

〈图像处理与仿真〉

## 不均衡少标签样本下基于语义自动编码网络的高光谱图像分类

孙宝刚<sup>1</sup>, 何国斌<sup>1,2</sup>

(1. 重庆人文科技学院 计算机工程学院, 重庆 合川 401524;  
2. 西南大学 计算机与信息科学学院, 重庆 北碚 400715)

**摘要:** 为了提升不均衡少标签样本下高光谱图像分类性能, 本文提出了一种改进的语义自动编码网络, 该网络首先将高光谱的类别标签信息引入到语义自编码网络模型中, 通过将不同数据集的原始数据及标签信息分别映射至同一特征空间以建立已知类别和未知类别的关联, 然后将该对应关系应用于未知数据集进行标签推理, 并构建基于图正则化项的目标函数以保存数据集中特征流形结构, 最后采用交替方向乘子法将全局问题分解为多个较小、较容易求解的局部子问题, 最终获得全局最优解。实验选取3个具有不同的光谱维度、光谱带数量和土地覆盖类型的高光谱数据集进行处理, 可以满足实验数据的多样性。结果表明, 本文所提方法的分类结果具有较高的分类精度, 其分类结果与基准结果比较相近, 适合工程上对非均衡高光谱图像数据分类。

**关键词:** 高光谱图像; 地物分类; 深度学习; 语义自动编码网络; 语义关联; 特征映射

中图分类号: TN958 文献标志码: A 文章编号: 1001-8891(2025)04-0429-08

## Hyperspectral Image Classification Based on Improved Semantic AutoEncoder Network in Unbalanced Small-Sized Labeled Samples

SUN Baogang<sup>1</sup>, HE Guobin<sup>1,2</sup>

(1. School of Computer Science and Engineering, Chongqing College of Humanities Science & Technology, Chongqing 401524, China; 2. College of Computer & Information Science Southwest University, Chongqing 400715, China)

**Abstract:** To improve the classification performance of hyperspectral images with unbalanced, few-labeled samples, an improved semantic autoencoder network is proposed in this paper. This network first introduces hyperspectral category-label information into the semantic autoencoder model, establishing the association between known and unknown categories by mapping the original data and label information of different datasets to the same feature space. It then maps the training dataset features to the unified embedding space to learn the correspondence between the visual features and the semantic features of the category labels. Finally, an objective function based on a graph regularization term is constructed to preserve the feature manifold structure in the dataset, and the global problem is decomposed into several smaller, more manageable local subproblems using the alternating direction multiplier method to obtain the global optimal solution. Three hyperspectral datasets with different spectral dimensions, numbers of spectral bands, and land cover types were selected to ensure the diversity of the experimental data. The results showed that the proposed method achieved better classification accuracy with a small number of labeled samples compared with other state-of-the-art methods, making it suitable for the engineering classification of unbalanced hyperspectral image data.

**Keywords:** hyperspectral image, terrain classification, deep learning, semantic auto-encoder network, semantic association, feature mapping

收稿日期: 2023-11-02; 修订日期: 2025-02-21。

作者简介: 孙宝刚(1979-), 男, 汉族, 陕西西安人, 学士, 副教授, 主要研究方向: 数据挖掘, 数据分析、深度学习。E-mail:sunbg@stu.swu.edu.cn。

通信作者: 何国斌(1968-), 男, 汉族, 重庆铜梁人, 博士, 副教授, 主要研究方向: 软件技术与理论、深度学习。.

基金项目: 国家自然科学基金项目(31071319), 2022年重庆教委研究项目(22SKGH493)。

## 0 引言

高光谱成像技术 (hyper spectral image, HSI) 是一种基于多窄波段的多维成像技术, 可同时探测目标的空间信息和光谱信息, 广泛应用于空间探测、军事、国土资源等领域<sup>[1]</sup>。高光谱成像系统由成像系统和分光系统两部分组成, 能够获取电磁光谱中数百种不同波长的空间二维图像<sup>[2]</sup>。大量光谱波段生成的二维图像堆叠形成一个超立方体, 其中每个空间像素由一组光谱探测到许多使用宽波段无法探查到的目标。然而, 对高光谱数据的处理不仅存在休斯 (Hughes) 效应, 还需要巨大的计算资源<sup>[3]</sup>。

近十年来, 国内外学者已经提出了许多优异的高光谱分类方法。早期分类方法主要关注光谱特征, 主要是采取特征降维和特征提取进行特征分析, 没有考虑图像的空间结构信息<sup>[4]</sup>。随着空间分辨率的提升, 将空间特征和光谱特征融合起来进行高光谱图像分类成为研究热点。近年来, 深度学习模型在高光谱图像分析中获得广泛应用, 已经设计出多种有效的深度网络。尽管已经有多种改进深度模型用于 HSI 的特征提取和数据分类, 但侧重于对训练中出现过标签类别的样本进行分类。由于高光谱数据存在小样本和高维度的问题, 且缺乏已标注的大型公开数据集, 这就使得这些方法在工程应用场景中存在样本数量不足以及不同类别样本数据不平衡的情况, 导致泛化能力下降。

为了解决上述问题, 一些针对不均衡分类的算法与策略被陆续提出。Gu 等人<sup>[5]</sup>提出了一种多核多粒度深度网络, 并采用半监督方式进行网络训练, 提升了有限样本下的分类精度。Aydav 等人<sup>[6]</sup>提出了一种基于自适应权重的多特征学习模型, 可以实现有限训练样本的 HSI 分类。与此同时, 一些学者设计合理的训练策略改进分类不平衡问题, 但严重依赖样本数量和分布仍然限制了 HSI 分类方法的工程应用。

最近, 不均衡少样本学习受到了越来越多的关注, 通过将学习规则从已知数据转移到未知数据, 从而提高识别精度。受此启发, 本文引入高光谱类别标签的语义信息, 拟通过将不同数据集的原始数据及标签信息分别映射至同一特征空间以建立已知类别和未知类别的关联, 再通过将训练数据集的两部分特征映射至统一的嵌入空间学习高光谱图像视觉特征和类别标签语义特征的对应关系。

## 1 语义自编码网络

自编码网络是通过将输入样本作为输出样本, 利用非监督或半监督学习模式提取图像特征, 而语义自

动编码网络是对已知数据集进行特征提取, 并直接对未知数据集进行分类识别。语义自动编码网络利用语义描述特征来建模已知数据与未知数据之间的联系, 并同时学习出原始特征到语义特征的编码映射以及语义特征到原始空间的解码映射<sup>[7]</sup>。

众所周知, 语义特征不仅有较好的类间语义共享性, 而且还有较强的类别区分性, 因而将语义特征用于不均衡少样本学习类的效果更好。假定已知数据训练集为  $D_S = \{(x_i^S, y_i^S)\}_{i=1}^N$ , 使得训练完的分类模型能够具有识别  $X_i^U$  的能力, 其中  $S$  和  $U$  分别代表已知类别数据集合和未知类别数据集合, 语义自动编码网络借助语义描述模块在  $S$  和  $U$  之间进行知识迁移, 从而实现对  $X_i^U$  的分类, 其示意图如图 1 所示。

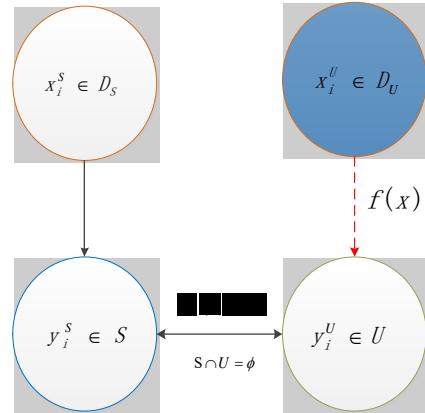


图 1 语义特征迁移关系

Fig.1 Transfer relationship diagram of semantic features

受少样本学习的启发, 本文提出将高光谱类别标签的语义信息引入到模型中, 通过将视觉空间与语义空间分别映射至共同的子空间, 学习二者之间的对应关系, 并实现测试数据集类别的标签推理。首先将样本的视觉特征向量投影到语义空间, 然后将样本及其标签的语义描述与剩余特征连接, 重构出样本的视觉特征向量。此外, 对目标数据中的流形结构进行建模有助于提高学习投影对目标类的泛化能力。

## 2 基于语义自动编码网络的高光谱图像分类

在 HSI 数据集中, 给定已知标签类别  $\{1, \dots, c_s\}$  的数据集  $D_S = \{X_S, A_S, Y_S\}$ , 其中  $A_S = \{a_i^S\}_{i=1}^{c_s}$  是已知训练类语义集合, 而未知集合  $D_U = \{X_U, A_U, Y_U\}$  的标签  $\{1, \dots, c_u\}$ , 其中  $X_S \in R^{d \times N_s}$  与  $X_U \in R^{d \times N_u}$  分别表示已知源域与未知源域特征向量, 向量的对应维度。 $N_s, N_u$  分别表示源域可见类数据集样本数量和目标域不可见类数据集样本数量。可见类与不可见类的语义特征可以采用  $A_S = \{a_i^S\}_{i=1}^{c_s}$  与  $A_U = \{a_i^U\}_{i=1}^{c_u}$  进行表示, 其中  $a_i \in R^{k \times 1}$

是第  $i$  类的语义表示,  $k$  是其相应维度。 $Y_s$  与  $Y_u$  是源域与目标域中样本的标签信息, 其中  $Y_s \cap Y_u = \emptyset$ 。 $H_s = [h_1^s, h_2^s, \dots, h_{N_s}^s] \in R^{k \times N_s}$  是源域所有可见样本的语义描述矩阵, 可通过类别为  $y_s^i$  的样本  $x_s^i$  表示。由于测试数据并没被标注, 其相应的语义矩阵  $H_u$  需要进行优化估计。

## 2.1 小样本下语义自编码模型

为了增强不均衡小样本高光谱数据的特征表征能力, 本文设计的模型由两个语义自编码网络组成, 其中编码器与解码器之间包含两个隐藏层。输入的样本数据  $X_s (X_u)$  经过第一层编码器  $P_s^T (P_u^T)$  投影到语义空间  $H_s (H_u)$ , 然后选用原型语义表示  $A_s^T (A_u^T)$  作为第二层编码器, 并将语义特征  $H_s (H_u)$  及其对应标注  $Y_s^T (Y_u^T)$  关联起来; 最后解码器  $(A_s, P_s) (A_u, P_u)$  寻求从标签空间和语义空间依次重构输入数据  $X_s (X_u)$ 。本文将语义自编码系数分解拓展成多层学习模式以提升单层模型的图像分类性能。为了有效保持数据结构信息, 基于每一层特征编码来构建图拉普拉斯矩阵, 并生成编码系数上的约束。图矩阵包含了训练样本的局部结构信息, 通过将该矩阵作用在编码系数上, 使第一层的编码系数保留了原输入样本中的局部结构信息。

与文献[8]描述的方法类似, 本文直接将解码器设置为相应编码器的转置, 以简化栈式自编码网络的结构。具体来说, 假定对小样本学习  $X_s$  与  $X_u$  的重构具有相同的重要性, 其模型可以表示为以下优化问题:

$$F = \min_{P_s, P_u, Y_u} \|X_s - P_s A_s Y_s^T\|_F^2 + \lambda \|A_s^T P_s^T X_s - Y_s^T\|_2^2 + \|X_u - P_u A_u Y_u^T\|_F^2 + \lambda \|A_u^T P_u^T X_u - Y_u^T\|_2^2 \quad \text{s.t. } \Delta P \in \Gamma \quad (1)$$

式中:  $\Delta P = P_s - P_u$ , 通过采用相对较小的 F-范数来约束  $\Delta P$  可以度量不同域中两个投影之间域适应性; 正则化参数  $\lambda$  是用来控制编码器与解码器之间的平衡。对于小样本学习, 我们希望训练样本的流形结构能够被保留, 并实现知识的迁移。也就是说, 通过将映射到语义空间中的样本再重建回去, 有助于使学习到的映射能保留更多的信息。

具体来说, 如果同一数据集中的两个样本  $x_u$  与  $x_l$  在可视空间中很接近, 那么它们的类标签也应该很接近。根据流形假设的定义, 我们使用样本空间中的最近邻图对几何结构进行建模。对于具有  $n$  个顶点 (样本) 的最近邻图  $G^l$ , 其相似矩阵定义如下:

$$M_{(k,l)} = \begin{cases} \cos(x_k, x_l), & x_k \in N_q(x_l) \text{ or } x_l \in N_q(x_k) \\ 0, & \text{else} \end{cases} \quad (2)$$

式中:  $N_q(x)$  表示样本  $x$  的前  $q$  个最近的邻居。由于  $G^l$  是第  $l$  层编码器构建的, 它可以在特征学习中随着  $D_l$  的改变被实时更新。由于  $D_l$  根据训练数据逐层构建, 因此图拉普拉斯矩阵  $G^l$  继承了训练数据的局部流形结构。因此, 给定  $Q = \text{diag}(\Sigma_k M_{k,l})$ , 我们可以构造图正则化项来保存数据集中特征流形结构, 如下所示:

$$L = \frac{1}{2} \sum_{(k,l)} (\|y_k - y_l\|^2) M_{(k,l)} = \text{tr}(Y^T (Q - M)) \quad (3)$$

由于源域样本的标签信息  $Y_s$  是已知的, 这就意味着源数据的图正则化项为常变量。因此, 我们只需要将等式(2)代入到等式(3)中, 就可以获得具有最优模型, 而不改变其最优值。

$$F = \min_{P_s, P_u, Y_u} \|X_s - P_s A_s Y_s^T\|_F^2 + \lambda \|A_s^T P_s^T X_s - Y_s^T\|_F^2 + \mu L_u \\ \|X_u - P_u A_u Y_u^T\|_F^2 + \lambda \|A_u^T P_u^T X_u - Y_u^T\|_F^2 \\ \text{s.t. } \Delta P \in \Gamma, Y_u^T I_{N_u} = I_{C_u} \quad (4)$$

式中:  $L_u = \text{tr}(Y_u^T (Q_u - M_u) Y_u)$  是使用测试样本构造的;  $I_{N_u}$ 、 $I_{C_u}$  分别表示长度不同的全 1 向量。该等式的优化可以利用  $Y_u$  列向量上  $L_1$  正则约束进行。接下来, 本文将对改造的栈式自编码网络进行优化。

可以看出, 本文改进的目标函数有 3 个未知变量, 并且在这些变量上不是联合凸的。为了求解全局最优解, 本文将全局问题分解为多个较小、较容易求解的局部子问题, 并通过协调子问题的解而得到大的全局问题的解。也就是说, 我们采用迭代策略来交替优化每个变量, 同时每次修正其他变量, 即通过固定其中两个参数来优化剩余参数。

## 2.2 参数优化

在求得编码器  $D_l$  之后, 即可采用等式(2)与(3)构建图拉普拉斯矩阵。当固定  $P_u$  与  $Y_u$  的结果后, 投影向量  $P_s$  可以通过如下等式进行优化更新。

$$F = \min_{P_s} \|X_s - P_s A_s Y_s^T\|_F^2 + \lambda \|A_s^T P_s^T X_s - Y_s^T\|_F^2 \\ \text{s.t. } \Delta P \in \Gamma \quad (5)$$

由于语义矩阵  $A_s$  是一个常量, 上述目标函数的约束项可以等价地转换为  $P_s A_s - P_u A_s \in \Gamma$ 。如前所述,  $\Gamma$  是相对较小 F-范数的矩阵, 因此等式(5)可以改写成:

$$F = \min_{P_s} \left\| X_s - P_s A_s Y_s^T \right\|_F^2 + \lambda \left\| A_s^T P_s^T X_s - Y_s^T \right\|_F^2 + \gamma \left\| P_s A_s - P_u A_s \right\| \quad (6)$$

为了求解该等式, 令其一阶导数为零, 可以获得如下 Sylvester 方程:  $Y_s^T Y_s A_s^T P_s^T + A_s^T P_s^T (\lambda X_s X_s^T + \gamma) = (\lambda + 1) Y_s^T X_s^T + \gamma P_u A_s$  Sylvester 方程可以采用 Bartels-Stewart 算法高效求解, 即:

$$W_s = \text{sylvester}(Y_s^T Y, \lambda X_s X_s^T + \gamma, (\lambda + 1) Y_s^T X_s^T + \gamma P_u A_s) \quad (7)$$

最终可以得到  $P_s = W_s^T (A_s + \varepsilon I)^{-1}$ , 其中  $\varepsilon$  的值非常小, 能避免求解过程奇异性问题。与此类似, 采用相同的策略可以求解  $Y_u$  与  $P_u$ 。最终,  $Y_u^T = \text{sylvester}(W_u W_u^T + x I, u(Q_u^T - M_u^T), (\lambda + 1) W_u X_u)$ 。

一旦优化完成, 通过选择  $Y_u$  中每一行得分最大的值作为测试样本的类别标签, 即:

$$Y_u^* = \arg \max_l (Y_u^l), \quad l \in [1, C_u] \quad (8)$$

其中, 需要说明的式(6)最小化问题, 可以用交替方向乘法器来解决, 采用栈式语义自编码网络算法 (stacked semantic autoencoder network, SSAEN), 其优化过程如下:

输入: 已知类训练样本  $X_s, Y_s, A_s$ ; 未知数据  $X_u, A_u$ ; 迭代次数  $T_n$ ; 迭代停止误差  $\varepsilon$ ; 权值参数  $\lambda, \gamma, \mu$  与  $q$ 。

初始化:  $t=1, P_s^0, P_u^0$  与  $Y_u^0$  的初始采用 PCA 初始化矩阵, 利用等式(4)与(5)计算构建图矩阵  $G^t$ ;

循环条件: 不满足收敛条件且  $t \leq T_n$

① 固定  $P_u$  与  $Y_u$ , 优化  $W_s = \text{sylvester}(Y_s^T Y, \lambda X_s X_s^T + \gamma, (\lambda + 1) Y_s^T X_s^T + \gamma P_u A_s)$ ;

② 计算已知数据的投影矩阵,  $P_s = W_s^T (A_s + \varepsilon I)^{-1}$ ;

③ 固定  $P_s$  与  $P_u$ , 计算  $W_u$ ;

④ 计算未知数据的投影矩阵  $P_u = W_u^T (A_u + \varepsilon I)^{-1}$ ;

⑤ 求解  $Y_u$ ;

⑥ 计算迭代后的误差数据的  $l_2$  范数;

结束循环

输出: 投影矩阵  $P_s$  与  $P_u$ , 以及对应类别标签矩阵  $Y_u$ 。

### 3 定性定量实验分析

为了验证本文所提出的高光谱图像分类算法在不均衡小样本条件下的分类效果, 本章选用 3 个广泛使用的公开数据集进行处理, 并与现有代表性分类网络进行定性定量对比分析。本文所设计网络模型采用 PyTorch 1.2.0 深度学习框架, 并在 Pycharm 中编程实现, 其编程语言为 Python3.6。试验所采用的硬件平台是 Intel XeonW-2102 CPU@2.90 GHz 处理器和 GeForce GTX 1080TI 用于加速。

#### 3.1 数据集及其评价指标

实验采用了 3 个广泛使用的公开多光谱数据集<sup>[8-9]</sup>, 分别为 Indian Pines、Pavia University 与 Salinas。这 3 个数据集具有不同的光谱维度、光谱带数量和土地覆盖类型, 可以满足实验数据的多样性。表 1 展示了 3 种高光谱数据的参数。

在实验评价方面, 本文选用了 3 种评价指标对不同对比模型的分类结果进行全面评价, 具体为整体分类准确度 (overall accuracy, OA)、平均分类准确度 (average accuracy, AA)、Kappa 系数 (Kappa coefficient)<sup>[8,10]</sup>, 其中 OA 是估计整体的类别精确程度; AA 是衡量每一类样本数据分类精度的平均值, 而 Kappa 系数在一定程度上可以反映多次实验结果一致性程度的鲁棒性。值得注意的是, 本文所选的对比模型都为开源代码, 其运行软件环境与库文件版本存在差异, 不同模型的运行时间并不能完全反映模型的运行效率, 因此本文主要从时间复杂度与收敛效率对所提模型进行分析。

#### 3.2 参数设计及对比算法

为了验证基于语义自动编码网络的高光谱图像分类算法的有效性, 本章选用了 8 种具有代表性的分类算法: SSRN<sup>[9]</sup>, DFSL-NN<sup>[10]</sup>, SLSVM<sup>[11]</sup>, CCPGE<sup>[12]</sup>, LapSVM<sup>[13]</sup>, SS-CNN<sup>[14]</sup>, 3-D-CAE<sup>[15]</sup> 和 uFLCNN<sup>[16]</sup>。为确保对比实验的公平性, 每类目标只选取 5 个已标注的目标域样本进行训练, 而对于一些跨域分类方法, 每类随机选择 200 个已标注源域样本来学习可转移知识, 如 DFSL-NN、SLSVM 等, 剩下的目标域样本都作为测试集。所有的数据采用波段选择<sup>[16]</sup>进行选择分割, 以确保输入维度的一致性。

表 1 高光谱数据集参数

Table 1 Parameters of hyperspectral databases

Dataset	Size	Resolution/m	Spectral range/μm	Categories	Used band
Indian Pines	145×145×220	20	0.4–2.5	16	200
Pavia University	610×340×115	1.5	0.43–0.86	9	103
Salinas	512×217×224	3.7	0.4–2.5	16	204

与文献[15,17-18]所设计的架构类似,本文所提出的算法采用 $9 \times 9 \times L$ 子区域作为输入,其中 $L$ 为自适应波段数量。文献[18]指出 $q_L$ 的取值依赖于数据集的类型,本文设置为5;针对窗口大小而言,11×11大小的窗口准确率更高;参数 $\lambda$ 、 $\gamma\beta$ 与 $\mu\gamma$ 采用训练样本各类的交叉验证来选择,其最优值分别为 $10^2$ 、 $3 \times 10^4$ 与 $3 \times 10^3$ 。所有训练样本在送入网络之前,均采用减去均值除以方差进行预处理,以消除量纲影响并保留高光谱数据原有分布。所提网络结构采用Adam优化器进行训练,所有卷积核都采用Xavier归一化进行初始化。训练迭代次数设置为10000次,学习率为0.001。

### 3.3 收敛性分析

为了便于分析改进网络的性能,本小节将对网络训练过程的收敛性能进行讨论。在传统语义自编码网络<sup>[19]</sup>设置下,算法在数据集上的收敛性分析如图2所示,其中蓝色、红色和绿色线分别表示 $P_s$ 、 $P_u$ 和 $\Delta P = P_s - P_u$ 在多次迭代后的误差数据的 $l_2$ 范数。当迭代次数 $t=1$ 时, $P_s(t-1)$ 和 $P_u(t-1)$ 是初始投影,为随机正规矩阵。图2展示了 $P_s$ 和 $P_u$ 的范数值在迭代过程中迅速降低,其收敛速度较快。当算法逐渐收敛时, $\Delta P = P_s - P_u$ 的范数值接近而不是等于1,这表明优化后的投影 $P_s$ 和 $P_u$ 不一致,也表明该模型可以通过学习域自适应投影来解决映射域偏移问题。为了实验结果的稳定性,当迭代次数达到20次或迭代过程中 $P_u$ 相对变化的 $l_2$ 范数低于 $10^{-3}$ 时,算法终止。

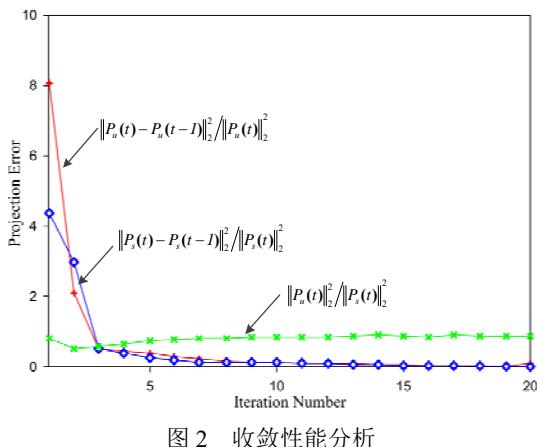


图2 收敛性能分析

Fig.2 Convergence performance analysis

### 3.4 定性定量分析

本文提出的高光谱分类模型通过引入类别标签的语义信息,将视觉空间与语义空间分别映射至共同的子空间,学习二者之间的对应关系,实现未知数据集类别的标签推理。为了公平有效地评估模型的性能,我们选用了具有代表性的高光谱图像分类算法在3种高光谱数据集上进行定性定量对比分析。

表2展示了不同算法模型在Indian Pines数据集上的分类结果。实验选用了8种具有代表性的分类算法,其中SSRN, DFSL-NN与SLSVM为有监督分类算法。可以看出,本文提出的深度模型的分类结果部分优于有监督分类算法,且需要的训练数据更少。在Indian Pines数据集中,本文所提算法的OA、AA与Kappa分别为 $63.01 \pm 0.62$ 、 $68.90 \pm 0.89$ 、 $61.86 \pm 0.52$ ,其中分别比SSRN高1.46%、9.15%与4.95%。

为了进一步定性不同对比模型的分类性能,图3展示在不同的目标域上相应的分类图。与本文所提的方法相比,其他对比算法都存在将较多的样本分配到错误类别的情况,使得分类结果与基准图存在差异。例如,图3(b)中DFSL-NN的分类结果中“同物异谱”现象较为严重,一些区域呈现出不同的颜色分布,影响了算法分类精度。虽然本文改进的方法与基于深度学习的对比模型都是采用相同的训练集,但前者的分类精度优于后者。这是由于本文改进模型采用的语义信息进行标签类推,可以从源类数据中发现可转移语义知识,这有助于对目标类数据进行预测,而标准深度模型的训练数据不足就会大大降低分类精度。

表3展示了Salinas Valley数据集中不同类别样本的分类精度。对于分类错误率较大的类别,所提的方法也能获得较好的结果。数据集中的部分类别的分类结果比DFSL-NN与SLSVM高了4.83%与15.27%。与DFSL-NN和SLSVM等无域自适应方法相比,所提方法的整体分类准确度、平均分类准确度(AA)、Kappa系数,分别提高了5.9%、6.2%和7.59%。可以发现,具有跨域的半监督方法优于没有跨域(LapSVM和SS-CNN)的方法。与这些半监督方法相比,本文提出的方法获得了更好的结果。也就是说,相同源域数据集在4个目标域数据集上都取得了更好的分类性能。从表3可以看出,所提网络的OA比对比模型SSRN的分类精度高9.989%。

为了验证不同数量的标记样本对所提模型的影响,实验还从目标域中为每类随机选择不同数量的标记样本进行训练,其结果如图4所示。实验结果表明,所有算法的整体分类准确度随着标注样本数量的增加而增加,而本文所提算法的性能均优于对比算法,表明了该算法对标注样本数量变化的适应性。定性结果展示了不同模型相应的分类结果图,其中所提模型的分类结果与基准图相似,充分表明本文所提模型具有较优异的性能,区域一致性得到提高,从而改善了分类效果。数据集不同类别区域分布均匀。

表2 不同算法模型在 Indian Pines 数据集上的分类结果

Table 2 Classification results of different algorithm models for Indian Pines dataset

Models	SSRN	DFSL-NN	SLSVM	CCPGE	3D-CAE	LapSVM	SS-CNN	uFLCNN	Proposed
OA/ (%)	61.55	58.63	61.35	58.25	57.11	62.22	60.28	62.55	63.01
	$\pm 0.98$	$\pm 0.58$	$\pm 1.52$	$\pm 1.23$	$\pm 0.98$	$\pm 1.07$	$\pm 0.85$	$\pm 1.21$	$\pm 0.62$
AA/ (%)	59.75	61.42	59.85	68.25	61.58	65.11	58.78	62.15	68.90
	$\pm 1.48$	$\pm 0.42$	$\pm 0.27$	$\pm 0.86$	$\pm 0.91$	$\pm 1.21$	$\pm 0.87$	$\pm 0.77$	$\pm 0.89$
Kappa/ (%)	56.91	54.55	57.28	61.22	60.07	52.52	58.24	50.94	61.86
	$\pm 1.51$	$\pm 0.58$	$\pm 0.73$	$\pm 0.88$	$\pm 1.20$	$\pm 1.31$	$\pm 0.99$	$\pm 0.62$	$\pm 0.52$

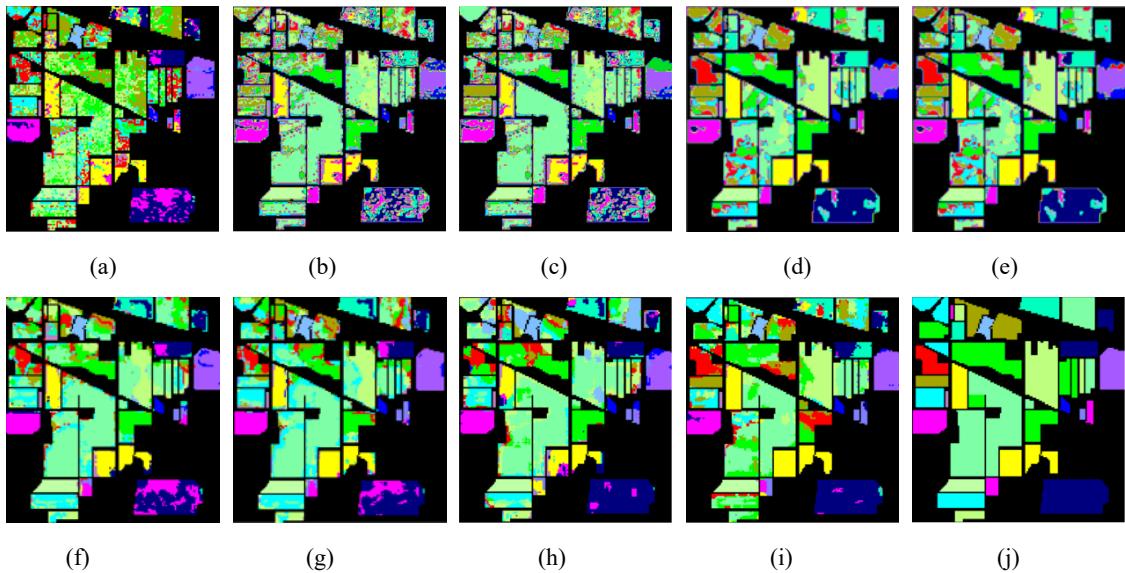


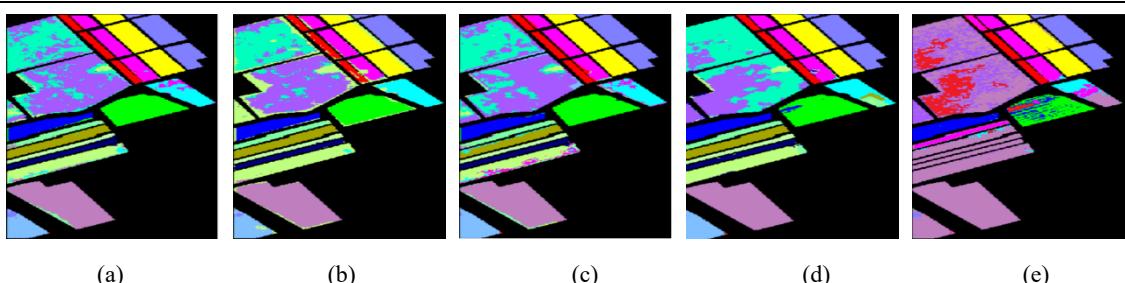
图3 Indian Pines 数据集下对比模型的分类结果: (a)SSRN; (b)DFSL-NN; (c)SLSVM; (d)CCPGE; (e)3D-CAE; (f)LapSVM; (g)SS-CNN; (h)uFLCNN; (i)Proposed; (j)Ground-truth

Fig.3 Classification maps for different comparison model for Indian Pines. (a)SSRN; (b)DFSL-NN; (c)SLSVM; (d)CCPGE; (e)3D-CAE; (f)LapSVM; (g)SS-CNN; (h)uFLCNN; (i)Proposed; (j)Ground-truth

表3 不同算法模型在 Salinas Valley 数据集上的分类结果

Table 3 Classification results of different algorithm models for Salinas Valley dataset

Models	SSRN	DFSL-NN	SLSVM	CCPGE	3D-CAE	LapSVM	SS-CNN	uFLCNN	Proposed
OA/ (%)	85.52	90.18	79.73	94.61	92.14	91.02	93.25	94.25	95.01
	$\pm 0.91$	$\pm 0.82$	$\pm 0.04$	$\pm 0.15$	$\pm 0.20$	$\pm 0.14$	$\pm 0.09$	$\pm 0.09$	$\pm 0.05$
AA/ (%)	88.84	91.75	85.76	95.20	93.11	89.29	94.01	93.07	95.41
	$\pm 0.48$	$\pm 0.07$	$\pm 1.33$	$\pm 0.92$	$\pm 0.36$	$\pm 0.27$	$\pm 0.07$	$\pm 0.18$	$\pm 0.07$
Kappa	83.85	89.06	78.06	91.56	95.27	92.08	95.04	94.00	95.66
	$\pm 0.51$	$\pm 0.39$	$\pm 0.41$	$\pm 0.23$	$\pm 0.1$	$\pm 0.27$	$\pm 0.04$	$\pm 0.21$	$\pm 0.03$



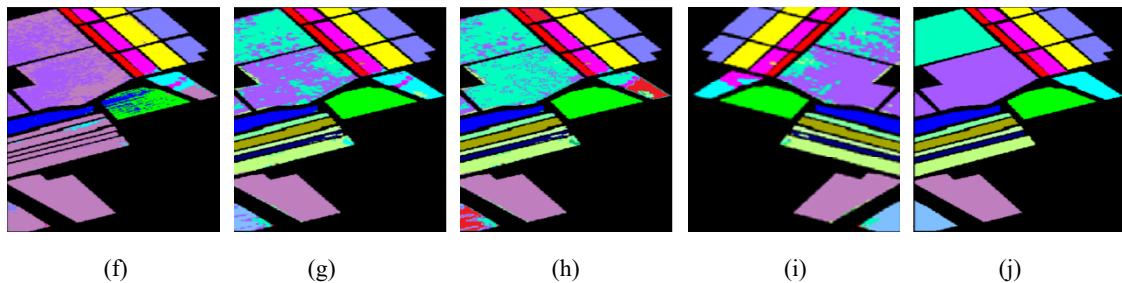


图4 Salinas Valley 数据集下对比模型的分类结果。(a) SSRN; (b) DFSL-NN; (c) SLSVM; (d) CCPGE; (e) 3D-CAE; (f) LapSVM; (g) SS-CNN; (h) uFLCNN; (i) Proposed; (j) Ground-truth

Fig.4 Classification maps for different comparison model for Salinas Valley.(a)SSRN; (b)DFSL-NN; (c)SLSVM; (d)CCPGE; (e) 3D-CAE; (f) LapSVM; (g) SS-CNN; (h)uFLCNN; (i)Proposed; (j) Ground-truth

表4 展示了不同数据集下不同方法的分类结果。

从表中数据可以看出,与3D-CAE和uFL-CNN方法相比,本文方法的OA在每个类别有5个标记样本的Pavia数据集上分别增加了7.1%和17.94%,这充分证明了该方法在标记样本较少时的优势。然而,本文所提模型的OA不如LapSVM,主要是由于LapSVM引入了无标签样本蕴含在流形结构中的几何信息,辅助有标签样本调整分类界面,对Pavia数据集的纹理结

构有较好的效果,尤其是改善了边界分类效果。

图5显示了不同目标领域的分类结果,本文所提网络对于每个类别的分类图的边缘轮廓都比其他方法分类可视化图的轮廓更加清晰平滑,但也存在部分区域不完整的问题。定性定量实验结果表明所提方法的分类结果具有较高的分类精度,其分类结果与基准结果比较相近,适合工程上对非均衡高光谱图像数据分类。

表4 不同算法模型在Pavia数据集上的分类结果

Table 4 Classification results of different algorithm models for Pavia dataset

Models	SSRN	DFSL-NN	SLSVM	CCPGE	3D-CAE	LapSVM	SS-CNN	uFLCNN	Proposed
OA(%)	82.13	91.44	89.72	83.24	84.82	91.25	88.27	83.26	91.20
	±2.05	±1.08	±1.37	±2.27	±0.95	±1.07	±1.22	±1.58	±0.35
AA(%)	79.53	84.27	83.66	87.24	86.91	89.08	88.00	84.26	88.65
	±1.89	±1.26	±1.09	±0.98	±0.98	±1.02	±1.11	±0.74	±0.52
Kappa	89.06	95.24	93.77	94.02	92.12	95.11	91.58	93.67	95.26
	±0.68	±0.17	±0.29	±0.13	±0.35	±0.25	±1.1	±0.75	±0.27

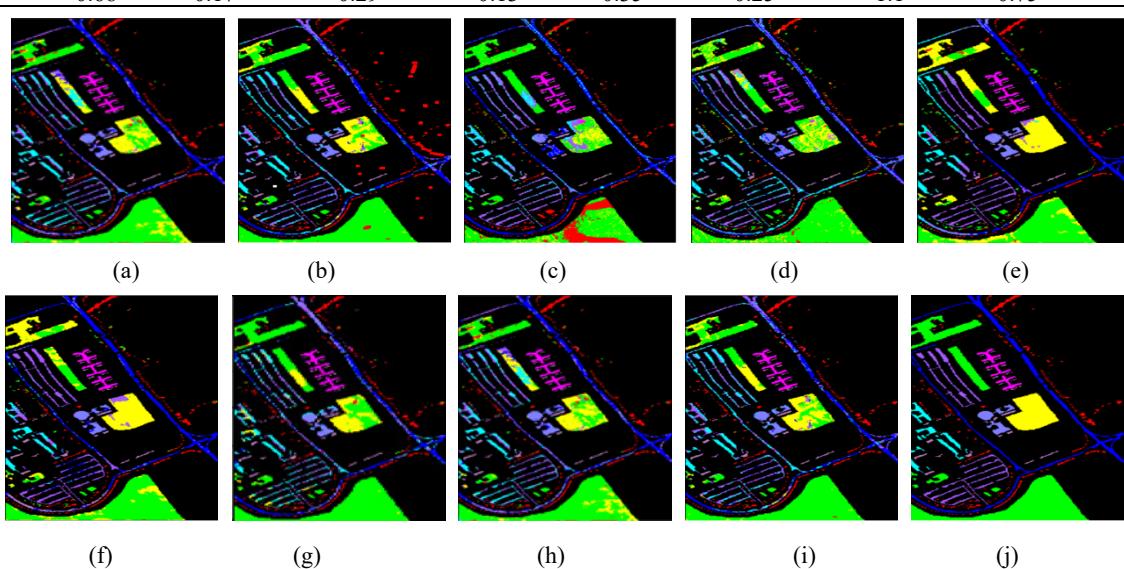


图5 Pavia 数据集下对比模型的分类结果。(a)SSRN; (b)DFSL-NN; (c)SLSVM; (d)CCPGE; (e)3D-CAE; (f) LapSVM; (g) SS-CNN; (h) uFLCNN; (i)Proposed; (j)Ground-truth

Fig.5 Classification maps for different comparison model for Pavia dataset.(a)SSRN; (b)DFSL-NN; (c)SLSVM; (d)CCPGE; (e)3D-CAE; (f)LapSVM; (g)SS-CNN; (h)uFLCNN; (i)Proposed; (j)Ground-truth

## 4 结论

本文提出了一种改进的语义自动编码网络，该网络将高光谱类别标签的语义信息引入到语义自动编码网络模型中，通过将不同数据集的原始数据及标签信息映射至统一的嵌入空间，然后计算高光谱图像视觉特征和类别标签语义特征的对应关系，最终实现对未知数据集进行标签推理。实验结果表明，本文所提的方法在不均衡少量标记样本的情况下可以获得与对比网络相当的精度。

虽然本文改进的语义自编码网络可以通过流形结构保留语义特征，实现知识的迁移，但在实际应用过程中，高光谱数据集本身的类别精细度以及语义描述粒度对模型的分类性能与可迁移能力影响较大，这将是笔者下一步的研究方向。

## 致谢

感谢武汉大学测绘遥感信息工程国家重点实验室提供了本文实验的高光谱数据。与电子科技大学光电科学与工程学院卓晗博士进行了有益讨论，谨此致谢。

## 参考文献：

- [1] 张国国, 陶于祥, 罗小波, 等. 基于特征重要性的高光谱图像分类[J]. 红外技术, 2020, 42(12): 1185-1191.  
ZHANG Yingguo, TAO Yuxiang, LUO Xiaobo, et al. Hyperspectral image classification based on feature importance[J]. *Infrared Technology*, 2020, 42(12): 1185-1191.
- [2] 闫贊彬, 崔博伦, 杨婷婷, 等. 基于轻型平台的多模态高分辨率高光谱目标检测系统[J]. 红外技术, 2023, 45(6): 582-591.  
YAN Yunbin, CUI Bolun, YANG Tingting, et al. Multi-modal high-resolution hyperspectral object detection system based on lightweight platform[J]. *Infrared Technology*, 2023, 45(6): 582-591.
- [3] 徐达, 潘军, 蒋立军, 等. 基于高光谱数据的典型地物分类识别方法研究[J/OL]. 激光与光电子学进展, 2023, 60(15): 396-410.  
XU D, PAN J, JIANG L J, et al. Research on typical feature classification and identification method based on hyperspectral data[J/OL]. *Laser and Optoelectronics Exhibition*, 2023, 60(15): 396-410.
- [4] 刘万军, 尹岫, 曲海成, 等. 提高小样本高光谱图像分类性能的变维卷积神经网络[J]. 中国图象图形学报, 2019, 24(9): 1604-1618.  
LIU W J, YIN X, QU H C, et al. A variable-dimensional convolutional neural network for improving classification performance of small-sample hyperspectral images[J]. *Chinese Journal of Graphics*, 2019, 24(9): 1604-1618.
- [5] 方帅, 祝凤娟, 董张玉, 等. 样本优化选择的高光谱图像分类[J]. 中国图象图形学报, 2019, 24(1): 135-148.  
FANG S, ZHU F J, DONG Z Y, et al. Sample optimization selection for hyperspectral image classification[J]. *Chinese Journal of Graphics*, 2019, 24(1): 135-148.
- [6] GU Y, Chanussot J, JIA X, et al. Multiple kernel learning for hyperspectral image classification: a review[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(11): 6547-6565.
- [7] Aydav P S S, Minz S. Granulation-based self-training for the semi-supervised classification of remote-sensing images[J]. *Granular Computing*, 2020, 5(3): 309-327.
- [8] CAI W, NING X, ZHOU G, et al. A novel hyperspectral image classification model using bole eonvolution with three-directions attention mechanism: small sample and unbalanced learning[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 61: DOI: 10.1109/TGRS.2022.3201056.
- [9] HUANG S, ZHANG H, Pižurica A. Hybrid-hypergraph regularized multiview subspace clustering for hyperspectral images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60(1): 1-16.
- [10] ZHONG Z, LI J, LUO Z, et al. Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(2): 847-858.
- [11] LIU B, YU X, YU A, et al. Deep few-shot learning for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(4): 2290-2304.
- [12] SUNG F, YANG Y, ZHANG L. Learning to compare: relation network for few-shot learning[C]//Proceeding of the 2018 IEEE/CVF Computer Vision and Pattern Recognition Conference, 2018: 1199-1208.
- [13] LIU N, LI W, DU Q. Unsupervised feature extraction for hyper-spectral imagery using collaboration-competition graph[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(6): 1491-1503.
- [14] Belkin M, Niyogi P, Sindhwani V. Manifold regularization: a geometric framework for learning from labeled and unlabeled examples[J]. *Journal of Machine Learning Research*, 7(24): 2399-2434.
- [15] LIU B, YU X, ZHANG P, et al. A semi-supervised convolutional neural network for hyperspectral image classification[J]. *Remote Sensing Letters*, 2017, 8(9): 839-848.
- [16] MEI S, JI J, GENG Y, et al. Unsupervised spatial-spectral feature learning by 3D convolutional autoencoder for hyperspectral classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(9): 6808-6820.
- [17] MEI S, JI J, HOU J, et al. Learning sensor-specific spatial-spectral features of hyperspectral images via convolutional neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(8): 4520-4533.
- [18] LI Z, LIU M, CHEN Y, et al. Deep cross-domain few-shot learning for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60(12): 1-18.
- [19] SONG J, SHI G, XIE X, et al. Domain-aware stacked autoencoders for zero-shot learning[J]. *Neurocomputing*, 2021, 42(9): 118-131.