Grassmann 流形空间中的两个点 $\Phi(0)$ 和 $\Phi(1)$; 然后,去寻找源域和目标域两点之间的测地线 $\{\Phi(t): 0 \leq t \leq 1\}$, 实现将 $\Phi(0)$ 变换到 $\Phi(1)$ 。这条测地线通过积分和核技巧获得测地线流式核 \mathbf{G} :

$$\langle z_i, z_j \rangle = \int_0^1 (\Phi(t)^T \mathbf{x}_i)^T (\Phi(t)^T \mathbf{x}_j)^T dt = \mathbf{x}_i^T \mathbf{G} \mathbf{x}_j^T \quad (1)$$

最后,通过 $\mathbf{z} = \mathbf{g}(\mathbf{x}) = \sqrt{\mathbf{G}}\mathbf{x}$ 将原始空间的特征变换到 Grassmann 流形空间中。

在本文中,通过公式(1)得到多级空间特征的测地线式核 \mathbf{G}^{spa} ; 然后,通过使用 $\mathbf{Z}^{spa} = \sqrt{\mathbf{G}^{spa}} \mathbf{X}^{spa}$ 将 \mathbf{X}_s^{spa} 和 \mathbf{X}_t^{spa} 映射到 Grassmann 流形空间中,以得到流形空间中源域和目标域的流形多级空间特征 \mathbf{Z}_s^{spa} 和 \mathbf{Z}_t^{spa} 。

1.4 测度学习

在域适应分类任务中,本文的目标是获得一个分类器 f , 将源域的知识迁移到目标

域中,多级空间特征是要去处理的对象。为了方便,本文使用 \mathbf{X}_s^{spa} 和 \mathbf{X}_t^{spa} 来表示源域和目标域的多级空间特征。

域,实现对目标域样本的标注。因此,对于分类任务来说,构建测度学习,来约束类的距离是重要的。

在构建测度学习时,目标域被要求具有完全的标注,这与目标域缺乏标注的实际相违背。因此,本文参考[16]的工作,通过使用简易的分类器——最近邻分类器 1NN (K-Nearest Neighbors, K=1), 为目标域构建伪标签。这个简易的分类器被要求具有一定的分类精度和较低的时间成本。

1) 最小化边缘分布

测度学习的第一个目标就是最小化边缘分布,这里参考 TCA^[7], 构建了边缘分布,使得源域和目标域在整体上更相似。边缘分布的约束为

$$\mathbf{M}_f(\mathbf{Z}_s^{spa}, \mathbf{Z}_t^{spa}) = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \beta^T k_i - \frac{1}{n_t} \sum_{j=1}^{n_t} \beta^T k_{n_s+j} \right\|_{\mathbf{H}_K}^2 \quad (2)$$

$$= \text{tr}(\beta^T \mathbf{K} \mathbf{M} \mathbf{K} \beta)$$

这里的 \mathbf{H}_K 代表再生核希尔伯特空间, $\mathbf{K} \in \mathbb{R}^{(n_s+n_t) \times (n_s+n_t)}$ 是核函数, $\beta \in \mathbb{R}^{(n_s+n_t) \times C}$ 是核函数 \mathbf{K} 的系数向量, $\text{tr}(\cdot)$ 代表矩阵的迹, \mathbf{M} 是边缘分布系数矩阵:

$$(\mathbf{M})_{ij} = \begin{cases} \frac{1}{(n_s)^2}, & z_i, z_j \in \mathbf{Z}_s^{spa} \\ \frac{1}{(n_t)^2}, & z_i, z_j \in \mathbf{Z}_t^{spa} \\ -\frac{1}{n_s n_t}, & z_i \in \mathbf{Z}_s^{spa}, z_j \in \mathbf{Z}_t^{spa} \end{cases} \quad (3)$$

2) 最小化类内距离

测度学习的第二个目标是最小化类内距离，这里参考 JDA^[8]，构建了类内距离，使得两个域的同类样本更加相似。类内距离的约束为

$$\mathbf{N}_f(\mathbf{Z}_s^{spa}, \mathbf{Z}_t^{spa}) = \sum_{c=1}^C \left\| \frac{1}{n_s^c} \sum_{x_i \in (\mathbf{Z}_s^{spa})^c} \beta^T k_i - \frac{1}{n_t^c} \sum_{x_j \in (\mathbf{Z}_t^{spa})^c} \beta^T k_j \right\|_{\mathbf{H}_K}^2 \quad (4)$$

$$= \text{tr}(\beta^T \mathbf{K} \mathbf{N}_a \mathbf{K} \beta)$$

这里的 n_s^c 表示源域第 c 类样本数量， n_t^c 表示目标域第 c 类样本数量， \mathbf{N}_a 是类内距离系数矩阵：

$$(\mathbf{N}_a)_{ij}^c = \begin{cases} \frac{1}{(n_s^c)^2}, & z_i, z_j \in (\mathbf{Z}_s^{spa})^c \\ \frac{1}{(n_t^c)^2}, & z_i, z_j \in (\mathbf{Z}_t^{spa})^c \\ -\frac{1}{n_s^c n_t^c}, & \begin{cases} z_i \in (\mathbf{Z}_s^{spa})^c, & z_j \in (\mathbf{Z}_t^{spa})^c \\ z_i \in (\mathbf{Z}_t^{spa})^c, & z_j \in (\mathbf{Z}_s^{spa})^c \end{cases} \\ 0, & \text{otherwise} \end{cases} \quad (5)$$

3) 最大化平衡类间距离

测度学习的第三个目标是最大化类间距离，这里参考无监督度量转移学习^[17]

(Unsupervised Metric Transfer Learning, UTML)，构建了类间距离，使得两个域的异类样本更加不相似。此外，类的非均衡性问题普遍存在于分类任务中。本文参考[18]的思想，通过类先验构建了平衡类间距离的权重，以缓解类非均衡的影响。平衡类间距离的约束为

$$\mathbf{N}_f(\mathbf{Z}_s^{spa}, \mathbf{Z}_t^{spa}) = \sum_{c=1}^C \left\| \frac{\sqrt{p^c}}{n^c} \sum_{x_i \in (\mathbf{Z}_s^{spa})^c} \beta^T k_i - \frac{\sqrt{p^c}}{n^c} \sum_{x_j \in (\mathbf{Z}_t^{spa})^c} \beta^T k_j \right\|_{\mathbf{H}_K}^2 \quad (6)$$

$$= \text{tr}(\beta^T \mathbf{K} \mathbf{N}_e \mathbf{K} \beta)$$

这里的 n 代表源域和目标域的所有样本量； n^c 表示所有样本中第 c 类的样本量， $n^{\tilde{c}}$ 表示所有样本中非第 c 类的样本量；其中 p^c 和 $p^{\tilde{c}}$ 是由类先验概率构建的权重：

$$p^c = \frac{n^c}{n} \quad (7)$$

$$p^{\tilde{c}} = \frac{n^{\tilde{c}}}{n} \quad (8)$$

类先验概率能够帮助更好地拟合类间矩阵 \mathbf{N}_e ：

$$(\mathbf{N}_e)_{ij}^c = \begin{cases} \frac{p^c}{(n^c)^2}, & z_i^{spa}, z_j^{spa} \in (\mathbf{Z}^{spa})^c \\ \frac{p^{\tilde{c}}}{(n^{\tilde{c}})^2}, & z_i^{spa}, z_j^{spa} \notin (\mathbf{Z}^{spa})^c \\ \frac{\sqrt{p^c} \sqrt{p^{\tilde{c}}}}{n^c n^{\tilde{c}}}, & \begin{cases} z_i^{spa} \in (\mathbf{Z}^{spa})^c, & z_j^{spa} \notin (\mathbf{Z}^{spa})^c \\ z_i^{spa} \notin (\mathbf{Z}^{spa})^c, & z_j^{spa} \in (\mathbf{Z}^{spa})^c \end{cases} \end{cases} \quad (9)$$

4) 最大化类间散度

测度学习的第四个目标是最大化类间散度，本文基于 MMD 的思想构建了类间散度，使得两个域的异类样本更加分散。类间散度的约束为

$$\mathbf{H}_f(\mathbf{Z}_s^{spa}, \mathbf{Z}_t^{spa}) = \frac{1}{C} \sum_{c=1}^C \left\| \frac{1}{n^c} \sum_{x_i \in (\mathbf{Z}_s^{spa})^c} \beta^T k_i - \frac{1}{n} \sum_{x_j \in \mathbf{Z}^{spa}} \beta^T k_j \right\|_{\mathbf{H}_K}^2 \quad (10)$$

$$= \text{tr}(\beta^T \mathbf{K} \mathbf{H} \mathbf{K} \beta)$$

其中， \mathbf{H} 是类间散度的系数矩阵：

$$\mathbf{H} = \frac{1}{C} \sum_{c=1}^C \left(\frac{1}{n^c} \mathbf{1} \mathbf{1}^T - \frac{1}{n} \mathbf{1} \mathbf{1}^T \right) \quad (11)$$

这里的 $\mathbf{1}_n^c \in \mathbb{R}^{n \times 1}$ 是指示向量，若第 i 个样本属于第 c 类，则 $\mathbf{1}_n^c(i)$ 为 1，否则 $\mathbf{1}_n^c(i)$ 为 0；这里的 $\mathbf{1} \in \mathbb{R}^{n \times 1}$ 是元素全为 1 的指示向量。

1.5 分类器构建

在多级空间特征提取、流形特征学习和测度学习之后，并构建源域的结构风险最小化，得到分类器 f ：

$$f = \arg \min_{f \in \mathbf{H}_K} \sum_{i=1}^{n_s} (y_i - f(z_i^{spa}))^2 + \eta \|f\|_{\mathbf{K}}^2 + \lambda \mathbf{M}_f(\mathbf{Z}_s^{spa}, \mathbf{Z}_t^{spa}) + \alpha \mathbf{N}_f(\mathbf{Z}_s^{spa}, \mathbf{Z}_t^{spa}) - \rho \mathbf{H}_f(\mathbf{Z}_s^{spa}, \mathbf{Z}_t^{spa}) \quad (12)$$

根据表征定理^[19]，将公式(12)改写成

$$f = \arg \min_{f \in \mathbf{H}_K} \left\| (\mathbf{Y} - \beta^T \mathbf{K}) \mathbf{A} \right\|_F^2 + \eta \text{tr}(\beta^T \mathbf{K} \beta) + \lambda \text{tr}(\beta^T \mathbf{K} \mathbf{M} \mathbf{K} \beta) + \alpha \text{tr}(\beta^T \mathbf{K} (\mathbf{N}_a - \mathbf{N}_e) \mathbf{K} \beta) - \rho \text{tr}(\beta^T \mathbf{K} \mathbf{H} \mathbf{K} \beta) \quad (13)$$

公式(12)和公式(13)中的各项对应。其中， $\mathbf{A} \in \mathbb{R}^{(n_s+n_t) \times (n_s+n_t)}$ 是指示矩阵，若是源域的第 i 个样本，则 $\mathbf{A}_{ii}=1$ ；否则 $\mathbf{A}_{ii}=0$ ；其中 $\mathbf{Y} = [y_1, \dots, y_{n_s+n_t}] \in \mathbb{R}^{(n_s+n_t) \times C}$ 是标签矩阵。

计算公式(13)的 $\partial f / \partial \beta = 0$ ，得到分类器 $f = \mathbf{K} \left((\mathbf{A} + \lambda \mathbf{M} + \alpha (\mathbf{N}_a - \mathbf{N}_e) - \rho \mathbf{H}) \mathbf{K} + \eta \mathbf{I} \right)^{-1} \mathbf{A} \mathbf{Y}^T$ (14)

这里的 $\mathbf{I} \in \mathbb{R}^{(n_s+n_t) \times (n_s+n_t)}$ 是单位矩阵，最后得到的分类器 $f \in \mathbb{R}^{(n_s+n_t) \times C}$ 。

分类器 f 的行代表样本，列代表类别。矩阵中的元素代表样本属于该类的可能性。本文将每个样本中可能性最大的类别作为其标签，从而实现对目标域的标注。由于伪标签的使用降低了分类器的分类精度，因此，本文通过迭代测度学习提高分类精度。

2 实验结果与分析

2.1 数据介绍

1) Worldview-2 数据集：该数据集由 Worldview-2 卫星获取的 2011 年 2012 年的武汉。该数据集涵盖了波长为 400-1040 纳米的 8 个波段，大小为 200×200 ，空间分辨率为 1.8 米。本文依据获取时间的差异，将 Worldview-2 数据集划分成“2011”和“2012”。图 3 显示了 2011 和 2012 的假彩色图像 (R:

5, G: 3, B: 2) 和真实地物图。本文选择了 Worldview-2 数据集共有的 4 个类别进行实验，表 1 中列出了对应的类别、样本量以及每个类别在各自域中所占的比例。

2) Pavia 数据集^[20]：该数据集是由 ROSIS-03 传感器采集于的帕维亚中心 (Pavia Center, PC) 和帕维亚大学 (Pavia University, PU) 两个区域的图像。该数据集涵盖了波长为 400-1040 纳米的 102 个波段。两张图像的大小为 150×150 ，空间分辨率为 1.3 米。图 4 显示了图像的假彩色图像 (R: 85, G: 45, B: 10) 和真实地面图。本文依据图像采集位置的差异，将 Pavia 数据集划分为“PC”和“PU”两个区域。本文选择了两个区域共有的 4 个类别进行实验，表 2 中列出了对应的类别、样本量，以及每类在各自域中所占的比例。

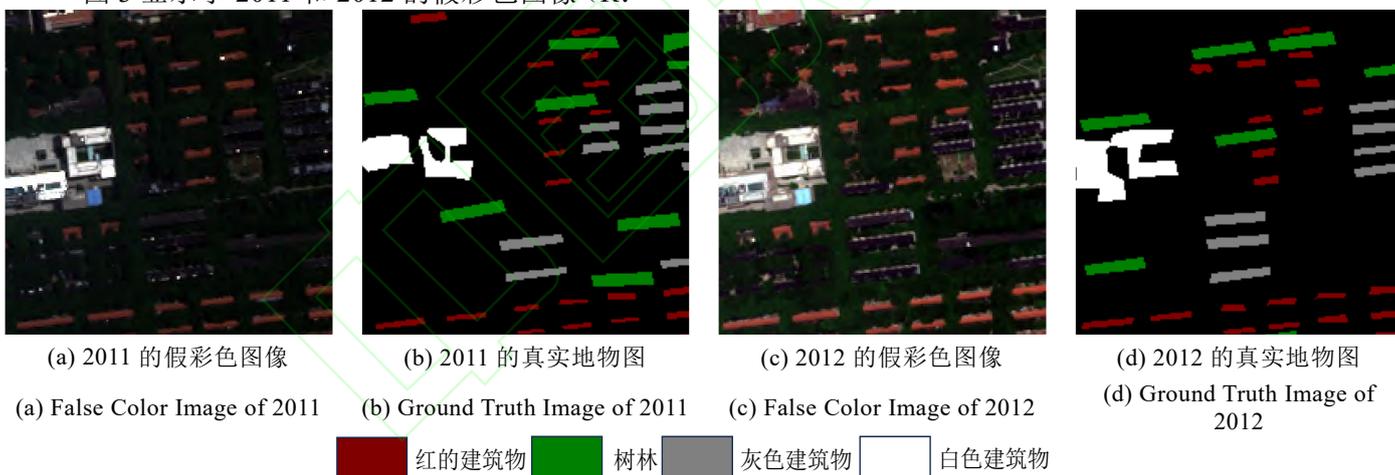
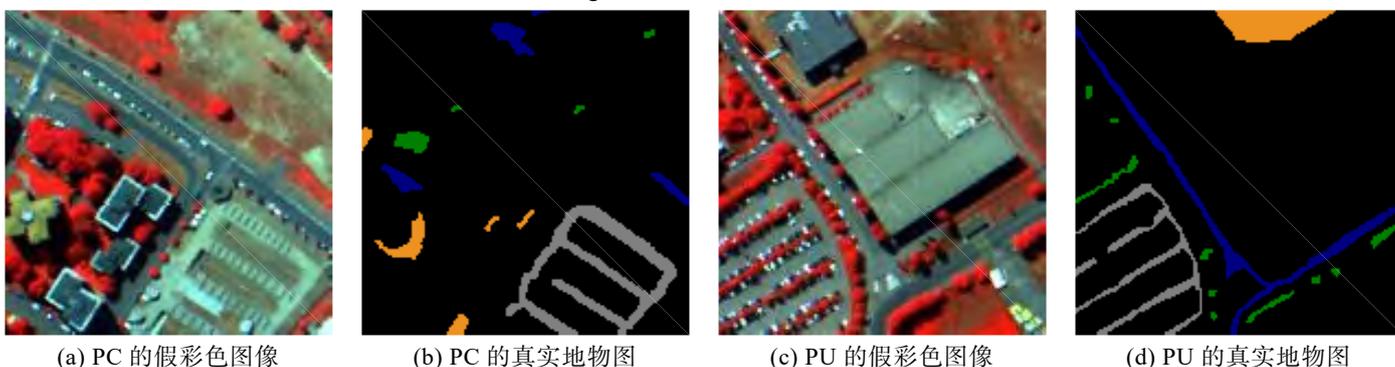


图 3 Worldview-2 数据集

Fig.3 Worldview-2 Dataset



(a) PC 的假彩色图像

(b) PC 的真实地物图

(c) PU 的假彩色图像

(d) PU 的真实地物图

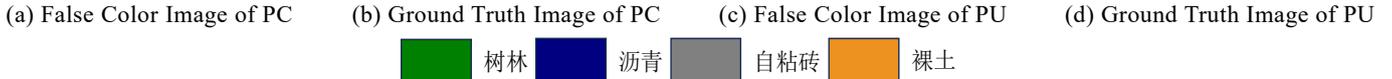


图 4 Pavia 数据集

Fig.4 Pavia Dataset

表 1 Worldview-2 数据真实地物样本信息

Table 1 Ground Truth of Main Classes on Worldview-2

标签	类别	2011(比例)	2012(比例)
1	红色建筑物	1035(19.47%)	1285(23.69%)
2	树林	1816(34.15%)	1476(27.20%)
3	灰色建筑物	1290(24.26%)	1213(22.36%)
4	白色建筑物	1176(22.12%)	1451(26.75%)
合计		5317(100.00%)	5425(100.00%)

表 2 Pavia 数据真实地物样本信息

Table 2 Ground Truth of Main Classes on Pavia

标签	类别	PC(比例)	PU(比例)
1	树林	153(7.53%)	276(11.39%)
2	沥青	355(17.47%)	815(33.64%)
3	自粘砖	1213(59.69%)	704(29.05%)
4	裸土	311(15.31%)	628(25.92%)
合计		2032(100.00%)	2423(100.00%)

2.2 实验结果

为了更好地去验证 BML-MSF 的有效性，本文在 Worldview-2 和 Pavia 两个数据集上设计了四个域适应的任务，以尽可能去接近现实的场景：“2011->2012”、“2012->2011”、“PC->PU”和“PU->PC”。其中“->”的前

部代表源域，后部代表目标域。本文选择了分类任务中常见的定量指标：整体精度^[21-22] (Overall Accuracy, OA)、kappa 系数^[23-24]、定性评价^[25-26]和时间消耗^[27]。

七个优异的域适应算法 GFK^[15]、JDA^[8]、深度相关性对齐^[28] (Deep coral)、流形嵌入分布对齐^[29] (Manifold Embedded Distribution Alignment, MEDA)、UTML^[17]、GEDA^[9]和 SSWK-MEDA^[10]被选择作为对比算法。其中，JDA 和 UTML 是较为经典的域适应的方法；Deep coral 是一个较为经典的深度域适应方法；GFK、MEDA 和 SSWK-MEDA 是与 BML-MSF 直接相关的域适应方法；GEDA 和 SSWK-MEDA 是在遥感图像分类中较为新颖的域适应方法。

从表 3 和表 4 中，可以明显观测到 BML-MSF 与所有的对比方法相比，都展现出了最好的分类性能。同经典的域适应方法 JDA、UTML 和经典深度域适应方法 Deep coral 方法相比，空间特征、流形特征能够显著地提升分类精度；与 GFK 和 MEDA 相比，测度约束和类不平衡的权重也可以很好地提升分类精度。GEDA 和 SSWK-MEDA 两个遥

表 3 BML-MSF 在不同任务上的 OAs(%)

Table 3 OAs(%) of BML-MSF on Different Tasks

数据集	任务	GFK	JDA	Deep coral	MEDA	UTML	GDEA	SSWK-MEDA	BML-MSF
Worldview-2	2011->2012	62.38	91.10	97.64	87.28	84.87	95.52	94.69	97.16
	2012->2011	50.12	80.91	97.07	86.36	73.26	96.85	96.18	98.93
Pavia	PC->PU	39.00	44.28	42.37	44.86	46.14	69.09	77.61	86.79
	PU->PC	13.63	48.72	66.12	76.72	49.80	82.04	40.73	84.65

表 4 BML-MSF 在不同任务上的 kappa

Table 4 Kappa of BML-MSF on Different Tasks

数据集	任务	GFK	JDA	Deep coral	MEDA	UTML	GDEA	SSWK-MEDA	BML-MSF
-----	----	-----	-----	------------	------	------	------	-----------	---------

Worldview-2	2011->2012	0.5006	0.8809	0.9684	0.8292	0.7967	0.9389	0.9289	0.9620
	2012->2011	0.3612	0.7438	0.9602	0.8153	0.6405	0.9578	0.9482	0.9855
Pavia	PC->PU	0.1625	0.2280	0.2255	0.2407	0.2590	0.5723	0.6274	0.8173
	PU->PC	-0.0169	0.2657	0.4776	0.6120	0.2864	0.7023	0.1822	0.7307

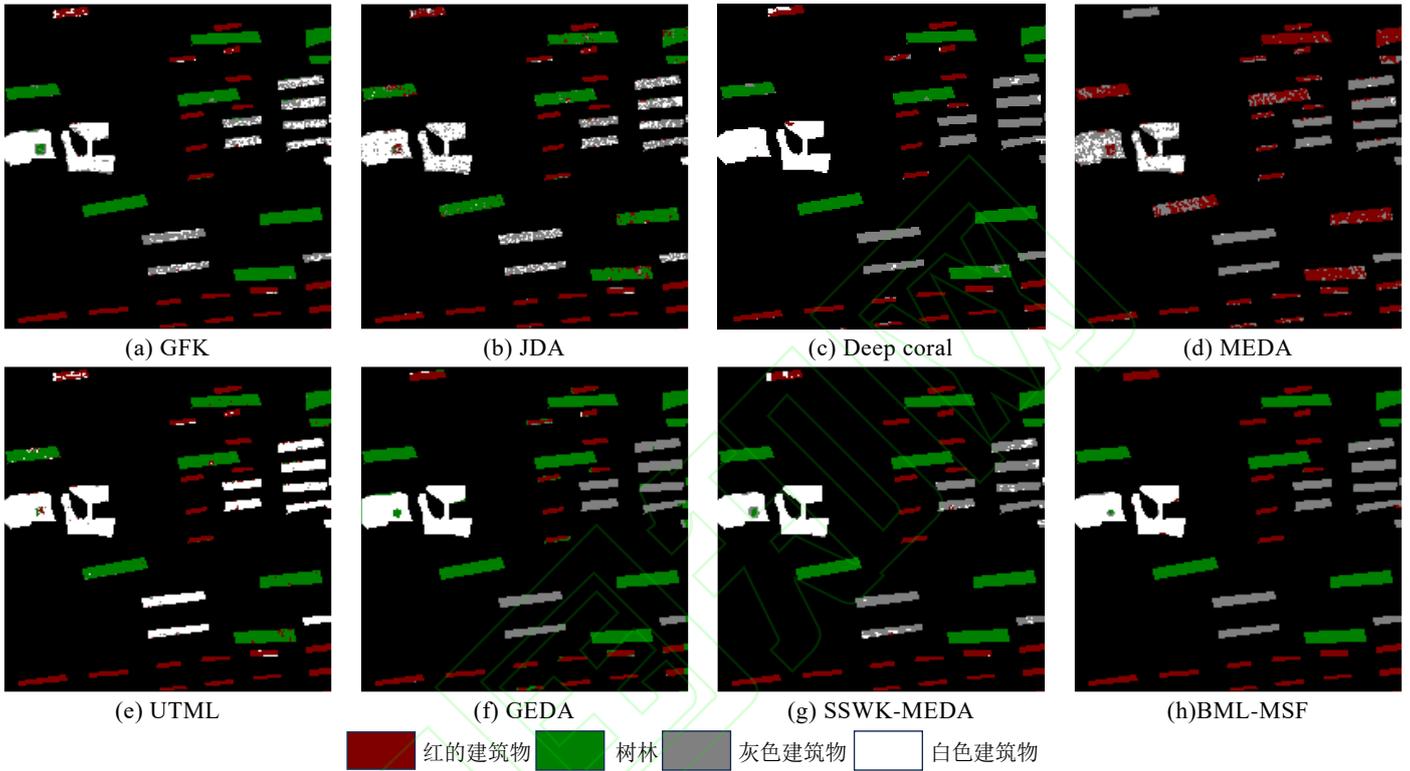
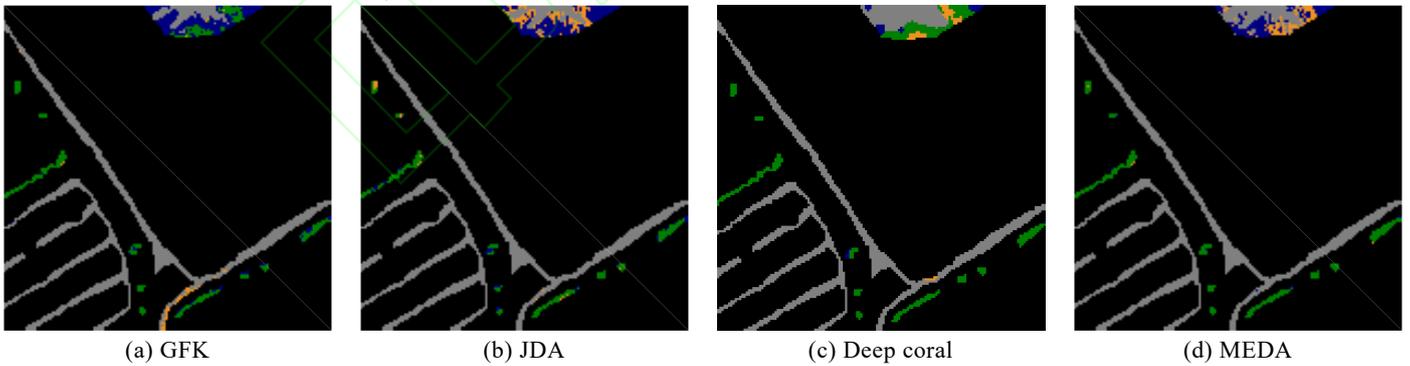


图 5 Worldview-2 数据集 2011 部分的预测标签

Fig.5 Predicted Labels of the 2011 Part of the Worldview-2 Dataset



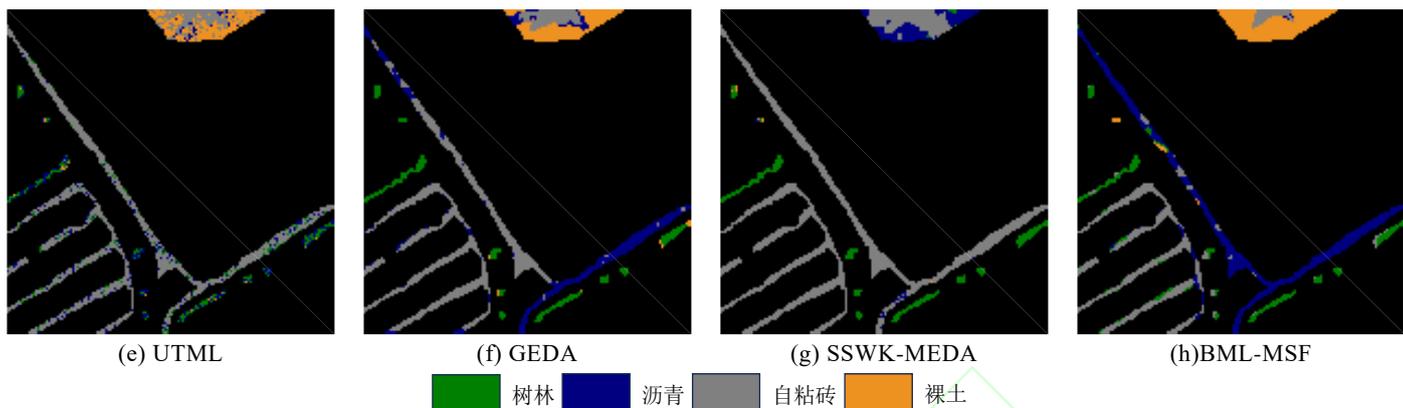


图 6 Pavia 数据集 PU 部分的预测标签
Fig.6 Predicted Labels of the PU Part of the Pavia Dataset

感图像分类中较为新颖的算法，同 BML-MSF 相比，说明遥感图像的多级空间特征对于提升分类精度是十分有益的。BML-MSF 和次优的结果相比，在 OA 上提升了 1.64%-9.18%，kappa 提升了 0.0231-0.1717。在“2012->2011”任务中，尽管 GEDA 的分类精度已经高达 96.85%和 0.9578，BML-MSF 仍然能够将精度进一步提升到 98.93%和 0.9855。在“PC->PU”任务中，BML-MSF 和 SSWK-MEDA 相比进一步地提升了高达 9.18%和 0.1899。这些精度地提升能够充分地证明 BML-MSF 的有效性。

在图 5 中，本文展示了“2012->2011”任务中，使用 2012 年的知识辅助 2011 年的预测结果，可以明显地观测到 BML-MSF 分类精度最高，仅仅只有少量的白色区块被误分为其他类别。其他的地物在可视化结果中，并没有观测到分类错误。

在图 6 中，本文展示了“PC->PU”任务中，使用 PC 的知识辅助 PU 的预测结果，可以清晰地观测到 BML-MSF 分类结果最好，结果图中的颜色混乱度明显的优于其他的方法，特别在蓝色区块和橙色区块的正确率要明显地优于其他的算法。

2.3 参数分析

1) 多级空间特征的级数

多级空间特征的级数 L 对分类精度有着重要的影响。图 7 展示了 1-5 级空间特征对 OA 的影响。在图 7 中，可以明显地观测到，

Worldview-2 数据集的分类结果受多级空间特征的级数影响较小，整体趋于平缓，有着小幅的上升；而 Pavia 数据集的分类结果，伴随着级数的改变有着明显的变化，呈现出先上升后下降的趋势，峰值出现在 $L=4$ 的位置。因此，本文将所有任务的分类结果和多级空间特征的级数的变化情况，统一的将级数 L 设置为 4。 $L=4$ 的级数设置，一方面所有的任务都具有良好的分类表现，另一方面，可以有效地减少需要调节的超参数。

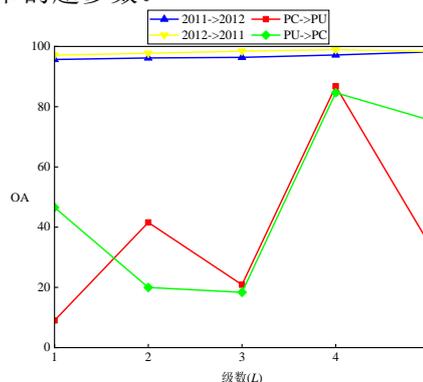


图 7 BML-MSF 在不同 L 取值的 OA
Fig.7 OAs of BML-MSF under Different Values L

2) 核函数

本文选择了径向基函数作为核函数，为了减少调节的参数，核函数的带宽被设置为 1。

3) 迭代次数

测度学习的构建依赖于伪标签，而伪标签会严重影响分类精度。因此，本文通过迭代测度学习来消除伪标签的影响。为了进行公平的比较，所有任务的迭代次数被统一设置为 5。

4) 维度参数

当使用 GFK 将多级空间特征映射到 Grassmann 空间时, 需要通过 PCA 降维, 创建源域和目标域的子空间。因此, 维度参数 d 对 BML-MSF 的分类性能有着重要的影响。由于 GFK 的计算要求, d 最多是原始维度的一半。因此, Worldview-2 数据集的 d 被设置为 1-4, 步长为 1; Pavia 数据集的 d 被设置为 5-50, 步长为 5。图 8 展示了 Worldview-2 数据集的 d 对 OA 的影响; 图 9 展示了 Pavia 数据集的 d 对 OA 的影响。在图 8 中, 可以观测到在

“2011->2012”的任务中, 分类结果伴随着维度参数的增加而增加, 在“2012->2011”的任务中, 在前期有一个下降, 后期又呈现上升的状态, Worldview-2 数据集的分类结果的整体趋势是伴随着维度参数的增加而增加。因此, Worldview-2 数据集的维度参数 d 被统一的设置 4。在图 9 中, 可以明显地观察到 Pavia 数据集的分类结果受维度参数的影响较大, 波动的状态较为明显。在“PC->PU”和“PU->PC”的任务中, 前期均呈现一个明显地下降, 又急

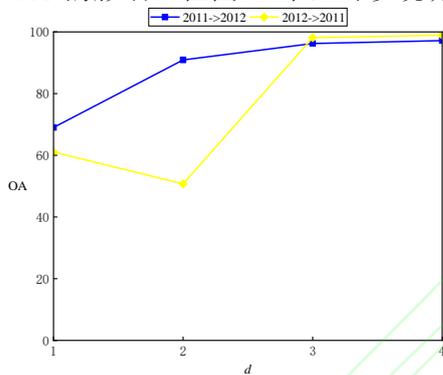


图 8 不同 d 值下 Worldview-2 的 OA

Fig.8 OAs of Worldview-2 under Different Values of d

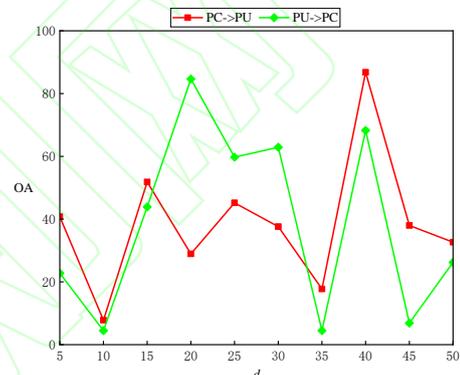
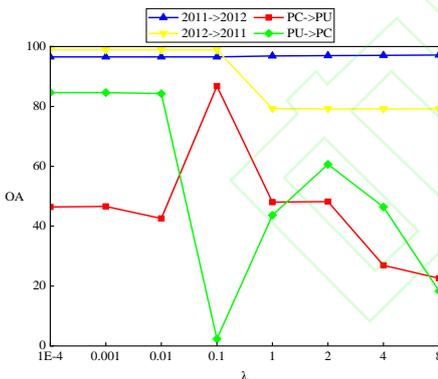


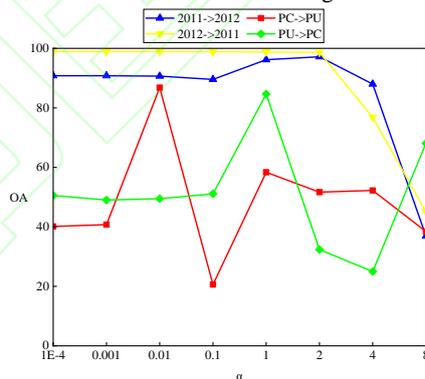
图 9 不同 d 值下 Pavia 的 OA

Fig.9 OAs of Pavia under Different Values of d



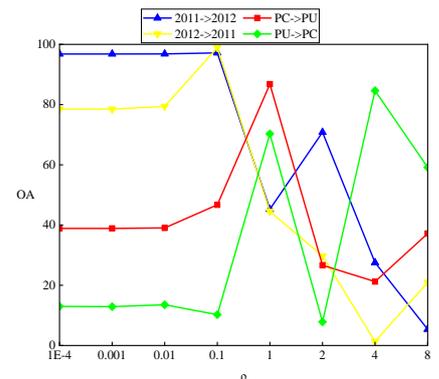
(a) 不同 λ 取值下的 OA

(a) OAs under Different Values of λ



(b) 不同 α 取值下的 OA

(b) OAs under Different Values of α



(c) 不同 ρ 取值下的 OA

(c) OAs under Different Values of ρ

图 10 不同正则化数值下的 BML-MSF 的 OA

Fig.10 OAs of BML-MSF with Different Regularization Values

剧地攀升, 然后再呈现逐步地下降和急剧的上升。从图 9 中可以观察到, “PC->PU”和“PU->PC”任务的最优值在不同的位置。因此, 在“PC->PU”的任务中, 维度参数 d 被设置为 40; 在“PU->PC”的任务中, 维度参数 d 被设置为 20。

5) 正则化参数

BML-MSF 的正则化参数 η 、 λ 、 ρ 、 α 在 0.0001, 0.001, 0.01, 0.1, 1, 2, 4, 8 的范围选择最优的参数; 为了减少调整的参数, η 被统一的设置为 0.0001。在图 10 中, 本文展示了正则化参数对 OA 的影响。

在图 10 (a)中, 本文展现了两个数据集的四个任务受正则化参数 λ 的变化情况。在 Worldview-2 数据集中, “2011->2012”受 λ 的影响较小, 基本不受 λ 变化的影响。

“2012->2011”前期呈现平稳的状态, 后有小幅的下降后期呈现平稳的状态。Pavia 数据集受 λ 的影响很大, 在 “PC->PU”任务中, 前期较为平稳, 后期迅速的攀升又急剧的下降, 在 “PU->PC”任务中, 前期也较为平缓后急需下降, 后期又迅速上升。

在图 10 (b)中, 本文展现了两个数据集的四个任务受正则化参数 α 的变化情况。在 Worldview-2 数据集中, 两个任务均呈现出前期呈现较为平缓, 后期呈现明显的下降趋势。在 Pavia 数据集中, 在 “PC->PU”任务中, 前期较为平稳, 后迅速的攀升又急剧的下降, 后期又呈现上升的状态; 在 “PU->PC”任务中, 前期上升的较为快速, 后期又迅速地下降, 然

后有小幅的上升。

在图 10 (c)中, 本文展现了两个数据集的四个任务受正则化参数 ρ 的变化情况。不论是 Worldview-2 数据集, 还是 Pavia 数据集都受 ρ 的变化影响较大。Worldview-2 数据集的前期都较为平稳, 后期呈现逐步的下降状态; 在 Pavia 数据集的两个任务存在多个波峰和波谷, 波动十分剧烈。

从图 10 中, 可以明显地观察到 λ 、 α 、 ρ 受取值的影响较大。因此, 不同的任务需要被设置为不同的参数, 在 “2011->2012”中, λ 设置为 8, α 设置为 2, ρ 设置为 0.1; 在 “2012->2011”中, λ 设置为 0.0001, α 设置为 0.0001, ρ 设置为 0.1; 在 “PC->PU”中, λ 设置为 0.1, α 设置为 0.01, ρ 设置为 1; 在 “PU->PC”中, λ 设置为 0.0001, α 设置为 1, ρ 设置为 4。

表 5 “2011->2012”任务不同组成部分的 OAs(%)

Table 5 OAs(%) for Different Components of the “2011->2012” Task

类别	光谱特征+MF	MSF		MSF+MF				BML
	BML	BML	M	M-N _e	M+N _a	M+(N _a -N _e)	M+(N _a -BN _e)	
红色建筑物	90.04	99.92	98.21	98.60	98.21	100.00	98.75	99.53
树林	99.80	100.00	81.30	82.59	81.30	98.58	100.00	100.00
灰色建筑物	85.08	87.88	65.95	66.45	65.95	76.26	87.22	87.22
白色建筑物	99.17	99.72	99.93	99.86	99.93	99.59	99.86	99.86

表 6 “2012->2011”任务不同组成部分的 OAs(%)

Table 6 OAs(%) for Different Components of the “2012->2011” Task

类别	光谱特征+MF	MSF		MSF+MF				BML
	BML	BML	M	M-N _e	M+N _a	M+(N _a -N _e)	M+(N _a -BN _e)	
红色建筑物	96.62	99.81	96.81	99.90	99.61	99.90	99.71	99.90
树林	99.12	100.00	55.07	100.00	92.13	100.00	99.50	100.00
灰色建筑物	97.44	99.07	82.71	98.22	99.07	97.44	99.30	99.15
白色建筑物	88.10	96.85	93.54	93.28	95.66	95.49	95.49	96.17

表 7 “PC->PU”任务不同组成部分的 OAs(%)

Table 7 OAs(%) for Different Components of the “PC->PU” Task

类别	光谱特征+MF	MSF		MSF+MF				BML
	BML	BML	M	M-N _e	M+N _a	M+(N _a -N _e)	M+(N _a -BN _e)	
树林	94.20	96.74	90.94	85.51	90.94	96.01	0.00	81.52

沥青	38.65	0.00	0.00	72.15	0.00	0.00	52.02	90.67
自粘砖	87.36	99.72	100.00	66.05	100.00	99.29	74.57	87.07
裸土	91.88	98.73	0.00	41.08	0.00	88.85	55.73	83.76

表 8 “PU->PC”任务不同组成部分的 OAs(%)

Table 8 OAs(%) for Different Components of the “PU->PC” Task

类别	光谱特征+MF	MSF	MSF+MF					
	BML	BML	M	M-N _e	M+N _a	M+(N _a -N _e)	M+(N _a -BN _e)	BML
树林	0.00	0.00	100.00	3.07	100.00	100.00	100.00	7.84
沥青	90.99	89.01	0.00	100.00	0.00	0.00	0.00	88.45
自粘砖	87.30	97.20	97.53	100.00	97.53	97.53	97.53	100.00
裸土	53.05	14.15	95.82	35.37	95.82	95.82	95.82	68.17

表 9 BML-MSF 在不同组件上的 OAs(%)

Table 9 OAs(%) of BML-MSF on Different Components

数据集	任务	光谱特征+MF	MSF	MSF+MF					
		BML	BML	M	M-N _e	M+N _a	M+(N _a -N _e)	M+(N _a -BN _e)	BML
Worldview-2	2011->2012	94.03	97.20	86.86	87.39	86.86	94.19	96.81	97.16
	2012->2011	95.79	99.04	78.41	98.06	96.05	98.36	98.61	98.93
Pavia	PC->PU	72.93	65.58	39.41	63.85	39.41	62.81	53.61	86.79
	PU->PC	76.13	75.74	80.41	83.56	80.41	80.41	80.41	84.65
	均值	84.72	84.39	71.27	83.22	75.68	83.84	82.36	91.88

表 10 不同方法的时间消耗(秒)

Table 10 Time Consumption (Seconds) of Different Methods

数据集	任务	GFK	JDA	Deep coral	MEDA	UTML	GEDA	SSWK-MEDA	BML-MSF
Worldview-2	2011->2012	0.21	292.39	285.80	94.63	271.71	51.04	97.02	171.05
	2012->2011	0.26	291.57	311.10	98.06	300.89	29.43	98.45	120.78
Pavia	PC->PU	0.44	51.07	165.40	10.54	41.56	13.73	12.01	21.48
	PU->PC	21.29	49.13	173.00	10.90	49.60	10.21	11.43	20.64

2.4 消融实验

BML-MSF 包括四个关键部分，即多级空间特征 (MSF)、流形特征 (MF)、平衡类间距离的权重 (B) (B)和测度学习 (ML)。本文在相同的参数范围内，对 BML-MSF 的各部分性能进行实验。在表 5-8 中，展示了在四个任务中，每个部件在每个类别的分类精度；在表 9 中，展示在四个任务中，每个部件的整体分类精度。表 5-9 中使用的一些符号需要进行清楚地解释： M 代表最小化边缘分布； $+N_a$ 代表最小化类内距离； $-N_e$ 代表最大化类间距离； $-H$ 代表最大化类间散度。从表 5-9 中，可以观察到多级空间特征可以快速地提高分类精

度；流形特征能够提升泛化性能；测度约束的增加也能够有效地提升分类；类不平衡权重能够在一定程度上缓解类别不平衡的问题，在 Worldview-2 数据集中，类别不平衡较为严重的“树林”的分类精度能够得到有效的提升，在 Pavia 数据集中类别不平衡的“沥青”的分类精度也能够的到有效的精度提升。从表 5-9 中，也可以观察到本文定义的类不平衡权重还不能彻底地解决类不平衡问题。

2.5 时间消耗

在表 10 中，展示了不同算法的时间消耗。BML-MSF 的时间成本明显地低于 JDA 和 UTML，明显地高于其他的算法。根据实验过

程,更多的测度约束会增加求导的复杂度,从而降低了分类器的分类速度,使得 BML-MSF 在时间成本上明显增加。但结合 BML-MSF 的分类表现,这种时间消耗可被认为是有意义的。

3 结 语

基于域适应的思想,本文提出了基于多级空间特征的平衡测度学习 (Balanced Metric Learning in Multilevel Spatial Features, BML-MSF) 遥感图像域适应分类。BML-MSF 通过迭代均值滤波器来获得多级空间特征,以更好地保存空间特征;然后,将得到的多级空间特征映射到流形空间中,实现对 Grassmann 几何结构的利用;其次,BML-MSF 使用 MMD 构建测度学习,以约束边缘分布、类内距离、类间距离和类间散度;BML-MSF 还创新性地使用了平衡类间距离来缓解类别不平衡问题;最后,本文在两个遥感数据集上的测试验证了 BML-MSF 优越的分类性能。

未来的工作,首先将探索从空间和光谱两个角度来处理遥感数据;其次,探索通过增强测度约束来减小源域和目标域的特征差异。

参 考 文 献

- [1] Xu Enen, Guo Ying, Chen Erxue, et al. An Estimation Model for Regional Forest Canopy Closure Combined with UAV LiDAR and High Spatial Resolution Satellite Remote Sensing Data[J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(8): 1298-1308. (徐恩恩, 郭颖, 陈尔学, 等. 基于无人机 LiDAR 和高空间分辨率卫星遥感数据的区域森林郁闭度估测模型[J]. 武汉大学学报(信息科学版), 2022, 47(8): 1298-1308.)
- [2] Gao Kuiliang, Liu Bing, Yu Xuchu, et al. Automatic Network Structure Search Method for Hyperspectral Image Classification[J]. *Geomatics and Information Science of Wuhan University*, 2024, 49(2): 225-235. (高奎亮, 刘冰, 余旭初, 等. 面向高光谱影像分类的网络结构自动搜索方法[J]. 武汉大学学报(信息科学版), 2024, 49(02): 225-235.)
- [3] Yu J, Zeng P, Yu Y Y, et al. A Combined Convolutional Neural Network for Urban Land-Use Classification with GIS Data [J]. *Remote Sensing*, 2022, 14(5): 1128.
- [4] Lu Yuwu, Wong Wai keung, Zeng Biqing, et al. Guided Discrimination and Correlation Subspace Learning for Domain Adaptation[J]. *IEEE Transactions on Image Processing*, 2023, 32: 2017-2032.
- [5] Liang Min, Wang Xili. Semantic Segmentation Model for Remote Sensing Images Combining Super Resolution and Domain Adaption, *Chinese Journal of Computers*, 2022, 45(12): 2619-2636. (梁敏, 汪西莉. 结合超分辨率和域适应的遥感图像语义分割方法[J]. 计算机学报, 2022, 45(12): 2619-2636.)
- [6] Zhou Yongsheng, Chen Peiyun, Liu Na, et al. Graph-embedding Balanced Transfer Subspace Learning for Hyperspectral Cross-scene Classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 2944-2955.
- [7] Sinno Jialin Pan, Ivor W. Tsang, James T. Kwok, et al. Domain Adaptation via Transfer Component Analysis[J]. *IEEE transactions on neural networks*, 2020, 22(2): 199-210.
- [8] Long Mingsheng, Wang Jianmin, Ding Guiguang, et al. Transfer Feature Learning with Joint Distribution Adaptation[C]. // *Proceedings of the 2013 IEEE International Conference on Computer Vision*, 2013: 2200-2207.
- [9] Huang Yi, Peng Jiangtao, Ning Yujie, et al. Graph Embedding and Distribution Alignment for Domain Adaptation in Hyperspectral Image Classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 7654-7666.
- [10] Dong Yanni, Liang Tianyang, Zhang Yuxiang, et al. Spectral-spatial Weighted Kernel Manifold Embedded Distribution Alignment for Remote Sensing Image Classification[J]. *IEEE Transactions on Cybernetics*, 2020, 51(6): 3185-3197.
- [11] Wu Tianjun, Luo Jiancheng, Xia Liegang, et al. An Automatic Sample Collection Method for Object-oriented Classification of Remotely Sensed Imageries Based on Transfer Learning[J]. *Acta Geodaetica et Cartographica Sinica*, 2014, 43(09): 908-916. (吴田军, 骆剑承, 夏列钢, 等. 迁移学习支持下的遥感影像对象级分类样本自动选择方法[J]. 测绘学报, 2014, 43(09): 908-916.)
- [12] Xu Suhui, Mu Xiaodong, Zhang Xiongmei, et al. Unsupervised

- Remote Sensing Domain Adaptation Method with Adversarial Network and Auxiliary Task[J]. *Acta Geodaetica et Cartographica Sinica*, 2017, 46(12): 1969-1977. (许凤晖, 慕晓冬, 张雄美, 等. 结合对抗网络与辅助任务的遥感影像无监督域适应方法[J]. 测绘学报, 2017, 46(12): 1969-1977.)
- [13] Luo Fang, Ai Tinghua, Jia Xiaobin. Consistency Evaluation of Land Use Distribution Pattern Supported by Spatial Autocorrelation[J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(7): 1017-1024. (罗芳, 艾廷华, 贾小斌. 空间自相关支撑下的地类分布模式一致性评价[J]. 武汉大学学报(信息科学版), 2022, 47(07): 1017-1024.)
- [14] Tobler W R. A Computer Movie Simulating Urban Growth in the Detroit Region[J]. *Economic Geography*, 1970, 46: 234-240.
- [15] Gong Boqing, Shi Yuan, Sha Fei, et al. Geodesic Flow Kernel for Unsupervised Domain Adaptation[C]. //In 2012 IEEE conference on computer vision and pattern recognition, 2012, pp: 2066-2073.
- [16] Dong Yanni, Liang Tianyang, Yang Cong, et al. Joint Distance Transfer Metric Learning for Remote-Sensing Image Classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [17] Huang Junchu, Zhou Zhiheng. Transfer Metric Learning for Unsupervised Domain Adaptation[J]. *IET Image Processing*, 2019, 13(5): 804-810.
- [18] Wang Jindong, Chen Yiqiang, Hao Shuji, et al. Balanced Distribution Adaptation for Transfer Learning[C]. //2017 IEEE International Conference on Data Mining(ICDM), 2017, 1129-1134.
- [19] Mikhail Belkin, Niyogi Partha, Sindhwani Vikas. Manifold Regularization: A geometric framework for learning from labeled and unlabeled examples[J]. *Journal of Machine Learning Research*, 2006, 7(1): 2399- 2434.
- [20] Sun Yifan, Yu Xuchu, Tan Xiong, et al. Lightweight Relational Network for Small Sample Hyperspectral Image Classification[J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(8): 1336-1348. (孙一帆, 余旭初, 谭熊, 等. 面向小样本高光谱影像分类的轻量化关系网络[J]. 武汉大学学报(信息科学版), 2022, 47(08): 1336-1348.)
- [21] LI Xiaoxu, Liu Zhongyuan, Wu Jijie, et al. Total Relation Network with Attention for Few- Shot Image Classification[J]. *Chinese Journal of Computers*, 2023, 46(02): 371-384. (李晓旭, 刘忠源, 武继杰, 等. 小样本图像分类的注意力全关系网络[J]. 计算机学报, 2023, 46(02): 371-384.)
- [22] Mao Lijun, Li Mingshi. Integrating Sentinel Active and Passive Remote Sensing Data to Land Cover Classification in a National Park from GEE Platform[J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(5): 756-764. (毛丽君, 李明诗. GEE 环境下联合 Sentinel 主被动遥感数据的国家公园土地覆盖分类[J]. 武汉大学学报(信息科学版), 2023, 48(5): 756-764.)
- [23] Wang Yan, Liu Wanjun, Tan Yali, et al. Classification of Urban Functional Areas by Convolution Neural Network Recognition Combined with Sliding Window and Semantic Reasoning[J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(6): 950-959. (王严, 刘万军, 谭亚丽, 李玉. 卷积神经网络滑动窗识别结合语义推理的城市功能区分类[J]. 武汉大学学报(信息科学版), 2023, 48(6): 950-959.)
- [24] Li Yifu, Sun Bin, Gao Zhihai, et al. Farmland Selterbelt Iformation Etraction Bsed on Mltispectral Image of the ZY1-02E satellite[J]. *National Remote Sensing Bulletin*, 2024, 28(03): 624-634. (李毅夫, 孙斌, 高志海, 等. 5米光学02星多光谱影像农田防护林信息提取[J]. 遥感学报, 2024, 28(03): 624-634.)
- [25] Liu Qian, Wu Zebin, Xu Yang, et al. Hyperspectral Remote Sensing Image Classification Based on Multidirectional Adaptive Aware Network[J]. *National Remote Sensing Bulletin*, 2024, 28(01): 168-186. (刘倩, 吴泽彬, 徐洋, 等. 基于多方向自适应感知网络的高光谱遥感图像分类[J]. 遥感学报, 2024, 28(01): 168-186.)
- [26] Yu Chunyan, Xu Mingyang, Song Meiping, et al. Unsupervised Domain Adaptive Classification for Hyperspectral Remote Sensing by Adversary Coupled with Distillation[J]. *National Remote Sensing Bulletin*, 2024, 28(01): 231-246. (于纯妍, 徐铭阳, 宋梅萍, 等. 对抗与蒸馏耦合的高光谱遥感自适应分类方法[J]. 遥感学报, 2024, 28(01): 231-246.)
- [27] Tang Shengjun, Zhang Yunjie, Li Xiaoming, . A High-Precision Indoor Point Cloud Classification Method Jointly Optimized by Super Voxel Random Forest and LSTM Neural Network[J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(4): 525-533. (汤圣君, 张韵婕, 李晓明, 姚萌萌, 叶致煌, 李亚鑫, 郭仁忠, 王伟玺. 超体素随机森林与 LSTM 神经网络联合优化的室内点云高精度分类方法[J]. 武汉大学学报(信息科学版), 2023, 48(4): 525-533.)
- [28] Sun Baochen, Saenko Kate. Deep CORAL: Correlation Alignment for Deep Domain Adaptation[C]. //Computer

Vision-ECCV 2016 Workshops, 2016, 443-450.

//In Proceedings of the 26th ACM international conference on

[29] Wang Jindong, Feng Wenjie, Chen Yiqiang, et al. Visual Domain Adaptation with Manifold Embedded Distribution Alignment[C].

Multimedia, 2018, 402-410.

网络首发:

标题: 多级空间特征的平衡测度学习遥感图像域适应分类

作者: 董燕妮, 秦学翔, 张玉香, 杜博

DOI: 10.13203/j.whugis20240212

收稿日期: 2024-06-10

引用格式:

董燕妮, 秦学翔, 张玉香, 等. 多级空间特征的平衡测度学习遥感图像域适应分类[J]. 武汉大学学报(信息科学版), 2024, DOI: 10.13203/j.whugis20240212 (DONG Yanni, QIN Xuexiang, ZHANG Yuxiang, et al. Balanced Metric Learning in Multilevel Spatial Features for Domain Adaptation in Remote Sensing Image Classification [J]. *Geomatics and Information Science of Wuhan University*, 2024, DOI: 10.13203/j.whugis20240212)

网络首发文章内容和格式与正式出版会有细微差别, 请以正式出版文件为准!

您感兴趣的其他相关论文:

面向高光谱影像分类的网络结构自动搜索方法

高奎亮, 刘冰, 余旭初, 余岸竹, 孙一帆

武汉大学学报(信息科学版), 2024, 49(2): 225-235.

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20210380>

基于MS-DeepLabV3+的街景语义分割及城市多维特征识别

柳林, 马泽鹏, 孙毅, 李万武, 项子诚

武汉大学学报(信息科学版), 2024, 49(3): 343-354.

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20220773>