

博士学位论文

基于空谱多维特征提取的高光谱图像
分类方法研究

RESEARCH ON HYPERSPECTRAL IMAGE
CLASSIFICATION METHODS BASED ON
MULTIDIMENSIONAL SPECTRAL-SPATIAL
FEATURE EXTRACTION

冯佳

哈尔滨工业大学

2024年5月

国内图书分类号：TP751.1

国际图书分类号：621.3

学校代码：10213

密级：公开

工程博士学位论文

基于空谱多维特征提取的高光谱图像 分类方法研究

博士研究生：冯佳

导师：张钧萍教授

申请学位：工程博士

学科：先进制造

所在单位：电子与信息工程学院

答辩日期：2024年5月

授予学位单位：哈尔滨工业大学

Classified Index: TP751.1

U.D.C: 621.3

Dissertation for the Doctoral Degree in Engineering

**RESEARCH ON HYPERSPECTRAL IMAGE
CLASSIFICATION METHODS BASED ON
MULTIDIMENSIONAL SPECTRAL-SPATIAL
FEATURE EXTRACTION**

Candidate:	Feng Jia
Supervisor:	Prof. Zhang Junping
Academic Degree Applied for:	Doctor of Engineering
Speciality:	Advanced Manufacturing
Affiliation:	School of Electronics and Information Engineering
Date of Defence:	May, 2024
Degree-Conferring-Institution:	Harbin Institute of Technology

摘要

得益于高光谱图像“图谱合一”的独特数据特点和内在丰富的空谱信息，高光谱图像分类技术在精细农业、智慧城市、地质勘探和生态保护等领域都发挥着不可替代的重要作用，尤其是当前正处于我国十四五农村农业现代化和新型城镇智慧化发展的重要战略机遇期，依托于高光谱图像的地物分类技术对实现农作物产量预估、农业生产布局和城市基础建设规划及管理等方面都具有十分重要的应用价值。但由于成像条件的不稳定性、采集区域场景的复杂性和地物分布及尺寸的差异性，高光谱图像分类技术在实际应用中仍然存在着亟待解决的关键问题：成像条件易受干扰造成光谱信息的不确定性，导致高光谱数据蕴含的地物本质流形结构难以有效挖掘，影响了地物判别性特征的有效提取；地物类别标注困难造成的标记样本稀缺，阻碍了高光谱分类模型的充分训练并限制了地物类型识别的准确性；由于单源高光谱数据缺少垂向的高程信息，对于地物种类繁多、分布结构多变等情况复杂的场景，难以实现全面的地物特征表示和精确的类别区分结果。针对上述问题，本文首先从高光谱图像内在的数据特点分析着手，深入探究了空谱信息联合下地物鉴别性多维特征的提取方法，并基于此拓展研究了标记样本数目有限和 LiDAR 数据辅助等不同条件下的高光谱图像分类方法。论文的研究内容主要包括以下几个方面：

首先，针对光谱信息不确定性对地物类别区分的干扰，提出一种基于可靠邻域结构的空谱多维特征提取方法。该方法通过联合高光谱图像中地物的光谱、纹理和空间位置等多维度信息对样本之间的距离进行度量，减少相似度计算误差，构建具有高可靠性的邻域结构，从而揭示同类地物的本质流形结构特性，然后结合已知的语义信息提取出地物判别性的空谱多维特征。论文采用多组不同场景的高光谱图像分类任务对所提方法进行验证分析，实验结果表明，所提方法能够在特征空间中加强同类地物的聚合度和不同类别间地物的区分度，从而提升地物类别的判定能力。

其次，面向小样本条件下标记样本不充足、地物识别困难等问题，论文提出一种基于半监督学习和多类型信息融合的高光谱分类方法。该方法利用有限的语义信息和高光谱图像隐含的类内地物邻域结构，从大量的无标记样本中逐级筛选出高质量的伪样本集，进而实现有效的样本扩充；在此基础上，论文通过引入类内地物样本在不同类型信息中的紧密关系，实现基于局部同质区域语义信息引导的地物类别修正，进一步提升高光谱图像的分类精度。实验结果和模型分析表明，

所提方法能够改善分类模型在地物辨别方面的性能，从而缓解标记样本稀缺对高光谱图像解译应用的不利影响。

最后，针对高光谱图像地物信息描述不完善、异构高程信息融合困难以及地物本质特征难以有效表征等问题，提出一种多视特征提取和多级信息融合框架下高光谱与 LiDAR 数据协同的地物分类方法。论文在前期研究内容的基础上，首先利用同属性空间信息中多源地物内容表达的一致性，构建基于多属性空间信息的多源地物多视图重表达形式；在此基础上，为解决地物特征表示单一、区分度弱等问题，设计了一种基于多分支双通道图卷积网络的特征提取模型，实现具有互补性和多样性的地物多视图特征提取；同时，结合不同层次上多源信息融合的优势，实现地物类别渐进式的高置信度判定。实验结果表明，所提方法能够有效地实现多源异构数据的信息融合，提升高程信息辅助下的高光谱图像地物分类精度。

关键词：高光谱图像分类；空谱特征；流形结构；样本扩充；多源数据融合

Abstract

Due to the advantages of image-spectrum merging characteristics and abundant spectral-spatial information inherent in the hyperspectral image (HSI), the HSI classification techniques have played an irreplaceable role in various application areas such as geological prospecting, smart agriculture, ecological protection and camouflage detection, etc. Especially, during the 14th Five-Year Plan period of important strategic opportunities for pushing forward the modernization of agriculture and rural areas and the innovation of new-type urban areas in our country, the landcover classification techniques based on hyperspectral images have important application value in the crop yield prediction, agricultural production allocation, urban infrastructure planning and development control, etc. However, due to the uncertainty of imaging conditions, the complexity of the image acquisition area and the difference in the size and distribution information of ground object, the HSI techniques are still confronted with some challenges in the practical applications: the hyperspectral imaging conditions which is susceptible to external disturbance causes the uncertain spectral information, resulting in the difficulty for the essential manifold structure mining and the discriminative landcover feature extraction; the limited labeled sample set caused by the difficulty in labeling the ground object leads to the underfitting hyperspectral classification model and the inaccurate classification result for different categories of landcovers; when it comes to the complex imaging scenarios with multiple kinds of ground objects and distribution structure, the HSI classification tasks suffers from the incomplete feature representation and the inaccurate classification results due to the lack of elevation information. To address these problems, this thesis starts with the analysis of data characteristics in the HSIs and the deep study of extracting the multidimensional landcover features with inter-class distinguishing ability based on the joint use of spectral-spatial information, on this basis, and the research on HSI classification methods for the small sample set condition and LiDAR-assisted situation is conducted respectively. The main research content of the thesis includes the following parts.

In view of alleviating the disturbance to category recognition caused by the spectral information uncertainty in the HSIs, a spectral-spatial feature extraction based on high-reliable neighborhood structure is generated in this thesis. Through a new distance metric in the proposed method which incorporates spectral bands, texture features and geographical information simultaneously to reduce the reconstruction error and construct the high-reliable neighborhood structure, the inherent manifold structure of the landcovers in the same category is revealed and the spectral-spatial features are obtained

to discriminate different classes of landcovers. The experiment results on several hyperspectral classification tasks in different scenarios show that the proposed method could effectively strengthen the aggregation of the same-class samples and the separation of different classes of samples in the feature space, hence, improve the accuracy of land cover classification.

In order to alleviate the difficulty in ground-object identification under the limited semantic information condition, this thesis presents an HSI classification method to tackle the small labeled sample size problem with semisupervised learning and multiple information fusion. On the basis of the previous research, the pseudo-labeled samples with high-quality would be automatically chosen from the unlabeled data by step-by-step screening based on the joint use of the class label information and high-reliable neighborhood structure. Then, the close relationships hidden in multiple information of the same-class samples are dug out and introduced to adaptively realize the label category amendment by the semantic information consistency in local homogeneous area, which further enhancing the landcover classification accuracy. The experimental results and model analysis show that the proposed method could boost the classification performance and help mitigate the negative influence from small-sized sample set to the practical applications of the hyperspectral image interpretation.

Aiming at the problem of the imperfect landcover information representation in the HSIs and the difficulty in heterogeneous elevation information fusion and natural feature extraction, a novel hyperspectral classification method which aided by LiDAR data is investigated in this thesis by use of multi-view feature learning and multi-level information fusion. First, owing to previous research, considering that the same-attribute spatial information among the multi-source data reveals the similar content representation, the multi-source multi-view data are re-expressed based on multiple attributes of spatial information inherent in the multi-source data. Then, a multi-branch dual-channel graph convolutional networks model is designed for extracting multi-view feature representations with diversity and complementarity to deal with the problem of the weak class discrimination in the single-view feature representation. Meanwhile, a progressively high-confidence label assignment scheme is proposed to classify the landcovers, benefiting from an organic integration of the complementary advantages in different levels of information fusion. Comparative experiments validate the effectiveness of the proposed method in multi-source heterogeneous information fusion and the accuracy boosting in the hyperspectral classification tasks with the aid of elevation information.

Keywords: hyperspectral image classification, spectral-spatial features, manifold structure, sample augmentation, multi-source data fusion

目 录

摘 要.....	I
Abstract.....	III
第 1 章 绪 论.....	1
1.1 课题背景及研究的目的和意义.....	1
1.2 国内外研究现状.....	3
1.2.1 高光谱遥感技术发展现状.....	4
1.2.2 高光谱图像特征提取及分类研究现状.....	6
1.2.3 高光谱图像小样本分类研究现状.....	8
1.2.4 基于异源遥感数据辅助的高光谱图像分类研究现状.....	11
1.2.5 研究现状简析.....	14
1.3 论文主要研究内容及组织结构.....	15
第 2 章 高光谱图像数据和分类评价准则.....	19
2.1 引言.....	19
2.2 高光谱成像机理及数据特点.....	19
2.2.1 成像机理.....	19
2.2.2 数据特点.....	21
2.3 高光谱图像数据集.....	22
2.3.1 国外高光谱数据集.....	22
2.3.2 国产高光谱数据集.....	28
2.4 高光谱图像分类结果评价指标.....	30
2.5 本章小结.....	31
第 3 章 基于可靠邻域结构的高光谱图像空谱特征提取.....	32
3.1 引言.....	32
3.2 流形学习基础理论.....	33
3.3 基于空谱信息联合和可靠邻域结构挖掘的高光谱特征提取.....	35
3.3.1 高光谱数据的重表达.....	35
3.3.2 基于空谱信息联合距离度量的改进 NPE 算法.....	37
3.3.3 基于可靠邻域结构的高光谱多维空谱特征提取.....	40
3.4 实验结果及分析.....	42
3.4.1 实验数据与设置.....	42

3.4.2 消融实验与模型参数分析	43
3.4.3 对比实验与分析	50
3.4.4 国产高光谱图像空谱多维特征提取及分类应用分析	54
3.5 本章小结	56
第 4 章 基于半监督学习和多类型信息融合的高光谱小样本分类	57
4.1 引言	57
4.2 高光谱小样本分类任务概述	58
4.3 面向高光谱小样本分类条件的样本扩充和类别修正方案	59
4.3.1 整体模型框架	59
4.3.2 基于半监督学习和可靠邻域结构的样本扩充	60
4.3.3 基于局部同质区域语义信息引导的地物类别修正	64
4.4 实验结果及分析	66
4.4.1 实验数据与设置	66
4.4.2 消融实验与参数分析	66
4.4.3 分类性能对比和分析	70
4.4.4 国产高光谱图像小样本分类应用分析	75
4.5 本章小结	77
第 5 章 基于高程信息辅助的高光谱图像分类	79
5.1 引言	79
5.2 图卷积网络模型	80
5.3 基于高光谱与 LiDAR 多源数据融合的地物分类模型	83
5.3.1 整体模型框架	83
5.3.2 基于多属性空间信息的多源数据多视图重表达	85
5.3.3 基于多分支双通道图卷积网络模型的地物多视图特征提取	87
5.3.4 基于多级信息融合的渐进式高置信度地物分类	89
5.4 实验结果及分析	91
5.4.1 实验数据与设置	91
5.4.2 消融实验与模型分析	92
5.4.3 分类性能对比实验	95
5.5 基于高光谱图像的地物分类与分析软件设计	99
5.5.1 软件整体框架	100
5.5.2 文件操作功能模块	101
5.5.3 基础工具功能模块	102

目 录

5.5.4 地物分类识别功能模块	103
5.6 本章小结	104
结 论	105
参考文献	107
附 录	118
攻读博士学位期间取得创新性成果	120
哈尔滨工业大学学位论文原创性声明和使用权限	122
致 谢	123
个人简历	125

Contents

Abstract (In Chinese)	I
Abstract (In English)	III
Chapter 1 Introduction	1
1.1 Background, objective and significance of the subject	1
1.2 Research status at home and abroad	3
1.2.1 Research status of hyperspectral remote sensing technology	4
1.2.2 Research status of hyperspectral image feature extraction and classification	6
1.2.3 Research status of small sample hyperspectral image classification	8
1.2.4 Research status of hyperspectral image classification aided by remote sensing data from different types of collection sensors	11
1.2.5 Research status summary	14
1.3 Main research contents and structure of the thesis	15
Chapter 2 Hyperspectral image data and evaluation criteria for classification results	19
2.1 Introduction	19
2.2 Imaging principle and data characteristics of hyperspectral image	19
2.2.1 Hyperspectral imaging principle	19
2.2.2 Hyperspectral data characteristics	21
2.3 Hyperspectral image datasets	22
2.3.1 Foreign hyperspectral image datasets	22
2.3.2 Domestic hyperspectral image datasets	28
2.4 Evaluation criteria for hyperspectral image classification	30
2.5 Brief summary	31
Chapter 3 Spectral-spatial feature extraction of hyperspectral image based on high-reliable neighborhood structure	32
3.1 Introduction	32
3.2 Basic theory for manifold learning	33
3.3 Feature extraction based on spectral-spatial information collaboration and high-reliable neighborhood structure mining	35
3.3.1 Data re-expression for the hyperspectral data	35
3.3.2 Improved NPE based on the distance measure by joint use of spectral-spatial information	37
3.3.3 Multidimensional spectral-spatial feature extraction for hyperspectral image based on high-reliable neighborhood structure	40

3.4 Experimental results and analysis	42
3.4.1 Experimental data and settings	42
3.4.2 Ablation experiments and parameter analysis	43
3.4.3 Comparative experiments and result analysis	50
3.4.4 Multidimensional spectral-spatial feature extraction and classification analysis on domestic hyperspectral image datasets.....	54
3.5 Brief summary	56
Chapter 4 Small sample hyperspectral image classification based on semisupervised learning and multiple information fusion	57
4.1 Introduction	57
4.2 Short overview of hyperspectral image classification tasks with small-sized labeled samples.....	58
4.3 Sample augmentation and label amendment for hyperspectral image classification with limited labeled samples	59
4.3.1 Overall framework.....	59
4.3.2 Sample augmentation based on semisupervised learning and high-reliable neighborhood structure	60
4.3.3 Class label amendment based on semantic information guidance in the local homogeneous area	64
4.4 Experimental results and analysis	66
4.4.1 Experimental data and settings	66
4.4.2 Ablation experiments and parameter analysis	66
4.4.3 Comparison and analysis of classification performance	70
4.4.4 Application analysis on domestic hyperspectral image classification with small sample size	75
4.5 Brief summary	77
Chapter 5 Hyperspectral image classification aided by elevation information.....	79
5.1 Introduction	79
5.2 Graph convolutional network model.....	80
5.3 Landcover classification based on hypersepctral and LiDAR data fusion.....	83
5.3.1 Overview framework.....	83
5.3.2 Multi-view data re-expression for multisource data based on multi-attribute spatial information.....	85
5.3.3 Multi-view feature extraction based on multi-branch dual-channel graph convolutional networks model	87
5.3.4 Progressively high-confidence label assignment based on information fusion on different levels	89

5.4 Experimental results and analysis	91
5.4.1 Experimental data and settings	91
5.4.2 Ablation experiments and parameter analysis	92
5.4.3 Comparison experiments on classification performance.....	95
5.5 Software design for landcover classification and anlysis based on hyperspectral image	99
5.5.1 Overview framework of the designed software.....	100
5.5.2 Functional module for document operation.....	101
5.5.3 Functional module for fundamental tool	102
5.5.4 Functional module for landcover classification and identification	103
5.6 Brief summary	104
Conclusions	105
References	107
Appendix	118
Innovative achievements for Ph.D	120
Statement of copyright and Letter of authorization	122
Acknowledgements	123
Resume	125

第1章 绪论

1.1 课题背景及研究的目的和意义

在 2021 年全球地球观测第四次部长级高峰会议上，地球观测组织曾指出通过综合不同来源的对地观测结果，能够分析地球系统过去与现在的情况、以及二者之间的交互作用和人类活动对地球系统的未来行为影响^[1]。作为对地观测的有效技术之一，遥感技术以非接触、远距离的数据获取方式，依托于卫星、航空器或地面装置等不同平台收集研究目标或区域的地表散射、反射或辐射等电磁波信息，实现地球表面的观测、测量和分析。时至今日，得益于传感器技术、航空航天技术和卫星通信技术的日新月异，遥感技术已步入“三多”、“三全”和“四高”的新发展阶段，获取地表观测数据也愈加便利，这为精细农业、资源勘探、灾害预警、环境监测和国防安全等诸多应用领域奠定了夯实的技术基础^[2]。其中，高光谱遥感技术作为欧盟委员会发布的《面向未来的 100 项重大创新突破》中一项令人瞩目的颠覆性创新技术，也早已被我国十三五发展规划纳入强化国家战略科技力量的重大工程项目中，该项技术通过联合成像技术和光谱探测技术，依靠数据采集平台的成像光谱仪对观测地表区域进行二维图像成像的同时，还能够探测图像中各个像元的一维光谱信息，进而获取到集空间信息与光谱信息为一体的高光谱图像（Hyperspectral Image, HSI）数据，这为精确有效的地表观测和分析提供了有力的数据保障。

高光谱图像不仅具有三维立方体的数据结构，还蕴含着多种不同类型的地物信息表示，图 1-1 为该数据在不同形式下的信息示意图，从图中可以看出，高光谱图像在每一个谱段上为一幅具有固定空间尺寸的二维图像；对于图像中指定位置的单一像元而言，在成像光谱仪覆盖的光谱谱段范围内，显示为基于密集邻接波段上的光谱响应曲线，其谱段范围能够覆盖可见光、近红外、中红外和热红外等电磁波谱区域，光谱谱段数目可以达到几十甚至上百，这一丰富的光谱信息能够反映不同类型地物在物理结构、化学成分等特性上的细微差异^[3]。此外，高光谱图像还隐含着能够体现地物形状、大小、位置和分布等不同属性的空间信息，不同类型的信息表示具有各自的独特性和一定的互补性，描述了高光谱图像中同一地物目标不同方面的性质特点^[4]，为地物类型的判别和分析提供了重要依据。得益于高光谱图像内在丰富的空谱信息和“图谱合一”的独特数据特点，基于高光谱图像的地物解译一直是国内外研究学者们密切关注的研究热点，并已成为遥感对地观测领域中不可或缺的中坚力量^{[3][4]}。

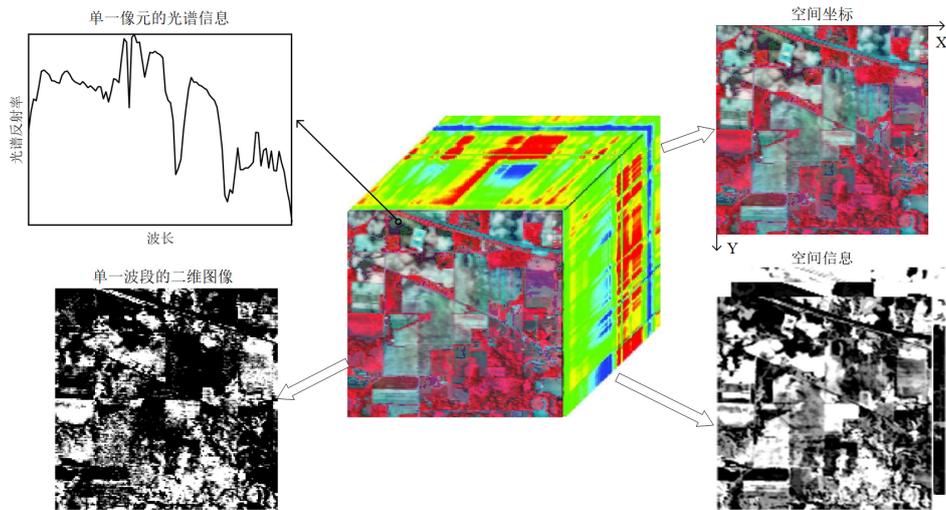


图 1-1 高光谱图像不同形式下的信息示意图

Fig. 1-1 Schematic diagram of hyperspectral image in different forms

作为高光谱图像解译研究中的一支重要分支，高光谱图像分类旨在利用一定的技术手段对图像中的各像元进行成分分析和类别标注，在精准农业应用领域，利用该项技术可以实现农作物的信息提取和类型区分，为种植区域的估算、耕地资源的规划和农业资源现状的调查等^[5]奠定基础；在生态环境保护领域，依托于高光谱分类技术不仅可以实现森林树种识别、草地植物群落物种判别，为林业状态评估和草原退化治理提供参考^{[6][7]}，同时还能够为水质生态环境监测领域提供基于内陆水质参数反演、水体面积变化^[8]和海洋资源调查^[9]等研究的技术支撑。除此之外，为满足城市规划建设和管理方面的应用需求，利用高光谱分类技术对地表目标和基础设施进行识别，可以实现城市结构、格局和功能布局的精细化表达^[10]。现阶段，高光谱图像数据的获取方式多样且日益便捷，但受限于固有的成像机理和数据特点，在许多应用场景中，高光谱图像分类技术仍面临着一些亟待解决的难题和挑战：

(1) 光谱波段间的高度相关性和光谱信息的不确定性影响地物鉴别性特征的有效提取。高光谱图像能够反映地物目标宽谱段范围内不同光谱波段上的响应信息，但较窄的谱段间隔使得相邻的光谱波段相关性大，造成数据维度高且信息冗余大，很容易引发“Hughes”现象^[11]，影响地物类别判定的准确度。此外，由于成像条件容易受到光照、大气云层等条件影响，存在着显著的“同物异谱、异物同谱”现象，即同类地物光谱差异性大、异类地物光谱相似度高，尤其是农作物种植区域，同一科种内不同属别的农作物往往具有高度相似的光谱信息，这种光谱信息的不确定性造成地物鉴别性特征提取困难。

(2) 标记样本获取困难，缺乏足够的地物类别语义信息，造成高光谱图像地

物类别难以有效区分、图像解译精度低。随着遥感技术和传感器技术的不断发展，目前高光谱图像数据的获取愈加便利，但在实际应用中，对每幅图像中的地物进行属性分析、类别标注往往需要大量的人力、物力成本，而高光谱图像分类模型的性能与标记样本的数量有较强的依赖关系，使得在标记样本数目十分有限的情况下，很难实现高精确度的地物分类结果。此外，对于同一幅高光谱图像而言，成像场景复杂、地物类别繁多，不同类别地物的形状大小、纹理分布都存在着一定的差异性，尤其是在当今智慧城市建设的背景下，人造地物不仅种类多样，还往往具有复杂的内部结构，增加了地物类别区分的难度。

(3) 单源的高光谱图像地物信息表示局限，引入 LiDAR 数据能够更加全面地表征地物特点，而异构高程信息融合困难、地物辨识性特征难以有效提取。高光谱图像以被动的方式记录了地表物体对太阳光的电磁波辐射信息，但缺少垂向分布的信息采集，而激光雷达 (Light Detection and Ranging, LiDAR) 则是利用主动发射的激光脉冲测采集地物的高程信息，二者在地物信息表达上具有一定的互补性，联合多源数据进行地物分类可以克服单一模态数据地物信息表达的局限性，更加全面地分析和表征地物特性，获得更加准确的地物类别辨识度。但多源数据的信息异构特性加深了类内地物间关联的复杂性，导致地物本质特征难以有效提取，阻碍了后续地物类别的高精度判定。

当今正处于我国十四五发展规划面向农业绿色发展、生态文明和智慧城市建设的新时代背景下^[12]，高光谱分类技术作为提取专题信息、监测地物变化的重要手段，在国家国防、生态安全和国民经济建设等方面都发挥着不可忽视的重要作用^[4]。针对上述存在的问题和高光谱图像地物智能化、精确化解译的应用需求，本文以高光谱图像空谱信息的联合利用作为出发点，首先从地物本质的流形结构挖掘角度入手，研究地物鉴别性空谱多维特征的有效提取方法；在此基础上，论文进一步探索小样本条件下的高光谱图像分类模型，对同类地物的内在信息和关联属性展开研究，实现标记样本稀缺情况下的样本扩充并改善不同类别地物的分类结果；随后，面向 LiDAR 数据辅助下的高光谱图像地物分类任务，研究多源异构信息的有效融合策略和地物本质特征的提取方法，构建更具普适性和鲁棒性的多源数据联合地物分类模型；在此基础上，论文进一步设计并搭建可操作性更强、灵活性更高的高光谱图像分析和分类软件，从而推动高光谱遥感技术在各领域的应用和发展。

1.2 国内外研究现状

本节首先回顾了国内外高光谱遥感技术的发展进程，然后基于论文的各项研

究内容，从空谱信息联合、小样本条件和异源遥感数据辅助等三个方面对现有的高光谱图像分类方法进行介绍和分析。为了避免混淆，本节面向高光谱图像特征提取及分类研究现状，不涉及小样本条件，仅对标记样本充足情况下的高光谱图像分类方法进行梳理和分析。

1.2.1 高光谱遥感技术发展现状

自上世纪八十年代首台机载成像光谱仪问世以来，各国研究机构竞相跟进，先后研制出了多种不同类型的机载高光谱成像光谱仪，主要包括美国国家航空航天局和加州理工学院喷气推进实验室的机载可见光/红外成像光谱仪（Airborne Visible/Infrared Imaging Spectrometer, AVIRIS）^[13]、加拿大 ITRES Research 公司推出的小型机载成像光谱仪（Compact Airborne Spectrographic Imager, CASI）^[14]、德国的反射光学系统成像光谱仪（Reflective Optics System Imaging Spectrometer, ROSIS）^[15]和芬兰 Specim 公司制造的应用型机载成像光谱仪（Airborne Imaging Spectrometer for Applications, AISA）Eagle 系列^[16]以及澳大利亚集成光电公司生产的机载扫描成像光谱仪（Hyperspectral Mapper, HyMap）^[17]等，这些机载成像光谱仪为不同应用研究奠定了基于高光谱遥感技术方案的可行性，并在海洋水体监测、矿质土壤分析和深空探索等领域取得了一定的应用进展。我国上海技术物理所于上世纪九十年代首次研制出机载高光谱成像光谱仪，随后历经多年的潜心研究，又相继开发出了光谱波段通道数目更多的实用型模块化成像光谱仪（Operational Modular Imaging Spectrometer, OMIS）和首台具有 244 波段的推扫式高光谱成像仪（Pushbroom Hyperspectral Imager, PHI）^[18]，并进一步研制出了机载热红外高光谱成像系统（Airborne Thermal-Infrared Hyperspectral Imaging System, ATHIS）和面向高分专项航空系统的机载多模态成像光谱仪（Airborne Multi-modality Imaging Spectrometer, AMMIS）^[18]。此外，还有中国科学院长春光学精密机械与物理研究所的高分辨率成像光谱仪和西安光学精密机械所设计的稳态大视场偏振干涉成像光谱仪，这一系列国产成像光谱仪的研制成功，大大地提升了我国对地观测的能力和效率，也推动了高光谱遥感技术在各领域的应用发展^[19]。表 1-1 展示了国内外典型机载成像光谱仪的主要参数，从表中所列参数可以看到高光谱成像光谱仪具有纳米级的光谱分辨率和较宽的谱段范围，能够为地物的有效识别和区分提供可靠依据。在各种机载高光谱成像光谱仪研制并应用的基础上，美国空军研究实验室于 2000 年发射了 MightySat II 卫星并搭载了首台基于傅里叶干涉分光技术的傅里叶变换高光谱成像光谱仪（Fourier Transform Hyperspectral Imager, FTHSI），随后于同年发射了装载色散型高光谱成像光谱仪 Hyperion 的高光谱地球观测卫星

EO-1^[20]。次年，欧空局发射了搭载紧凑式高分辨率成像光谱仪（Compact High Resolution Imaging Spectrometer, CHRIS）的 PROBA-1 卫星^[18]，能够同时获取地表的高光谱和多角度数据，自此拉开了世界各国开展星载遥感技术对地观测研究的帷幕^[21]。

表 1-1 国内外机载高光谱成像仪主要指标的参数对比

Table 1-1 Main technical parameter comparison of airborne hyperspectral imaging spectrometers at home and abroad

仪器名称	光谱范围 (μm)	光谱通道数	光谱分辨率 (nm)	瞬时视场角 IFOV (mrad)
AVIRIS	0.36-2.45	224	10	1.0
CASI	0.36-1.05	144	2.4	1.2
HyMap	0.45-2.5	126	15	2.0
OMIS	0.4-12.5	128	10	3.0
PHI	0.4-0.85	244	5	1.5
AMMIS	0.4-2.5 8-12.5	64/256 (VNIR)	9.6/2.4 (VNIR)	0.125/0.25 (VNIR)
		512 (SWIR)	3 (SWIR)	0.5 (SWIR)
		140 (TIR)	32 (TIR)	1 (TIR)

近年来，随着多元信息在环境、农林和地质等方面重要性的日益凸显，各国相继研制并发射了针对不同应用领域的高光谱观测卫星，典型的代表如俄罗斯陆续发射的 Resurs 资源卫星星座、意大利空间局于 2019 年发射的小型超光谱成像卫星（PRecursores IperSpettrale della Missione Applicativa, PRISMA）和德国航空航天中心在 2022 年发射的本国首颗高光谱遥感卫星（Environmental Mapping and Analysis Program, EnMAP）^[22]。为满足大范围、多目标的遥感观测实际需要，我国于 2008 年发射了搭载傅立叶变换高光谱成像仪 FTHSI 的环境 1 号卫星，并历经十多年的核心关键技术突破，相继成功发射了装载可见短波红外高光谱相机（Advanced Hyperspectral Imager, AHSI）^[19]的资源探测业务卫星（资源一号 02D）以及高光谱综合观测卫星（高分五号 02 星），大大地缓解了生态环境、自然资源等诸多应用领域中对地观测数据的紧缺局面，并推进了高分辨率对地观测计划的实现进程^[23]。此外，在机载热红外高光谱成像光谱仪 ATHIS 的技术体系基础上，我国已于 2020 年成功研制了空间高分辨红外的星载高光谱成像仪，首次实现了中波红外谱段的高光谱成像，进一步地扩展了高光谱遥感技术在灾害监测、气体识别和地表温度探测等领域的业务应用。表 1-2 列出了国内外星载高光谱成像光谱仪核心的各项指标参数，结合表 1-1 中的机载成像光谱仪对比参数可以看出，我国高光谱遥感技术虽起步较晚，但历经长期的潜心研究，目前航天航空等平台的高光谱成像光谱仪相关技术指标已达到国外先进水平，有效地解决了各项应用研究中高光谱图像的数据需求。

表 1-2 典型星载高光谱成像光谱仪参数信息

Table 1-2 Parameter information of typical spaceborne hyperspectral imagers

仪器名称	FTHSI	Hyperion	CHRIS	PRISMA	EnMAP	AHSI
搭载卫星	MightySat II	EO-1	PROBA-1	PRISMA	German HS	高分 5 号 02 星
国家	美国	美国	欧空局	意大利	德国	中国
光谱范围 (μm)	0.45-0.95	0.4-2.5	0.4-1.05	0.4-2.5	0.42-2.45	0.45-2.5
光谱通道数	115	220	150	237	228	330
光谱分辨率(nm)	4	10	1.25-11	12	6.5 (VNIR) 10 (SWIR)	5 (VNIR) 10 (SWIR)
幅宽 (km)	50	7.7	13	30	30	60
空间分辨率 (m)	100	30	25-50	30	30	30

2023 年 11 月,我国首届中国测绘地理信息大会如期召开,大会发布了《中国测绘地理信息科技创新与产业发展报告(2023)》和《中国地理信息产业发展报告(2023)》^[24],其中已明确指出截至 2022 年末,我国遥感卫星数量和质量都已达到世界先进水平,并已构建出了由陆地卫星、气象卫星、海洋卫星组成的全方位对地观测体系,极大地丰富了高光谱遥感数据的供给来源。此外,伴随着空中移动智能体无人机研制技术的日趋成熟,基于无人机的高光谱成像系统也应运而生,通过集成小型高性能的遥感传感器和其他辅助设备,搭建出了操作灵活、续航时间长且具有全天候作业能力的遥感数据获取系统^[25]。例如,我国杭州高谱成像技术有限公司的无人机组高光谱成像系统 HY-9010 和赛斯拜克公司的无人机组高光谱成像系统 SF500,这不仅缓解了传统机载或星载成像平台对地观测实时性较差、造价成本高等问题,其简便的操作模式还降低了数据采集的难度,能够获取到近距离、高空间分辨率的地面高光谱图像数据。综上所述,各种便利的采集平台和丰富的数据来源为高光谱图像的分析 and 处理提供了充分的保障,并已在森林、冰川等环境变化的全面监测、农业粮食的安全生产、土地资源的可持续利用和气候模型的可靠构建以及自然灾害的应急响应等领域得到了广泛的应用。

1.2.2 高光谱图像特征提取及分类研究现状

1.2.2.1. 基于光谱/空间信息的高光谱图像特征提取及分类研究现状

高光谱图像中的光谱信息能够反映地物表面特性和材料成分,但容易受成像条件如大气、光照、地物分布等环境因素影响,使得相同类别的地物光谱曲线迥异而不同类别的地物光谱曲线近似,一定程度上削弱了地物之间的可区分性,而图像中的空间信息能够描述出地物空间分布和形状结构等特点,因而综合利用高光谱图像蕴含的空谱信息,在尽可能保留有效信息的同时提取出鉴别性的地物特征表示,是实现高光谱图像后续应用的重要基础和技术前提^{[3][26]}。但由于高光谱图

像自身存在着毗邻波段相关性强、数据维度大、信息冗余度高等特点，传统的遥感图像处理并不适用于高光谱图像，这使得高光谱图像的处理和应用都面临着重大的挑战^{[27][28]}。

早期的特征提取方法主要集中于降低高光谱图像中光谱信息的冗余度，典型的方法有主成分分析(Principal Component Analysis, PCA)^[29]、最小噪声分离变换^[30]、邻域保持嵌入(Neighborhood Preserving Embedding, NPE)^[31]和局部线性判别分析(Local Fisher's Discriminant Analysis, LFDA)^[32]等，然后结合支持向量机(Support Vector Machines, SVM)^[33]、随机森林(Random Forest, RF)^[34]、 k 近邻分类器(k -Nearest Neighbor, k NN)和逻辑回归(Multinomial Logistic Regression, MLR)^[35]等分类器，实现地物类别的最终判定。此外，还有一些基于领域专家知识的光谱特征提取方法，这些方法通过对光谱范围内的一些波段进行组合或微分运算得到诊断性的光谱指数特征，如归一化植被指数(Normalized Difference Vegetation Index, NDVI)^[36]、归一化差分水体指数^[37]和土壤调节植被指数^[38]等，上述这些光谱特征提取方法运算简单直观，但无法应对光谱信息不确定性对地物区分的干扰，只适用于大尺度范围内的粗略度量。考虑到不同类型的地物往往呈现出各不相同的大小、形状和空间分布等空间特性，研究人员意图利用高光谱图像蕴含的空间信息增加地物的可分性，常见的空间特征提取方法有扩展的多属性剖面特征(Extended Multi-attribute Profiles, EMAP)^[39]、灰度共生矩阵(Gray Level Co-occurrence Matrix, GLCM)^[40]、Gabor滤波器^[41]、局部二值化(Local Binary Pattern, LBP)^[42]和不变属性剖面特征(Invariant Attribute Profiles, IAPs)^[43]等，这些方法能够捕捉高光谱图像中地物的几何结构、形状和纹理等不同方面的特性，但仅依赖于空间特征的高光谱图像分类方法缺少了细节性的光谱信息，因而无法有效地对结构、成分高度相似的异类地物进行区分。

1.2.2.2. 基于空谱信息联合的高光谱图像分类研究现状

鉴于高光谱图像光谱信息和空间信息对地物特点表示的差异性，越来越多的学者致力于研究高光谱图像中地物的空谱特征表示，规避单一视图信息下地物表示的不充分，进而提升地物特征的鉴别能力，缓解图像中“同物异谱、异物同谱”等问题对图像解译的不利影响，从而实现减少地物错分和改善分类效果的目的^{[44][45]}。早期基于空谱信息的高光谱图像分类方法主要是通过不同的光谱特征和空间特征方法预先对高光谱图像数据进行信息处理，再通过特征级联^[39]或核函数^[46]等方法进行光谱特征和空间特征的整合，最后结合分类器实现地物类别的判定。后期，研究人员引入流形学习^[47]、表示学习^[48]等思想，改善地物特征的判别性和

鲁棒性, 进一步提升地物的分类精度。例如, Gao 等^[49]将提取出的 LBP 空间特征与光谱波段按照矢量级联方式进行联合, 通过构建随机多图(Random Multi-Graphs, RMGs) 实现基于空谱信息联合的地物分类。Hong 等^[50]提出了一种鲁棒性的局部流形表示方法 (Robust Local Manifold Representation, RLMR), 通过全局和局部数据的归一化实现目标样本的层次化近邻样本筛选, 并结合空间上下文信息获取更具鲁棒性的重构权重系数。Jiang 等^[51]提出了基于 Laplacian 正则化协同表示 (Laplacian Regularized Collaborative Representation Projection, LRCRP) 的特征提取方法, 学习地物样本全局信息的同时保留了高光谱数据隐含的局部流形结构。Zhou 等^[52]则设计了基于空间峰值感知的协同表示方法 (Spatial Peak-Aware Collaborative Representation, SPaCR), 将图像分割后各个超像素簇中的空谱信息融入归一化项中, 从而改善高光谱图像的分类效果。

近年来, 深度学习通过对人脑神经结构进行模拟, 将低层次的概念不断地进行学习, 进而得到目标的高层次特征表示, 在高光谱图像分类领域得到了研究人员的广泛关注^[53]。例如, He 等^[54]提出了一种多尺度三维深度卷积神经网络框架 (Multiscale 3D Deep Convolutional Neural Network, M3D-DCNN), 对高光谱图像中地物的二维多尺度空间特征和一维光谱特征进行联合学习, Hamida 等^[55]为了保留高光谱三维立体结构的内部特性, 利用 3D CNN 框架提取地物的空谱特征。Gao 等^[56]构建了基于 CNN 的多类型特征提取框架 (CNN-based Multiple Feature Learning, CNN-MFL), 利用多个 CNN 模块同时挖掘高光谱图像中地物的光谱和空间上下文特征信息, 取得了较为理想的解译效果。在文献^[57]中, 研究人员提出了集成多类型 CNN 分类器的分类方法 (Ensemble of Multiple CNN Classifiers, EM-CNN), 通过基于 CNN 基本模块的多个特征提取模型提取地物的空谱特征, 最后联合集成学习的思想整合分类结果提升类别预测的合理性和可靠性。为了更好地实现高光谱内在的空谱信息学习, 提升不同类别间地物特征的辨识度, Hong 等^[58]将具有局部信息提取能力的 CNN 和注重长程拓扑结构挖掘的图卷积网络 (Graph Convolutional Network, GCN) 相结合, 提出了一种可训练的端到端的小批量图卷积网络框架 mini-GCNs, 捕捉类内地物隐含的空谱关系, 展现出了良好的鲁棒性和可观的分类效果。Zhong 等^[59]将空间注意力机制和光谱关联模块进行整合, 提出了基于空谱 Transformer 网络框架 (Spectral-spatial Transformer Network, SSTN) 的特征提取方法, 通过捕捉长程距离上地物的隐含关联, 提升地物的分类精度。

1.2.3 高光谱图像小样本分类研究现状

高光谱图像虽然蕴含着丰富的光谱信息, 但相应的数据维度也较高, 当标记

样本数目有限时, 分类模型难以通过训练获取到最佳的参数, 极大程度地削弱了模型对不同类别地物的区分能力, 导致小样本条件下高光谱图像的解译效果大幅度下降^[60]。在实际应用中, 标注高光谱图像中的地物类别往往耗时费力且人工成本昂贵, 因而高光谱图像解译往往面临着标记样本数目稀缺情况下, 难以有效区分地物类别以及保证分类结果准确性等技术难题^[61]。为了解决上述问题, 国内外研究人员分别从样本数据、算法模型等两个方面开展了一系列研究, 前者主要通过引入半监督学习^[62]、主动学习^[63]等思想对待分类目标高光谱图像中的无标记样本进行自动类别标注和筛选以达到增加标记样本数量的目的, 或是利用迁移学习^[64]的思想克服不同场景间地物表示的差异性, 从具有丰富标记样本的其他场景图像中学习对待分类目标场景可利用的语义知识信息, 后者则侧重于分类模型的调整和改进, 利用度量学习、少样本学习等^[65]思想优化分类模型, 使其更适用于小样本条件下的高光谱图像分类任务^[66]。

样本扩充作为一种直观的解决方案, 通过一定的技术手段扩充原始有限的标记样本集, 从而缓解分类模型性能对标记样本数目的重度依赖^[67]。在同一幅高光谱图像中类别相同的地物样本在空间分布往往呈现连续密集分布的状态, 因此, 研究人员试图通过局部窗口或超像素块^[68]挖掘出类内样本的密切关联, 降低错误样本被筛选的可能性, 提升样本扩充的可靠度。例如, Shang 等^[69]以每个标记样本为聚类中心, 对其周边 8 近邻样本进行基于欧氏距离和光谱角度的相似区域聚类, 进而筛选出代表性的扩充样本。Su 等^[70]利用基于核概率联合表示分类器获得无标记样本的分类结果, 然后在标记样本的局部窗口区域内, 通过中心类别一致性、形态学结构筛选每一类别的候选样本集, 结合集成学习确定最终伪样本集的伪标签。Liu 等^[71]在图像分割后得到的高光谱图像超像素块内, 引入密度峰值聚类算法和主动学习策略实现扩充样本的筛选。Zheng 等^[72]设计了基于超像素引导的样本扩充方法 (Superpixel-Guided Training Sample Enlargement, SGTSE), 利用小尺度的超像素分割方案, 筛选出内含标记样本类别一致的超像素块用于样本扩充, 结合添加了距离加权的 MLR 分类器, 进一步提升了地物分类精度。

深度学习通过模拟人脑神经的感知过程, 对待处理数据进行逐级式的信息整合, 从而获取到不同层次的特征表示, 但由于网络框架中有大量的参数需要训练, 当标记样本数目有限时, 基于深度学习的高光谱分类方法往往会出现模型训练困难、特征提取性能下降和分类结果不理想等问题。针对上述问题, 研究人员试图利用样本扩充和模型优化策略, 缓解深度学习分类模型对标记样本数目的重度依赖^[73]。例如, 部分学者通过平移缩放、旋转剪切、添加噪声和随机遮挡等^{[74][75]}不同的操作, 增加标记样本的数量和多样性, 达到样本扩充的目的。除此之外, 前

文所述基于窗口或超像素的样本扩充方案，也同样被应用于深度学习框架中，从而削弱分类模型性能对标记样本数目的敏感性。Fang 等^[76]利用不同尺度的卷积神经网络 CNN 对无标记样本进行类别的初步预判，然后结合最大投票法筛选用于扩充的样本集。Niu 等^[77]通过统计无标记样本局部窗口内标记样本类别及其与不同标记样本集的光谱角，获取无标记样本预设的标记结果，结合局部和全局约束实现样本扩充。Yao 等^[78]每一次选取部分标记样本对 CNN 进行训练并获取样本的类别概率，然后结合超像素内的样本类别熵和主动学习策略选出最具有信息量的候选样本，从而改善小样本条件下的图像解译效果。Yue 等^[79]通过光谱域和空间域的三维变换实现原始数据的扩充，并通过结合自适应蒸馏的自监督学习 (Self-supervised Learning with Adaptive Distillation, SSAD)，实现模型的训练和无标记样本标签的自适应生成。

迁移学习，即利用从一个环境中学到的知识来帮助完成新环境中的分类任务，可以解决标记样本数目不足对当前分类任务的制约问题，但基于迁移学习的高光谱小样本分类方法往往需要克服数据分布差异性的问题，确保引入知识信息的准确性^[80]。例如，Zhang 等^[81]对 3D CNN 模型进行轻量化改进，减少需要训练的模型参数，并提出基于跨传感器的高光谱源数据集和跨模态的 RGB 图像数据集等两种可选的迁移学习方案，实现分类模型的预训练处理。Ahmad 等^[82]则是将主动学习和迁移学习思想整合，每轮选取出最具信息性的样本进行扩充，并冻结了紧凑型 3D CNN 模型中的部分参数，保证下一轮的模型训练仅需要进行微调而非再次的重新训练，降低分类模型对标记样本数目的需求。在文献[83]中，作者分别考虑了基于联合卷积稀疏分解和多尺度空谱特征提取的同构域适应和异构域适应高光谱分类方法，用以实现从标记样本数目较为充足的源域向待分类的目标域进行知识迁移。Deng 等^[84]设计了基于深度度量模型的高光谱小样本分类方法 (Similarity-based Deep Metric Model, SDMM)，通过引入基于度量学习的损失函数，在特征映射空间中减小类内间距并增大类间间距，在同场景和跨场景的高光谱小样本分类任务中都展现出了较为理想的分类结果。

少样本学习意图通过单个或少量样本的特性学习，促使模型能够快速认识地物目标的信息概念，从而实现对未知类别地物样本的内容理解和准确识别，一经问世就受到了业内研究人员的广泛关注。例如，Liu 等^[85]设计了基于 3D CNN 特征提取的深度少样本学习方法 (Deep Few-Shot Learning, DFSL)，利用从标记样本集中学习到的度量空间提升无标记样本的区分度。随后，作者还设计了基于深度多视图学习 (Deep Multi-view Learning, DMVL) 的小样本分类方法^[86]，通过学习地物样本视图不变特征，显著地提高了地物分类精度。Li 等^[87]考虑到不同传感器所

采集高光谱图像的差异性，提出了深度跨域少样本学习方法（Deep Cross-domain Few-Shot Learning, DCFSL），通过在源域和目标域中同步进行少样本学习，缩小域间的差异，利用学习到的源域可迁移类别信息和目标域特征提取模型，缓解高光谱分类模型在小样本条件下性能退化的问题。

1.2.4 基于异源遥感数据辅助的高光谱图像分类研究现状

近年来，伴随着传感器、计算机和航天通信等技术的日新月异，从不同传感器收集到的遥感数据日益便利，这为对地观测和地表目标识别提供了种类丰富的多模态数据信息，如全色、多光谱和高光谱等遥感图像、合成孔径雷达（Synthetic Aperture Radar, SAR）以及激光雷达 LiDAR 数据等^[88]。相较于单一传感器获得的对地观测数据而言，多源遥感数据包含了对于同一场景区域更为丰富、更加全面的地物表示信息，且当今对地观测技术在农业、环境和军事等领域的应用需求不断攀升，因此，研究人员试图利用多源数据融合突破单源高光谱图像数据在地物种类识别的局限性^[89]。例如，利用具有更高空间分辨率的多光谱或是全色图像数据，可以有效地增强高光谱图像的空间分辨率，克服成像过程中空谱信息难以同时兼顾导致高光谱图像空间信息退化的问题^[90]；结合全天候观测 SAR 数据中的空间结构信息，可以提升在复杂场景中对高光谱图像地物目标内部精细结构的识别能力^[91]；借助 LiDAR 数据提供的地表三维空间信息，可以弥补高光谱图像在高程维度上的信息缺失，增加不同类型地物目标区分时的细节信息^[92]。其中，高光谱和 LiDAR 数据以不同的成像方式获取同一场景的地表观测内容，二者在地物信息呈现上不仅有各自的独特性还具有较强的互补性，因而，通过高光谱和 LiDAR 数据的有效融合提升对观测区域内地物类别信息的准确理解，实现更加精准的地物类型判别和分析^{[93][94]}，成为了高光谱图像高精度解译和应用邻域的研究热点。但由于高光谱图像和 LiDAR 这两种不同模态的数据在内容表现上存在着明显的异构性和差异性，因而如何实现地物跨模态的联合表示和鉴别性特征的有效提取一直是高光谱图像和 LiDAR 数据联合分类应用领域内亟待解决的一项重大难题^[94]。

按照传统图像融合层次的区别，可以将多源遥感数据联合分类方法划分为像素级融合、特征级融合和决策级融合等三个主要类别^{[93][95]}，像素级的多源数据融合往往面向精确对准后的同质遥感数据如高光谱和多光谱图像数据，属于图像融合中最低层次的处理方式；特征级的多源数据融合旨在生成不同于单一数据源的新型地物特征，特征提取方法的有效性直接影响不同类型地物特点的识别，灵活性更高，但缺乏针对复杂成像环境的普遍适用性；决策级融合方式依据对目标性质的初步判断按照规定的决策规则进行融合，可以获得更鲁棒性更高、容错性更

强的分类结果，但对前期的预处理过程要求较高。由于高光谱图像和 LiDAR 数据来源于不同的成像机理，存在着明显的多源信息异构性，因此，特征级融合方案更适合二者的信息融合，且逐渐成为高光谱和 LiDAR 数据联合地物分类的主流研究方向。除此之外，考虑到不同层次上多源数据融合的优缺点，特征-决策级混合型的多源融合方法优势日渐凸显，并呈现出了日益增长的发展趋势。

1.2.4.1. 基于特征级信息融合的高光谱和 LiDAR 数据联合分类

为了满足地物类型精准识别日益增长的应用需求，基于特征级信息融合的多源数据联合地物分类方法，通过整合多源数据在地物表达上的不同特点，进而获取到比单一数据源更加丰富的地物特征和更为准确的解译结果^{[92][95]}。早期研究人员采用不同类型的空间特征方法，对多源数据的空间特征和其他衍生特征进行级联组合^{[96][97]}，然后结合 SVM、RF 等分类器获得了明显优于单一数据源分类的精度。例如，张等^[97]将主成分分析 PCA 提取的光谱特征、归一化植被指数、红边特征和 GLCM 空间特征以及高度特征进行级联，借助 RF 分类器实现地物分类，但这种多类型特征的堆叠方式没有考虑到不同类型特征在地物内容表达上的差异性和互补性，很容易造成特征信息冗余和分类模型的过拟合。在上述研究的基础上，研究人员通过引入图结构^[98]、核空间^[99]和稀疏低秩模型^[100]等不同的方法对地物的多源异构信息进行深层次融合，从而提升多源数据联合分类过程中信息融合的有效性和地物判别的准确性^[101]。例如，Gu 等^[102]在异构特征融合过程中添加类内和类间的相似性度量约束，实现基于判别式的多源数据图融合；Zhang 等^[103]针对多模态数据的各自特性，设计了基于复合核的局部 Fisher 判别分析算法，引入权重系数用以平衡多源数据和优化特征空间；Rasti 等^[104]提出正交全变分成分分析法（Orthogonal Total Variation Component Analysis, OTVCA），去除多源数据中地物冗余信息的同时，有效地融合了光谱信息和多源数据的空间消光特征；Duan 等^[105]采用低秩表示模型对多源数据提取出的多级结构特征（Multi-level Structure Extraction, MSE）进行融合，然后通过最大后验估计模型确定地物的最终类别标签。

近年来，深度学习以其强大的信息挖掘能力和地物特性表征能力在高光谱图像地物分类应用中取得了令人瞩目的成绩，基于此，研究人员在对多源数据处理时添加深度学习模型，从而提取出更高阶的地物特征，在多源联合地物分类中展现出长足的进展^[92]。早期的研究方法采用了被广泛使用的卷积神经网络 CNN 作为基础框架，通过双分支或多分支的卷积网络框架实现多源数据的特征提取和地物分类^{[106][107]}。后期，研究人员也将一些革新性的深度学习框架整合到多源数据的联合分类任务中，例如，Hong 等^[108]在基于编码器-解码器的融合框架后端添加全连

接网络 (Fully Connected Networks, FCNets), 从而实现像素级的地物类别分配。此外, 作者还提出了一种基于 CNN 模块的多模态深度学习方法 (Multimodal Deep Learning, MDL) 用于挖掘多源数据中地物的深层次特征表示, 并将编码器-解码器结构引入到多源数据的融合网络框架中 (Encoder-decoder Network, EndNet)^[109], 采用跨模态的重建策略最大程度上地激活模型中的各个基本单元。Ding 等^[110]设计了全局-局部 Transformer 网络模型 (Global-Local Transformer Network, GLT-Net), 通过将局部空间卷积编码特征与全局谱序列编码相结合, 显著地提升了分类结果的精度。Wu 等^[111]将即插即用的跨通道重建模块 (Cross-Channel Reconstruction, CCR) 添加到 CNN 框架中, 从而学习到更为稠密的多模态特征, 提升了不同类别间地物特征的区分度。

1.2.4.2. 基于特征级和决策级信息融合的高光谱和 LiDAR 数据联合分类

基于不同层次的多源数据信息融合方法存在着各自的优势, 彼此并非对立不兼容^[89], 基于特征-决策级联合的多源数据融合方案能够规避单一层次上多源信息融合存在的弊端, 从而提升地物类别判断的合理性和正确性。早期, 研究人员对多源遥感数据进行不同类型的特征提取, 然后对不同类型特征对应的分类结果进行决策级融合, 最终实现地物类别的判定。例如, Liao 等^[112]对高光谱图像的光谱信息和多源数据衍生的 MP 空间特征进行基于图的特征融合, 采用 SVM 分类器对前三种独立的特征和融合后的特征分别地物分类, 最后利用加权的最大投票法对上述四种条件下的分类结果进行整合。Ge 等^[113]对多源数据提取出的 EP 和 LBP 空间特征以及光谱信息计算基于 Tikhonov 正则化核协同表示的重构残差, 残差参数反映了不同类别下样本的特性, 根据重构残差进行决策层面的融合, 减小错分样本数目。曹等^[114]将不同类型的光谱特征与 GLCM 空间特征和 LiDAR 高程信息进行层叠, 然后通过决策级融合对最大似然分类、MLR 和 SVM 等多个分类器产生的地物分类结果进行整合, 最后利用 LiDAR 数据的建筑物掩膜对分类结果进一步优化。Zhong 等^[115]同样采用了上述三种分类器对 NDVI 光谱特征、GLCM 空间特征和 LiDAR 高程信息级联后的混合特征进行分类, 通过加权投票的决策级融合进行多分类结果的整合, 并引入条件随机场的后处理方式改善分类效果。Jia 等^[116]设计了基于多类型特征的超像素级决策融合方法 (Multiple Feature-Based Superpixel-Level Decision Fusion, MFSuDF), 首先利用核主成分分析对高光谱进行降维处理, 随后基于 2D Gabor 和 3D Gabor 挖掘多源数据中地物光谱、空间和高程信息, 最终结合 RF 和象限二进制编码分类器实现地物分类。

考虑到多源数据衍生出的多类型特征堆叠会带来一定的信息冗余, 分类结果

的不确定性将会影响后续决策级融合后最终判别结果的准确度，研究人员引入深度学习思想，提升多源异构信息在特征级层面融合的有效性，后续联合不同的决策级融合方案，改善地物分类精度。例如，Hang 等^[117]在挖掘多源异构特征时，设计了参数共享的双分支 CNN 通道，采用级联、求和、最大化等三种不同策略实现异质特征融合，然后采用决策级方案进行分类结果的整合，有效地减少了错分的样本数目。Lu 等^[118]提出了基于耦合对抗学习（Coupled Adversarial Learning-based Classification, CALC）的多源分类网络框架，首先利用耦合对抗特征提取网络模块联合学习到高层语义特征和低层细节特征，然后基于多级特征融合分类模块进行决策级的融合和分类，从而改善地物分类的精度。在文献[119]中，作者提出了一种基于特征-决策级协同融合的多源地物分类框架，利用多层次交互的融合模块间接地连接高光谱分支、LiDAR 数据分支和二者整合后的中间分支，以便增强多源数据中的共享互补信息，然后在决策层引入了一种动态权重选择策略，自适应地为三支的输出分配权重，从而优化特征表示，提升地物分类精度。

1.2.5 研究现状简析

通过对国内外研究现状的深入分析和梳理，高光谱图像分类技术作为遥感领域内的研究热点，历经多年的研究发展，从传统的统计学习方法逐步转变为结合多模态数据和机器学习、深度学习等算法的新型地物分类模式，在精细农业、城市规划、地质勘测和军事预警等诸多领域都体现出了卓越的应用价值，但在实际应用过程中也展现出了一些亟待解决的技术问题和挑战：

(1) 高光谱图像中空谱信息的联合利用一直是影响图像解译效果的核心要素，数据维度高和信息冗余度大等固有性质阻碍了地物鉴别性的特征提取和后续类别的准确区分。借助于流形学习的思想，通过挖掘高维数据中潜在的几何结构，将高维的高光谱数据投影到低维特征空间中，揭示不同类别地物的本质结构特性，达到维数约减和特征提取的目的，已成为高光谱图像分类方法中的重要研究方向。然而，现有方法大多采用光谱信息进行样本距离度量，忽视了地物样本在空间信息表示中的紧密关系，样本相似性衡量偏差大，同类地物样本内含关系挖掘不充分，难以准确地揭示地物本质流形结构，导致在嵌入的低维特征空间中同类地物样本聚合度不足以及不同类别地物间离散度较弱等问题，无法为后续高光谱图像分类任务提供有效的鉴别性地物特征。

(2) 尽管高光谱图像数据获取途径多种多样，然而标记样本不足的问题依然存在，并极大地阻碍了图像中地物目标类别的准确预估。考虑到同类地物在图像空间上往往呈现密集分布状态，现有高光谱小样本分类方法利用局部空间区域内

语义信息的关联性筛选伪标签样本集，用于扩充原始有限的训练样本集，从而缓解小样本条件下类别边界不清晰、分类精度低等问题。但由于成像区域地物种类繁多、地物目标尺寸分布差异性大，当前基于样本扩充策略的分类方法大多集中于地物样本局部空间中的关联性挖掘，忽视了图像中不同类型信息在揭示样本内在属性时的重要性，类内地物样本隐含的密切关系挖掘不充分，难以有效地应对目标场景复杂情况下的地物类型识别，导致分类模型的地物辨别能力弱、图像解译效果不理想。

(3) 虽然高光谱图像蕴含丰富的空谱信息，但缺少垂向的高程信息，联合 LiDAR 数据可以更加完整地描述地物目标特点，但多源异构信息融合的难度阻碍了高程信息在高光谱图像地物分类上的应用。目前，绝大多数的高光谱和 LiDAR 联合分类方法采用特征级的信息融合方式，克服单一数据源地物信息表示的不完整性和多源信息融合的异构性，提升地物特征的判别性和分类精度。然而，这类方法在地物内容表达上的互补性、差异性合作深度不足，导致地物特征表示单一，难以有效地挖掘出不同类别地物的本征属性。此外，依赖于特征-决策级信息融合的多源分类方法，虽然兼顾了不同层次信息融合方式的优势，但在不同信息表达层面对同类地物间的耦合关联性挖掘不充分，存在着分类精度不够理想、鲁棒性亟待加强等问题。

针对高光谱图像分类方法在上述情况中面临的一系列问题，本文以高光谱图像中地物的空谱信息联合利用为核心，从类内地物本质结构表征、小样本条件下地物关联信息挖掘和异构高程信息辅助下地物特征表示等方面进行分析和研究，构建更具有效性和鲁棒性的高光谱图像分类模型，从而为不同应用背景下地物解译任务提供技术支撑。

1.3 论文主要研究内容及组织结构

高光谱分类技术能够反映地物的类别、空间分布以及变化情况，具有广泛的应用价值，但在实际应用中仍然面临着一些问题和挑战，如在农业生产过程中农作物类型的有效识别，对后续的长势监测、产量预估等方面都有着重要的影响，但不同农作物间地物的光谱响应曲线十分接近，往往难以有效地进行类别区分；在城镇建设和管理应用中基础设施的区分，对后续的布局规划起到了重要的作用，但由于大部分设施内在材料成分相近，存在着光谱信息相似度高的情况，同时不同类型人造地物目标复杂的内部结构和空间分布，也增加了类间识别的难度，阻碍了高光谱遥感技术在农业信息化和城市智慧化发展中的应用。目前，传统的分类方法无法有效地应对光谱信息不确定性造成的类别区分干扰，而现有方法对类

内地物的密切关联和类间地物的细微差异挖掘不够充分，导致地物识别效果差、图像分类精度低。基于此，论文开展了空谱信息联合下基于地物多维特征提取的高光谱图像分类研究，整体框架如图 1-2 所示，首先对高光谱图像的成像原

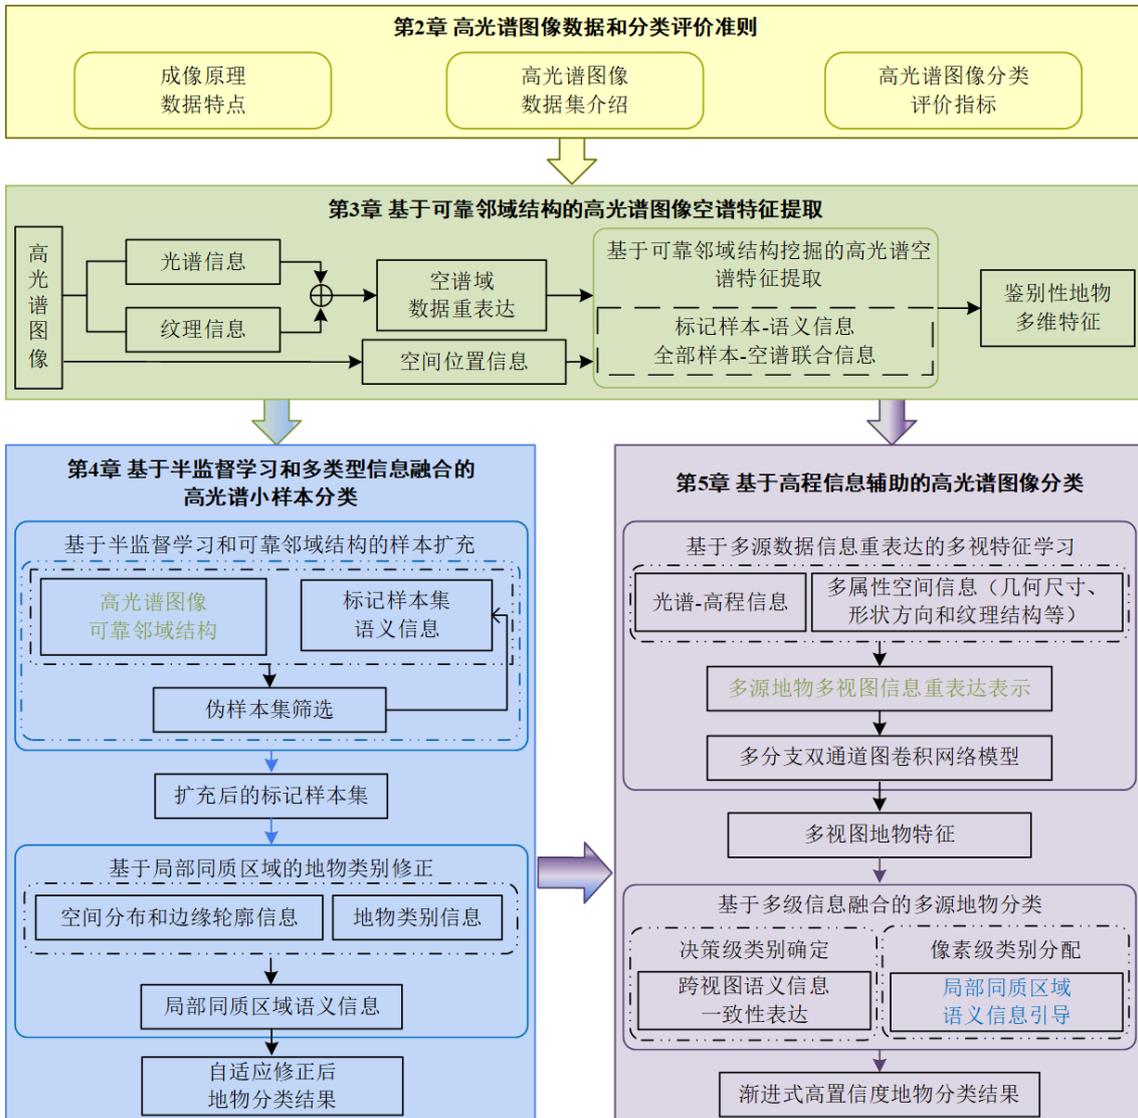


图 1-2 本论文整体框架

Fig. 1-2 Main framework of this dissertation

理和数据特点进行介绍，然后简要描述本文使用的数据集与高光谱图像的分类评价指标（第 2 章）。随后针对不同背景下高光谱图像分类模型的应用需求和技术难题，本文分别开展基于可靠邻域结构的高光谱空谱特征提取（第 3 章）、小样本条件下的高光谱图像分类（第 4 章）和高程信息辅助下的高光谱图像分类（第 5 章）等方法研究。其中，第 3 章中地物空谱域的信息重表达为后续两个章节的分类模型搭建奠定数据处理基础，同时，在第 3 章中基于空谱信息联合构建出的高可靠

邻域结构为第4章样本扩充策略的有效实现提供约束保障。此外，第4章构建基于局部同质区域语义信息引导的地物类别修正模型，在此基础上，本文在第5章中进一步设计基于多视特征提取和多级信息融合的渐进式高置信度地物分类方案，从而实现高程信息辅助下的高光谱图像高精度分类。各章主要的研究内容和逻辑关联如下：

论文首先面向高光谱图像分类任务中光谱信息不确定性对地物识别的干扰和类内地物本质结构难以有效挖掘等问题，研究基于可靠邻域结构的高光谱图像空谱特征提取方法。通过联合高光谱图像中地物的光谱、纹理和空间位置等多维信息，重新构建样本间的距离度量方式；在此基础上对邻域保持嵌入NPE算法进行改进，构建地物样本可靠邻域结构，挖掘出高光谱图像中地物隐含的本质流形结构；然后结合监督特征提取方法局部线性判别分析LFDA提取出鉴别性的地物多维空谱特征，为真实场景中地物类别的准确区分提供技术支撑。最后，论文通过多组国内外的高光谱图像数据集上进行地物分类实验，对所提空谱特征提取方法的有效性和适用性进行分析。

在上述研究基础上，论文在第4章中开展小样本条件下的高光谱图像分类方法研究。由于成像场景中地物种类丰富、空间分布复杂，当标记样本获取不充分时，传统的高光谱分类模型难以有效地判定地物目标的类别，通过分析图像中同类地物在高光谱图像中各类信息表示呈现出的深层次关联特性，设计基于半监督学习和多类型信息融合的高光谱小样本分类方法，首先利用第3章中可靠邻域结构展现出的语义信息一致性，结合已知的有限地物类别语义信息，生成高质量的伪标签样本集，进而实现对原始标记样本集的有效扩充；然后，通过地物的空间分布和边缘轮廓信息挖掘局部同质空间中类内地物的相关性，实现目标样本的自适应类别修正，从而提升小样本条件下高光谱图像解译模型的精度，为实际应用中标记样本稀缺条件下地物类别的有效区分提供技术支撑。为了验证所提方法的性能，对比实验选取不同场景的高光谱数据集和近年来所提的小样本分类方法进行论证。

针对高光谱图像在地物信息表达上缺失的高程信息，论文在第5章中研究基于多视特征提取和多级信息融合的高光谱与LiDAR协同分类方法。所提方法首先对第3章中地物空谱域信息重表达的概念进行拓展，利用不同属性的空间信息在描述地物几何尺寸、形状方向和纹理结构等方面时的各自特性，构建基于多属性空间信息的多源地物多视图信息重表达形式；其次，为克服多源数据地物内容表达的异构性，设计多分支双通道图卷积网络的特征提取模型，实现具有差异性和互补性的多视图地物特征提取；然后，在第4章所提样本类别修正方法的基础上，

结合多级信息融合的优势实现地物渐进式高置信度的类别预测，为高程信息辅助下高光谱图像的高精度地物分类应用提供技术支撑。通过与近年来的多源数据联合地物分类方法在不同数据集上进行分类性能对比实验，验证本章所提方法的有效性和适用性。最后，根据论文的研究内容和实际的应用需求，设计并搭建高光谱图像地物分类与分析软件，实现不同条件下的高光谱图像地物分类，拓展所提方法在地物类型区分与识别应用任务中的可行性和适用性。

第2章 高光谱图像数据和分类评价准则

2.1 引言

随着成像技术的进步与观测需求的激增，高光谱遥感技术正沿着“三多”、“三全”和“四高”的方向快速发展，时至今日，高光谱图像的采集来源丰富且日趋便利，为后续应用提供了充分的数据保障，异于其他遥感数据的独特性质，使其在地物分类应用中具有不可替代的重要作用。但高光谱图像的固有数据特点也使得高光谱地物分类应用面临着数据处理复杂度高、标记样本难以获取和光谱信息变异导致地物易混淆等问题。针对上述问题，本章首先对高光谱图像成像机理进行介绍，继而深度剖析了高光谱图像的数据特点，然后简要介绍本文实验使用到的数据集，包括高光谱单源数据集以及高光谱和 LiDAR 多源数据集，最后介绍高光谱图像分类结果的评价指标，为本文后续章节所提方法的性能验证提供支撑。

2.2 高光谱成像机理及数据特点

2.2.1 成像机理

高光谱遥感技术是基于成像技术和光谱技术相结合的多维信息获取技术，以被动式的数据获取方式采集探测区域内地物目标的二维几何空间信息以及相应的一维光谱信息，从而生成在宽谱段范围内具有连续且窄波段、三维立方体结构的高光谱图像数据^[120]。高光谱图像的采集平台往往由成像光谱仪、传感器、探测器及其他相关的精密机械设备组合而成，其中成像光谱仪是整个高光谱图像采集系统的核心部件，按照其光谱信息分光方式的不同，成像光谱仪主要可以分为色散型、干涉型和滤光片型等^[18]，色散型成像光谱仪主要包含棱镜色散型和光栅衍射型两类，前者利用介质对不同波长单色光折射率的差异，引发色散从而依次成像于探测器的不同位置上，后者利用衍射光栅将入射的复色光色散成不同方向出射的单色光；干涉型成像光谱仪将获取的光谱干涉图信息进行基于计算机技术的光谱傅里叶变换分析，从而获得地物目标的光谱分布；滤光片型则是通过添加线性可变滤光片、声光可调谐滤光片和液晶可调谐滤光片等不同类型的滤光片，达到分光的目的^[19]。此外，近年来提出的快照光谱成像技术利用空谱调制投影，通过单次曝光成像获得目标的二维调制投影数据，后期经解调处理重构出目标三维立方体结构的数据模式，在动态场景的目标探测方面有显著的应用优势^[121]。依据空间成像模式的不同又可将成像光谱仪划分为凝视型、摆扫型和推扫型等，凝视型

成像光谱仪结构简单、体积小、功耗低，但空间维度的图像信息与光谱维度的地物响应信息不能同时获取；摆扫型成像光谱仪利用摆扫镜的左右摆动实现一维空间成像，同时借助于其所搭载移动平台的向前推移完成另一维度空间信息的获取，具有较大的总视场，能够在线阵探测器上实现对瞬时视场中同一像元不同波段上的光谱信息采集，但需要采集设备具有较高的稳定性；推扫型成像光谱仪则是利用面阵探测器在瞬时视场中同时获得一维空间信息和一维光谱信息，并沿着搭载平台的飞行方向，补充另一维度的空间信息，能够实现高空间分辨率的三维高光谱数据采集，是业内广泛使用的高光谱成像模式^[122]。下面以星载 Hyperion 推扫式光栅色散型成像光谱仪为例，详细地介绍高光谱图像的信息采集过程。

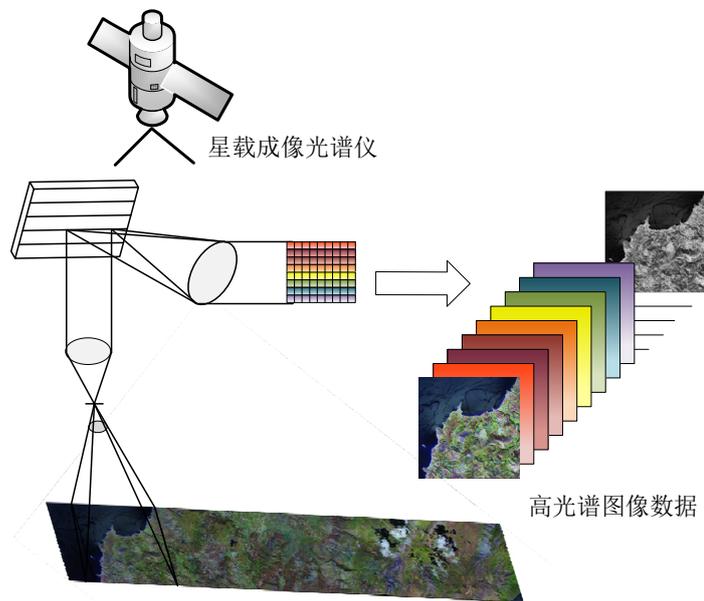


图 2-1 基于星载成像光谱仪的高光谱成像原理示意图

Fig. 2-1 Principle of hyperspectral imaging by spaceborne imaging spectrometer

星载高光谱成像光谱仪数据采集的原理示意图如图 2-1 所示，经前置光学系统获取后的光束由分光镜分成两路，反射光路是谱段范围在 400-1000 nm 的可见光，透视光路是谱段范围约为 900-2500 nm 的短波红外光，两束光分别通过光栅进入焦平面装置，当复合光束以某一入射角透射入衍射光栅后，基于光的干涉衍射原理将原入射的复合光分散为多个不同波长的单色光束，最终以不同的衍射角进入探测器成像镜中形成目标地物的光谱响应信息^[123]。在垂直于扫描移动方向的飞行平台上，成像光谱仪在瞬时视场中捕捉探测区域内的一维空间图像信息和经上述光学分光系统获取的光辐射信息，随着搭载成像光谱仪的飞行平台不断向前移动，最终完成观测区域内的二维空间扫描，得到成像区域的高光谱三维立方体数据，其中，图像中的每个像元反映了地物在一定波长范围内的光谱响应情况，不同类

型的地物像元在各波段的响应情况有所差异，利用这一特性可以用于实现不同类别间的地物区分。

2.2.2 数据特点

近年来，得益于传感器和计算机技术的飞跃发展，如今高光谱成像光谱仪可以采集到成像区域中地物目标上百个连续且狭窄波段的光谱响应信息，谱段范围覆盖整个可见光、近红外短波红外和热红外等区域，这一纳米级的光谱分辨率和大范围的光谱谱段覆盖，使得图像上的地物像元在光谱信息维度上呈现出近似连续的光谱响应曲线，并能够同时获取到地表的空間信息，这种图谱合一的独特性质使得高光谱图像在分析地物的组成成分、物质结构以及空间分布等应用上体现出了卓越的优势^[45]。但图像中相邻波段间的高度相关性，导致高光谱图像不仅具有较高的数据维度还存在着一定的信息冗余，此外，成像过程容易受到很多外界因素的干扰如光照、气候变化、云层厚度等，这加剧了“同物异谱”和“异物同谱”等现象，这种光谱信息的变异性一定程度上降低了地物类别的判别性以及不同类别地物之间的可分性。图 2-2 展示了城市区域成像背景下高光谱图像不同地物的光谱信息和空间结构及分布信息，从图中可以看到同一类别的地物样本呈现出具有差异性较大的光谱曲线，而不同类别的地物目标光谱曲线相似度又极高。此外，待分类场景中人造地物较多，不同地物目标的空間分布、结构尺寸往往具有较大的差异度，这种空間信息的多样性和光谱信息的变异性造成了高光谱图像数据处理复杂、解译模型设计困难等问题，给复杂背景下的高光谱图像地物分类应用增加了一定的难度。

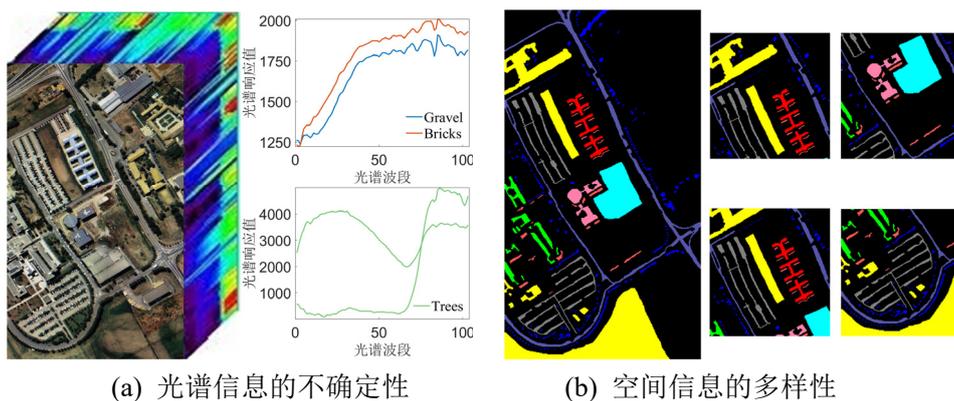


图 2-2 高光谱图像中的光谱信息变异性 and 空间信息多样性

Fig. 2-2 Spectral information variability and spatial information diversity in the HSIs

除了上述高光谱图像的固有数据特点以外，成像地区背景复杂和地物种类繁多使得高光谱图像中地物语义类别的标定往往需要相关领域内的专家们长时间协同作业或是实地调研，这不仅消耗大量的时间还耗费巨大的人力和物力，因而，

造价昂贵和标记困难使得现有的高光谱图像数据应用往往都存在着标记样本稀缺这一限制，加之上述高光谱数据自身的固有特点，使得高光谱图像分类模型容易出现“Hughes”现象，严重地影响了地物分类精度和后续应用。因此，在高光谱图像数据特点的深入剖析基础下，如何建立具有良好泛化能力的特征提取及分类模型，对高光谱图像地物分类的实际应用起到关键性的作用。

2.3 高光谱图像数据集

为了更好地验证所提方法在高光谱图像分类任务上的鲁棒性和适用性，论文采用不同成像背景和不同采集条件下的多组国内外高光谱图像数据集对各方法的有效性进行验证和分析，这些数据集不仅具有各异的空谱信息还包含了不同类型的地物目标，下面对论文使用的高光谱数据集进行简要介绍。

2.3.1 国外高光谱数据集

论文采用业内公开并广泛使用的国外高光谱数据集，包含两组单源高光谱数据集和两组多源高光谱和 LiDAR 数据集，以便更加充分地验证模型的泛化性能，这些数据集来自于不同的传感器和采集区域，各组数据集的主要信息如表 2-1 所示。此外，本节对各个数据集中的已知地物类别进行数字编号和颜色编码，展示了相应的中英文名称，在后续各章节中的分类方法横向对比中，均沿用本节对各数据集中的地物类别编号概念，下面分别介绍各组国外数据集。

表 2-1 各组国外数据集的主要信息
Table 2-1 Main information of each foreign dataset

数据集名称	印第安纳	帕维亚大学	休斯顿大学	特兰托
采集区域	Indiana	Pavia	Houston	Trento
图像场景	农林土地覆盖	城市基本 土地覆盖	城市基本 土地覆盖	农林土地覆盖
数据形式	高光谱	高光谱	高光谱、LiDAR	高光谱、LiDAR
传感器类型	AVIRIS	ROSIS	CASI 1500	AISA Eagle
图像尺寸	145×145	610×340	349×1905	166×600
波段数目	200	103	144	63
光谱范围 (μm)	0.4-2.5	0.43-0.86	0.38-1.05	0.42-0.99
空间分辨率(m)	20	1.3	2.5	1
类别总数	16	9	15	6

(1) 印第安纳数据集

该数据集拍摄于印第安的西北部部分区域，由美国国家航空航天局的机载可

见光/红外成像光谱仪(AVIRIS)在飞行高度为 65000 英尺的状态下进行数据采集。获取到印第安纳 (Indian Pines, IP) 高光谱图像的尺寸为 145×145 ，包含 220 个波段，去除吸水区域的波段覆盖后，保留了 200 个波段，覆盖的波长范围是 400-2500 nm，空间分辨率约为 20 m。该图像数据集标注了 16 种不同类别的地物，样本共计 10249 个，各类地物样本的平均光谱响应曲线如图 2-3 所示，数据集的假彩色图及真值图如图 2-4 所示，为了方便后续章节的使用，图中对不同类别的地物目标进行了数字编号。从图中可以看出，该数据集包含类型丰富的地物目标，绝大多数为相似度极高的植物，特别是同一科属下的不同类别地物如大豆和小麦，光谱曲线重合度较高，对实现高光谱图像的精确解译增加了一定的难度。

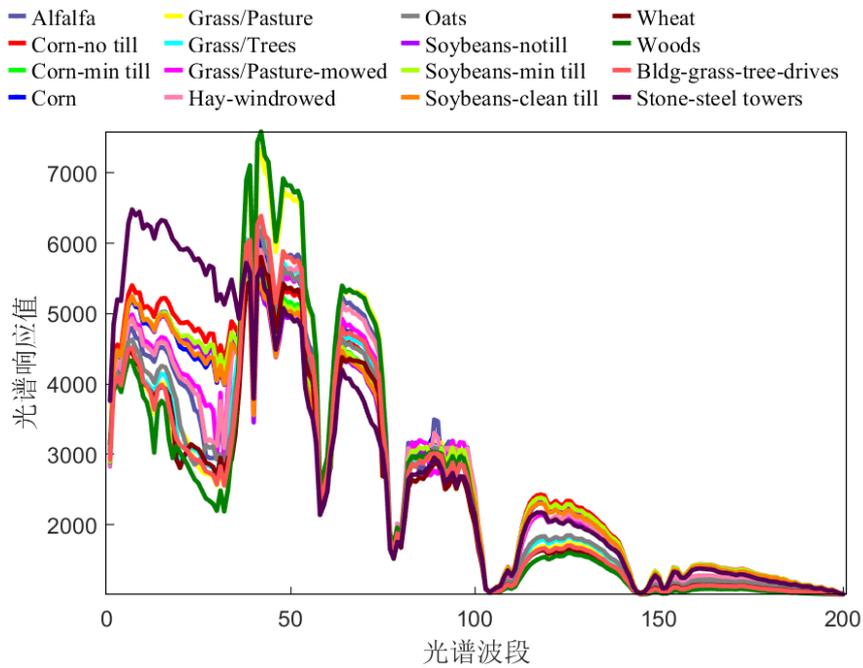
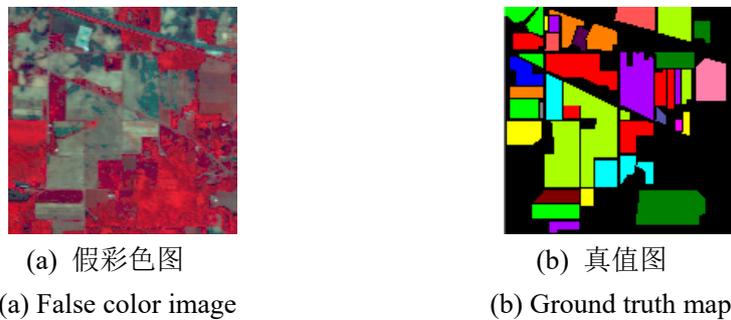


图 2-3 印第安纳数据集中不同地物的光谱响应曲线

Fig. 2-3 Spectral response curves of different ground objects in the IP dataset



(a) 假彩色图 (a) False color image (b) 真值图 (b) Ground truth map

图 2-4 印第安纳高光谱数据集

Fig. 2-4 Indian Pines Dataset

1 Alfalfa 苜蓿 (46)	9 Oats 燕麦 (20)
2 Corn-no till 免耕玉米 (1428)	10 Soybeans-notill 免耕大豆 (972)
3 Corn-min till 少耕玉米 (830)	11 Soybeans-min till 少耕大豆 (2455)
4 Corn 玉米 (237)	12 Soybeans-clean till 净耕大豆 (593)
5 Grass/Pasture 草地/牧场 (483)	13 Wheat 小麦 (205)
6 Grass/Trees 草地/树林 (730)	14 Woods 木材 (1265)
7 Grass/Pasture-mowed 修剪过的草地/牧场 (28)	15 Bldg-grass-tree-drives 建筑/草/树/机器 (386)
8 Hay-windrowed 干草料堆 (478)	16 Stone-steel towers 石/铁搭 (93)

(c) 地物名称及类别编号

(c) Semantic category and color code of ground objects

图 2-4 (续图)

(2) 帕维亚大学数据集

第 2 幅高光图像为 ROSIS 传感器在意大利北部帕维亚城市区域拍摄得到的帕维亚大学 (Pavia University, PU) 数据集, 其光谱覆盖范围为 430-860nm, 图像的大小为 610×340 像素, 空间分辨率为 1.3m/像素, 该数据内含 9 类标注的不同地物目标, 不同类别的地物目标对在各光谱波段上的响应情况如图 2-5 所示, 同样对不同地物类别进行数字编号和颜色标记以便后续使用, 假彩色图、真值图和地物类别的名称及数目情况如图 2-6 所示, 从图中展示的结果可以看到, 由于采集区域中人造地物较多, 存在着具有相似或相同化学材质的异类地物目标如砂砾和砖石、柏油路和沥青屋顶, 这些类别的地物目标具有高度相似的光谱响应曲线, 容易导致错分现象。

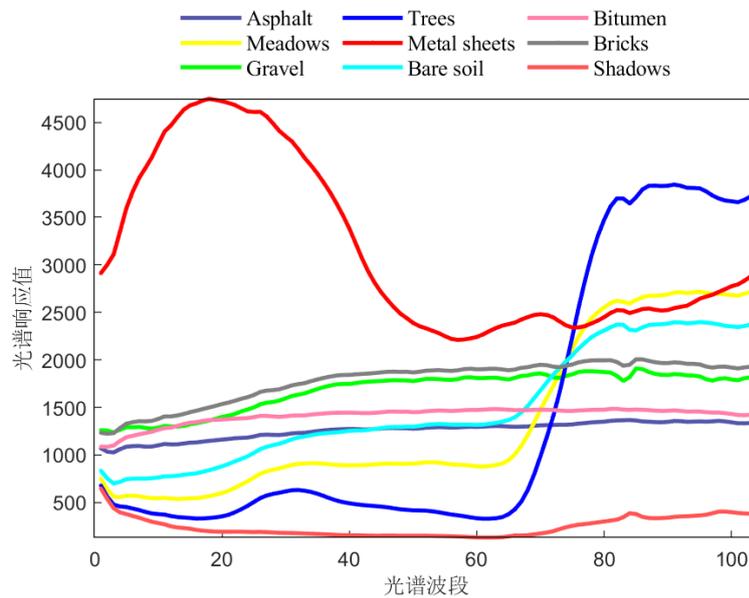


图 2-5 帕维亚大学数据集中不同地物的光谱响应曲线

Fig. 2-5 Spectral response curves of different ground objects in the PU dataset

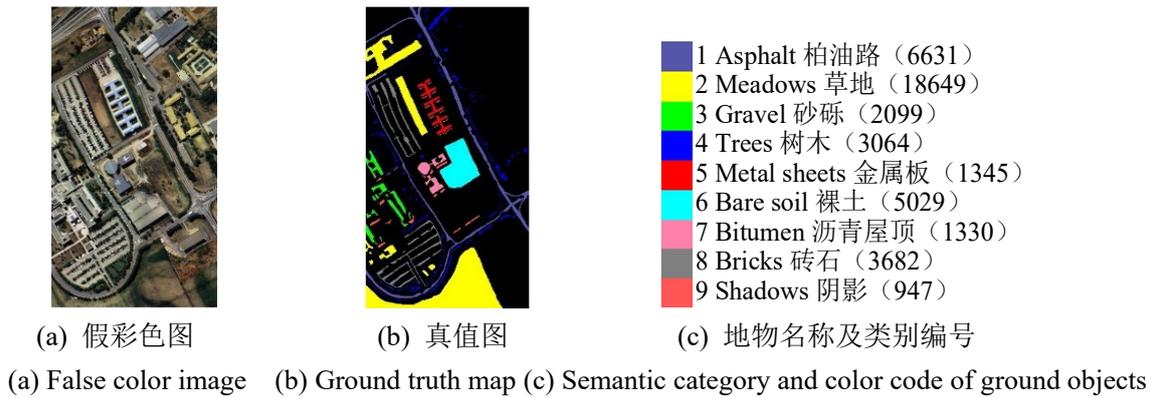


图 2-6 帕维亚大学数据集

Fig. 2-6 Pavia University Dataset

(3) 休斯顿大学多源数据集

该组多源数据集来自 2013 年 IEEE 地理科学与遥感协会发起的数据融合竞赛，拍摄区域是美国休斯顿大学及其周边的城市区域 (Houston University, HU)，其中高光谱图像由 CASI-1500 光谱仪采集获取，包含了 144 个光谱波段，覆盖从 380 nm 到 1050 nm 的光谱范围，图像的空间尺寸为 349×1905 像素，分辨率为 2.5m/像素，整幅图像对 15 类地表真实物体进行了标注，机载激光测绘中心提供了尺寸与高光谱图像一致的单通道 LiDAR 数据，蕴含着对应地面位置的海拔高度信息。图 2-7 详细地展示了每一类地物目标在成像光谱仪覆盖光谱范围内的平均光谱响应曲线，数据的高光谱假彩色图、LiDAR 示意图以及标记的地物类别分布和样本数目如图 2-8 所示。该数据集涵盖了较为丰富的地物类别，在图像上的分布也较为广泛，且

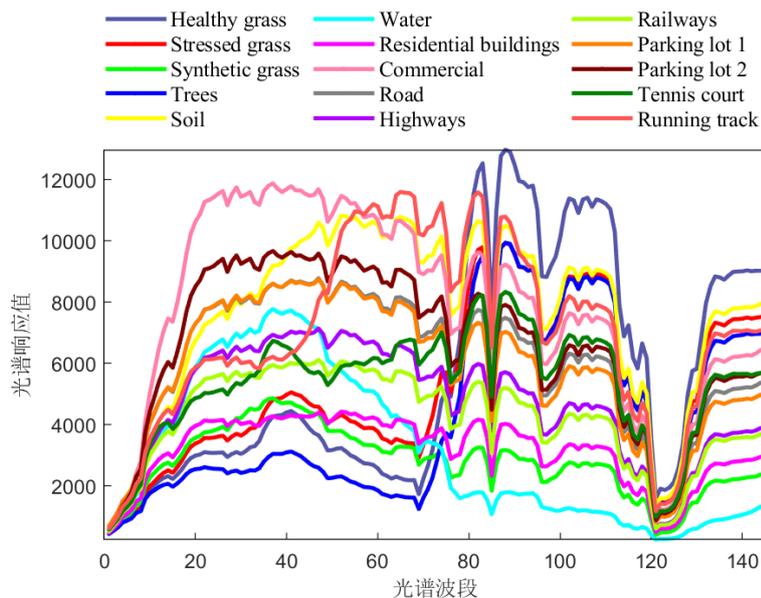


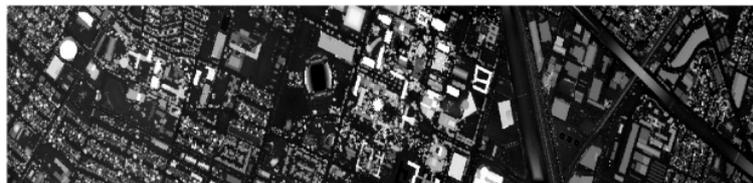
图 2-7 休斯顿大学数据集中不同地物的光谱响应曲线

Fig. 2-7 Spectral response curves of different ground objects in the HU dataset

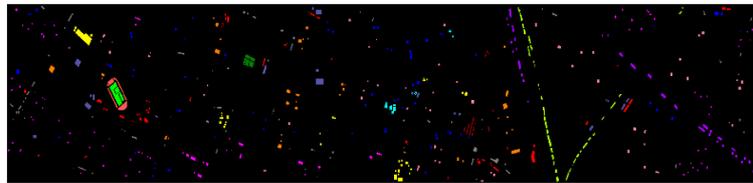
由于高光谱图像的采集过程中受到了云层遮挡，导致分布于阴影区内外的同一类别地物存在着较大的光谱差异性，这种光谱信息的变异性对地物类别的准确识别造成了一定的困难。



(a) 高光谱假彩色图
(a) False color image



(b) LiDAR 数据示意图
(b) Schematic diagram of LiDAR



(c) 地物真值图
(c) Ground truth map



(d) 地物名称及类别编号
(d) Semantic category and color code of ground objects

图 2-8 休斯顿大学多源数据集

Fig. 2-8 Houston university multisource dataset

(4) 特兰托多源数据集

该组多源数据集采集于意大利特兰托南部的农村地区，其图像大小为 160×660 像素，高光谱图像由 AISA Eagle 传感器拍摄获取，波段数目为 63，谱段范围

为 420-990 nm，空间分辨率为 1m/像素，LiDAR 数据是由 Optech ALTM 3100EA 传感器采集获得的对地海拔单通道高度信息，共标注了 6 种不同类型的地物目标，不同类别地物的平均光谱响应曲线如图 2-9 所示。高光谱假彩色图、LiDAR 示意图和真值图以及标记地物类别信息如图 2-10 所示，图中也展示了标注的地物类别编号和每类地物样本的数目情况。虽然标注的地物类别较少，但存在着较多光谱曲线高度相似的异类地物目标情况，如苹果树和葡萄园、苹果树和树木以及建筑物和道路等，且光谱相似度高异类地物在空间分布上也相距较近，实现高精度地物的分类与识别具有一定的挑战性。

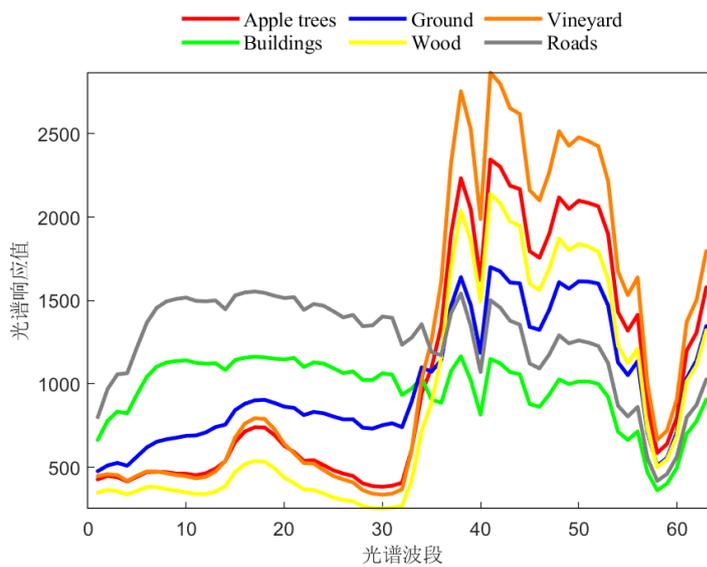


图 2-9 特兰托数据集中不同地物的光谱响应曲线

Fig. 2-9 Spectral response curves of different ground objects in the Trento dataset

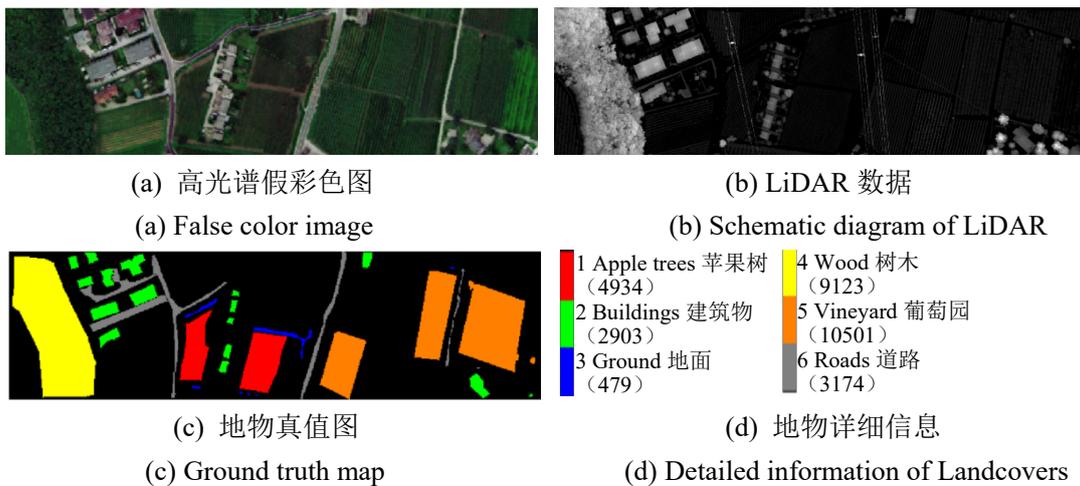


图 2-10 特兰托多源数据集

Fig. 2-10 Trento multisource dataset

2.3.2 国产高光谱数据集

为了进一步验证所提方法在高光谱图像分类任务上的适用性，论文选取了两组来自于不同采集条件和不同成像环境的国产高光谱数据集，这两组数据集的成像背景更为复杂，包含了更为丰富的地物类别，可以用于检验所提方法对不同类型地物间细微差异的敏感度。

(1) 唐岛湾区域数据集

该数据集在 2021 年 5 月份由 Gaiasky mini2-VN 无人机高光谱成像系统在飞行高度 300 m 的条件下进行拍摄，采集区域是我国山东省青岛市唐岛湾地区^[124]，空间分辨率为 0.15 m，光谱范围在 400-1000 nm，光谱波段数目为 176，光谱分辨率为 3.5 nm，本文截取了易混淆类别地物较为集中的区域进行所提分类方法的性能验证，区域空间尺寸为 270×310，共有 11 种不同类型的地物目标，由成像光谱仪采集到的不同地物辐亮度光谱响应曲线如图 2-11 所示，高光谱图像的假彩色图和地物类别的名称及数目信息如图 2-12 所示。从图中可以看到，该数据集的地物种类丰富且形态分布复杂，不仅包含了光谱响应曲线极为相似且不规则分布的植被地物，如草地和石楠，还覆盖了由相似材料组成的不同类型人行道如木板人行道和砾石道，大大地增加了地物类别区分的难度。

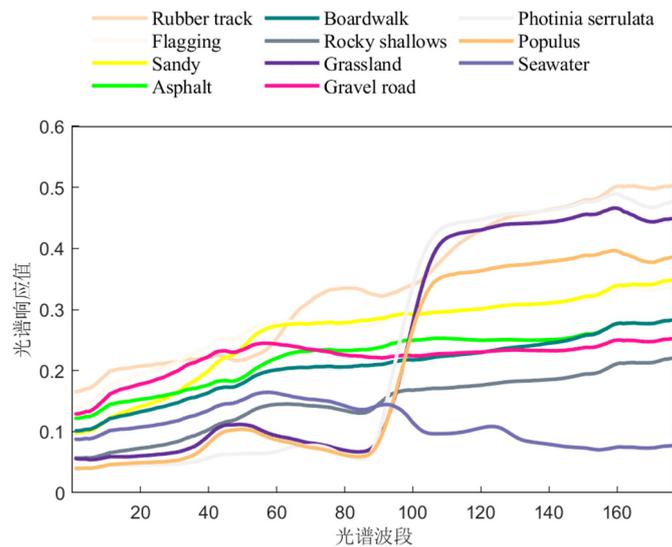


图 2-11 唐岛湾数据集中不同地物的光谱响应曲线

Fig. 2-11 Spectral response curves of different ground objects in the Tangdaowan dataset

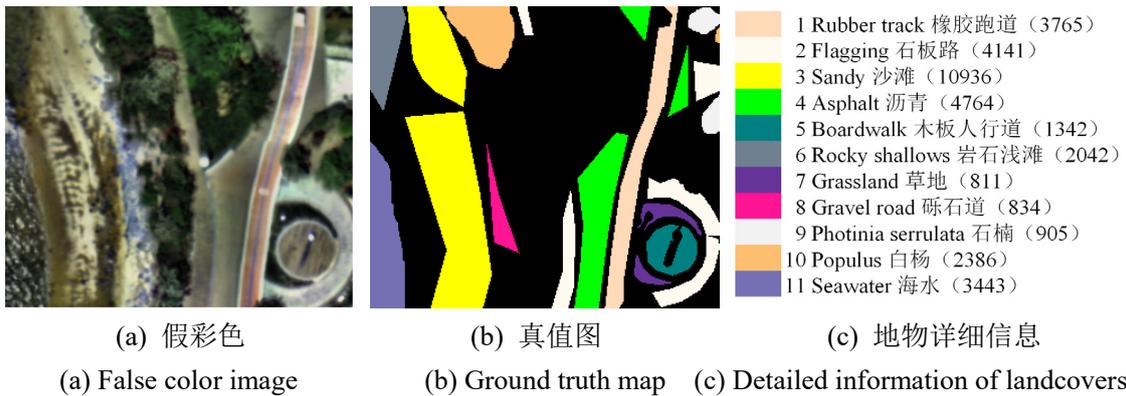


图 2-12 唐岛湾数据集

Fig. 2-12 Tangdaowan dataset

(2) 雄安新区数据集

该数据集由中科院遥感与数字地球研究所联合上海技术物理研究所于 2017 年 10 月在我国河北省雄安新区进行拍摄，在航飞高度为 2000m 的条件下利用我国中科院上海技物所高分专项航空系统全谱段多模态成像光谱仪进行数据采集^[125]，涉及到的光谱范围为 400-1000 nm，涵盖了 256 个波段，空间分辨率为 0.5m，本文从原始数据截取了存在着明显耕地细碎化情况的部分区域进行分析，得到的区域数据空间大小为 370×370，共有 8 种类别标注的地物目标，相应的不同地物光谱响应曲线如图 2-13 所示，数据的假彩色示意图、真值图和地物类别信息如图 2-14 所示。从图中可以看到，该数据区域包含了光谱信息相似的不同类型农作物如玉米和菜地，以及不易区分的多类型植物如复叶槭、草地和杨树等，实现高精度的地物解译具有一定的难度和挑战。

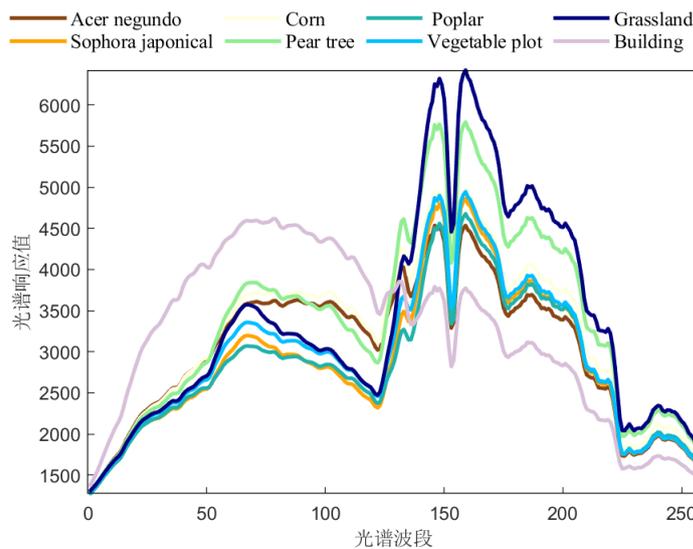


图 2-13 雄安数据集中不同地物的光谱响应曲线

Fig. 2-13 Spectral response curves of different ground objects in the Xiongan dataset

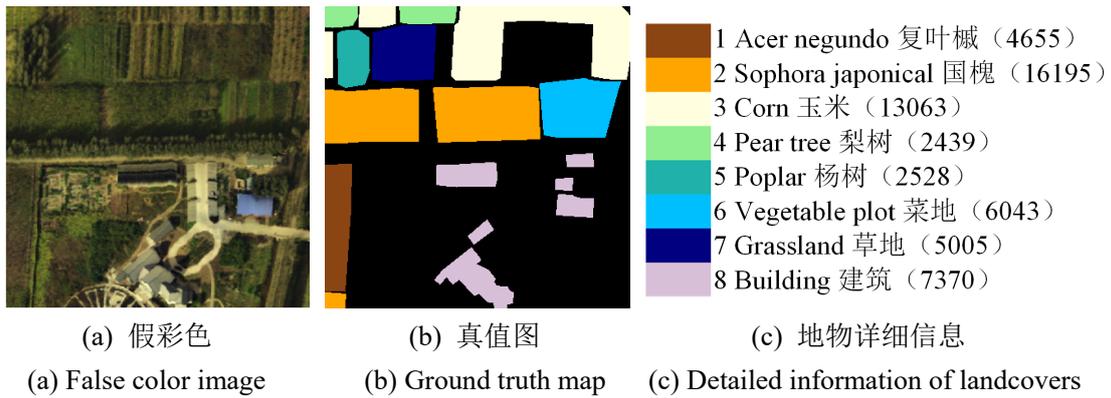


图 2-14 雄安数据集

Fig. 2-14 Xiongan Dataset

2.4 高光谱图像分类结果评价指标

高光谱图像的地物分类即根据已知的各类信息和一定的判别函数对图像中的像素向量分配指定的类别标识，依据该类别标识对相应的像素分配特定的类别标签，这一像素级的高光谱图像解译手段在农业生产、地质与矿产调查、生态环境保护等领域都有重要的应用价值。为了衡量不同高光谱图像分类方法的性能，常用的评价指标有总体分类精度（Overall Accuracy, OA）、类内分类精度（Class-specific Accuracy, CA）和 Kappa 系数（Kappa Coefficients, κ ）等^[126]。上述定量化评价指标一般通过对混淆矩阵（Confusion Matrix, CM）的进一步计算获得，混淆矩阵 CM 以方阵的形式提供了一种直观的地物分类结果展示，记录了不同类别下类别正确判别的样本数目和误判的样本数目，其表示形式如表 2-2 所示。

表 2-2 混淆矩阵

Table 2-2 Confusion matrix

分类结果	类别编号 1	类别编号 2	...	类别编号 C
类别编号 1	M_{11}	M_{12}	...	M_{1C}
类别编号 2	M_{21}	M_{22}	...	M_{2C}
...
类别编号 C	M_{C1}	M_{C2}	...	M_{CC}

混淆矩阵 CM 的行和列分别对应着不同的地物类别，第一行与第一列都对应着第一类别编号的地物，第二行与第二列都对应第二类别编号的地物，依此类推，对角线上的元素即表示当前行（或列）所对应的类别被正确分类的样本数目，而每一列中非对角线上的元素表示当前列对应的类别被错分到其它类别（对应其它行）的样本数目^[126]。假设高光谱图像包含了已经获取类别信息的 C 类地物，则混

混淆矩阵 M 可表示为一个 $C \times C$ 的方阵, 其中 M_{ij} 表示真实类别标签为 i 的测试样本被分类到类别标签 j 的像素样本个数, 总测试样本个数为 $N = \sum_i^C \sum_j^C M_{ij}$, 相应地各总体评价标准可通过以下的计算公式获得, 从而客观地评估不同分类方法的优劣。

(1) 总体分类精度 OA 作为最广泛使用的性能指标, 代表分类结果与参考标签类别的吻合程度, 能够量化地评价图像地物分类的整体效果, 依据上述混淆矩阵的定义, 其计算公式可表示为:

$$OA = \frac{\sum_i^C M_{ii}}{N} \quad (2-1)$$

(2) 类内分类精度 CA 代表每一类样本被正确分类的数据与该类别所有分类的样本数目之比, 可通过以下公式计算获得

$$CA_i = \frac{M_{ii}}{\sum_j^C M_{ij}} \quad (2-2)$$

(3) Kappa 系数 κ 是基于对测试集中每个样本的预测类别标签和实际类别标签的比较, 得到的分类一致性评价指标, 可以由下式计算得到:

$$\kappa = \frac{N \times \sum_i^C M_{ii} - \sum_i^C \left(\sum_j^C M_{ij} \times \sum_j^C M_{ji} \right)}{N^2 - \sum_i^C \left(\sum_j^C M_{ij} \times \sum_j^C M_{ji} \right)} \quad (2-3)$$

为了消除标记样本随机抽取的不定性、确保所有方法评价的结果公平性, 上述各项评价指标往往都是通过重复数次的实验计算获得的平均数值结果, 且在每轮的实验过程中, 训练样本均采用随机方式从已知类别的地物样本中进行抽取。除了上述定量评价指标外, 本文也采用了高光谱图像分类结果图的视觉比较, 从而能够更加直观地显示不同方法的解译性能。

2.5 本章小结

本章简要介绍了高光谱图像的成像机理, 并对高光谱数据的特点进行了分析。说明了论文所采用的高光谱数据集和分类结果评价标准, 为分类模型性能的验证提供支撑。

第3章 基于可靠邻域结构的高光谱图像空谱特征提取

3.1 引言

高光谱图像具有立方体的数据结构，图像中的每个像素都可以表示为一个对应于不同光谱波段的单维光谱响应向量，能够反映地物特定内在成分的属性信息，并为地物类别判断提供依据。但由于成像条件易受光照、大气、拍摄角度等外界条件影响，高光谱图像很容易出现“同物异谱”和“异物同谱”现象，即同类地物的光谱信息差异性大而异类地物的光谱信息相似度高，如图 3-1 所示的帕维亚大学高光谱图像，其中空间位置相距较近的同类别地物样本间出现了显著的类内光谱差异性，而不同类别的地物样本间光谱响应曲线又极其吻合，上述情况极大地增加了地物类别准确区分的难度。目前，现有的高光谱特征提取方法在度量样本之间的相似度时，往往着重于单一光谱信息的利用，忽略了同类地物样本在空间信息表达中的密切关联，导致重构模型为目标样本错选异类地物样本或是选取不到同类别中的最佳近邻样本，造成较大的重构误差，无法揭示数据内在的本质结构并提取出有效的判别性地物特征，导致最终分类精度低、图像解译效果差等问题。

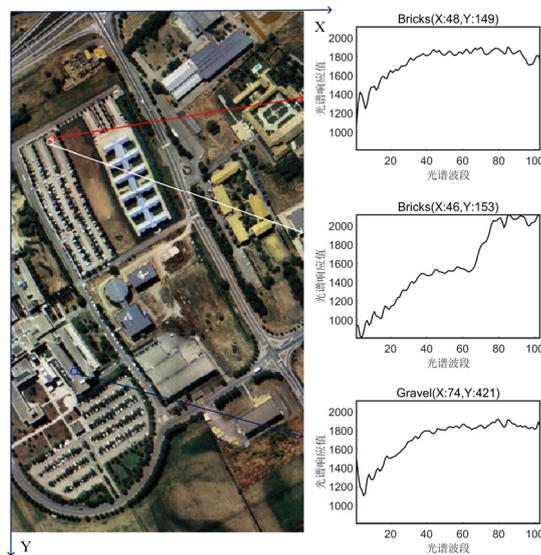


图 3-1 帕维亚大学中不同地物像元的光谱响应信息

Fig. 3-1 Spectral reflectance curves of different pixels in the PU dataset

考虑到高光谱图像具有“图谱合一”和丰富空谱信息的独特数据特点，每个像素除了光谱信息之外，还隐含着自身属性相关的纹理结构和空间分布等空间信息，特别是同类地物往往具有较强的空间相关性，基于上述分析，本章提出了一

种联合空谱多维信息的样本相似度度量方式，首先采用纹理信息和光谱信息对原始数据进行空谱域的地物信息重表达，然后结合能够反映图像上地物空间分布的位置信息共同衡量样本间的相似度，提出了一种能够充分挖掘同类样本高度相关性的改进邻域保持嵌入法 NPE，构建可靠的地物样本邻域结构，从而更加准确地揭示出高维高光谱数据内在的流形结构。最后，结合能够挖掘标记样本集语义信息的局部线性判别分析法 LFDA，实现高光谱图像地物的鉴别性空谱多维特征提取。本章在流形学习思想的基础上，联合高光谱图像中的空谱信息和语义类别信息对地物多维特征提取进行研究，首先对相关的基础理论进行介绍，然后详细地阐述本章所提的特征提取方法，最后，通过消融实验和多组高光谱图像的分类实验分析和验证所提方法的有效性和适用性。

3.2 流形学习基础理论

高光谱图像不仅具有图谱合一的独特数据，还包含了丰富的光谱信息和空间信息，空间信息反映了地物的形状、大小及与周边地物的关系，光谱信息则揭示了不同类型的地物对不同波长电磁辐射的响应值，在地物分类与识别领域应用十分广泛。但由于光谱波段数目高、间隔短，导致高光谱数据维度和冗余度较高，在进行数据处理时，不仅计算量大、处理难度高，需要占据较大的存储空间，还很容易出现维数灾难引起的“Hughes”现象，这极大地阻碍了高光谱图像数据的后续应用。因此，研究人员提出利用流形学习的思想，通过学习高维高光谱图像数据内含的几何结构，获取从原始高维空间到低维特征空间的映射关系，进而实现高光谱图像的数据降维和特征提取^[127]，如图 3-2 所示，通过将原始的高维数据投影到新的低维特征空间中，减少图像内在冗余信息的同时挖掘出有效的地物特征表示，不仅为后续高光谱图像精确的地物识别提供可能，还为数据的快速传输、存储空间和运算时间的缩减等情况创造了便利条件^{[26][45]}。

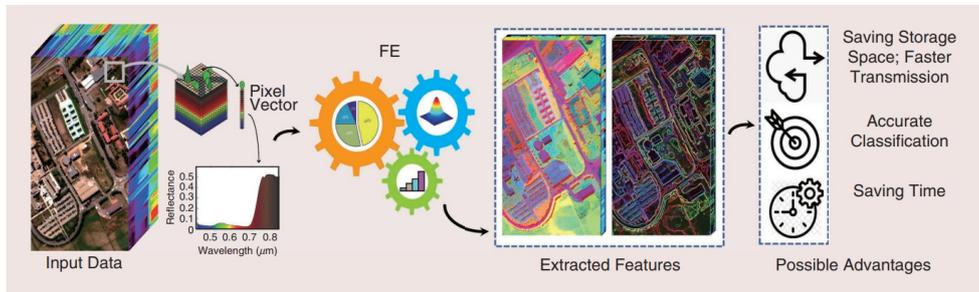


图 3-2 用于高光谱图像分析的特征提取技术及其作用^[26]

Fig. 3-2 The FE technique and its advantages for HSI analysis^[26]

流形的思想最早由德国数学家黎曼提出，其假设在流形上任意一点处是与欧

式空间同胚的局部空间，借助与欧式空间具有相同性质的概念，即使高维空间中数据分布复杂，但在局部上仍然满足欧式空间的性质^{[128][129]}。随后，流形学习（Manifold Learning, ML）的概念首次由 Bregler 和 Omohundro 提出并应用于语音识别中^[130]，其本质是挖掘出高维数据中潜在的结构属性，通过对局部内蕴结构关系进行参数化并在低维空间保持不变，来获得高维数据到低维空间的映射关系，使得原有数据在低维嵌入空间中仍能保持数据的固有特征和几何结构不变等特性，从而达到维数约减和特征提取的目的^[131]。受此启发，国内外研究人员纷纷引入流形学习的理念，通过构建地物样本的近邻图结构挖掘出高光谱数据内在的流形结构，并相继提出了许多适用于高光谱图像数据特点的特征提取和分类方法。其中典型的流形学习算法，主要有局部线性嵌入、等距特征映射、拉普拉斯特征映射和邻域保持嵌入 NPE 等^{[129][131]}，下面以使用较为广泛的典型算法 NPE 为例，对其原理进行简要的概述。

邻域保持嵌入 NPE 是由 He 等^[31]提出的一种无监督特征提取方法，该方法基于高维数据隐含的邻域结构性质，通过假定样本点可由其邻域点进行近线性的表示，来寻求合适的线性投影矩阵使得该局部几何结构在低维空间中仍然保持。假设高维的数据集表示为 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n, \mathbf{x}_i \in \mathcal{R}^D\}$ ，由 n 个样本组成，相应的数据原始维度为 D 。考虑到样本点在局部空间中近似为线性分布，即每一个样本点可通过其近邻样本点进行重构表示，通过挖掘数据内在的局部结构并在低维空间中保留这一结构，可以获得高维数据到低维空间的映射关系 f ，则经映射后得到的低维流形嵌入可表示为 $\mathbf{X}' = f(\mathbf{X}) \in \mathcal{R}^d (d \ll D)$ ，其中 d 为嵌入后的特征维度。在具体的实现过程中，首先是利用欧式距离对各对样本点进行度量，如 \mathbf{x}_i 和 \mathbf{x}_j 间的距离可以表示为 $dist_{ij} = \|\mathbf{x}_i - \mathbf{x}_j\|^2$ ，距离越小说明两个样本之间的相似度越高，反之，则表明样本间差异性比较大。根据重构误差最小的原则和近邻法，为每个待重构的目标样本筛选其前 k 个近邻样本，利用局部的线性结构来对样本进行重构，其表示形式为：

$$\mathbf{x}_i = w_{i1}\mathbf{x}_{i,1} + w_{i2}\mathbf{x}_{i,2} + \dots + w_{ik}\mathbf{x}_{i,k} \quad (3-1)$$

式中， $\mathbf{x}_{i,k}$ 表示样本 \mathbf{x}_i 的第 k 个近邻样本，权重系数 w_k 描述了近邻样本 $\mathbf{x}_{i,k}$ 对于重构样本 \mathbf{x}_i 的贡献程度。进一步引入权重约束项确保求解的唯一性，重构误差的代价函数可以表示为：

$$\min \sum_{i=1}^n \left\| \mathbf{x}_i - \sum_{j=1}^k w_{ij}\mathbf{x}_{i,j} \right\|^2 \quad \text{s.t.} \sum_{j=1}^k w_{ij} = 1 \quad (3-2)$$

当高维原始数据被投影到低维空间中时，样本的局部几何结构保持不变，即投影后的低维数据 \mathbf{X}' 仍然可以使用原有的重构关系进行表达，相应地，投影空间中的误差代价函数可以表示为：

$$\begin{aligned} \min \sum_{i=1}^n \left\| \mathbf{x}'_i - \sum_{j=1}^k w_{ij} \mathbf{x}'_{i,j} \right\|^2 &= \min \left\| \mathbf{X}' (\mathbf{I} - \mathbf{W}) \right\|^2 \\ &= \min \left(\mathbf{X}' (\mathbf{I} - \mathbf{W}) (\mathbf{I} - \mathbf{W})^T (\mathbf{X}')^T \right) \\ &= \min (\mathbf{F}^T \mathbf{X} \mathbf{M} \mathbf{X}^T \mathbf{F}) \end{aligned} \quad (3-3)$$

其中， $\mathbf{M} = (\mathbf{I} - \mathbf{W})(\mathbf{I} - \mathbf{W})^T$ ， \mathbf{I} 表示单位矩阵， \mathbf{F} 即为待求解的线性映射关系。借助于拉格朗日乘子法，误差代价函数进一步转换为矩阵的特征值分解，从而得到最优化且唯一的投影矩阵 \mathbf{F} 。该利用了高光谱图像的光谱信息，将高维度的高光谱图像数据映射到特定的低维流形空间中，减少信息冗余的同时揭示了地物的本质特征，但对于外界因素干扰明显的成像环境，高光谱图像中的“同物异谱、异物同谱”现象更为显著时，由于缺少图像中地物空间信息的利用，无法有效地应对光谱信息不确定性对地物特征提取的干扰，难以准确地挖掘出数据蕴含的本质结构，导致地物特征判别性弱、分类结果不理想。

3.3 基于空谱信息联合和可靠邻域结构挖掘的高光谱特征提取

3.3.1 高光谱数据的重表达

高光谱图像数据不仅能够提供地物类别区分的细节性光谱信息，还蕴含着表征地物不同特性的空间信息，但这些空间信息往往隐性地蕴藏在高光谱数据中，需要显示性地表征出地物空间信息，才能构建出更加完善的地物信息表达。作为高光谱分类应用领域广泛使用的空间特征提取方法，扩展的多属性剖面特征 EMAP^[39]能够灵活地表征地物目标的大小、形状等不同方面的结构特性，因此本章利用 EMAP 从高光谱图像中挖掘地物的纹理信息表示，然后与原始光谱信息进行级联，使原始图像中的每个像素能够以联合后的空谱信息进行表示。在 EMAP 特征的具体提取过程中，往往需要先进行属性剖面 AP 特征的运算，以灰度图像 f 为例，通过选用一系列不同属性的滤波器对图像进行处理，得到的属性剖面特征 AP^[39]可表示为：

$$\text{AP}(f) = \{ \phi_n(f), \phi_{n-1}(f), \dots, \phi_1(f), f, \gamma_1(f), \gamma_2(f), \dots, \gamma_n(f) \} \quad (3-4)$$

式中 ϕ 和 γ 分别代表属性的增厚和稀疏操作，根据不同类型的属性操作和初设阈值，最终获得图像的形态学处理结果。目前常用的属性有区域面积 (area)、对角

线长度 (length of the diagonal)、标准差 (standard deviation) 和惯性矩 (moment of inertia) 等^[106], 其中前两种属性属于递增属性, 随着采集区域像元数目的增多而增大, 用于实现属性增厚操作, 后两种则属于非递增属性, 用于实现属性稀疏操作, 组合四种不同的属性操作能够更为完整地实现图像的形态学信息表征。

对于高维多元的高光谱图像而言, 考虑到原始数据的维度和信息冗余度比较大, 因此往往是先通过主成分分析法 PCA 对原始数据进行降维处理, 然后将提取出的前 c 个主成分按照特定的属性滤波提取其属性剖面特征 AP, 再对由各个成分获得的属性剖面 AP 进行堆叠, 从而得到图像在某一特定属性下的扩展属性剖面特征 EAP。将不同属性对应的 EAP 特征依次进行级联, 最终得到的 EMAP 空间特征可表示为:

$$EMAP = \{EAP_{\alpha_1}, EAP_{\alpha_2}, \dots, EAP_{\alpha_m}\} \quad (3-5)$$

其中, α_i 是通用属性, 这些属性包括均值、标准差等与灰度有关的特征以及面积、外接矩等与图像形状相关的特征。考虑到主成分分析法 PCA 提取出的前两个主成分能够反映出高光谱图像地物目标大部分的原有信息, 因此本章选用高光谱图像的前两个主成分参与区域面积、对角线长度、标准差和惯性矩等不同属性的纹理特征计算, 以 PC 1 和 PC 2 分表示高光谱图像经 PCA 提取出的第一主成分和第二主成分, 相应的空间特征提取示意图如图 3-3 所示, 最终得到 EMAP 纹理特征的如下表达形式:

$$EMAP = \{EAP_a, EAP_d, EAP_s, EAP_i\} \quad (3-6)$$

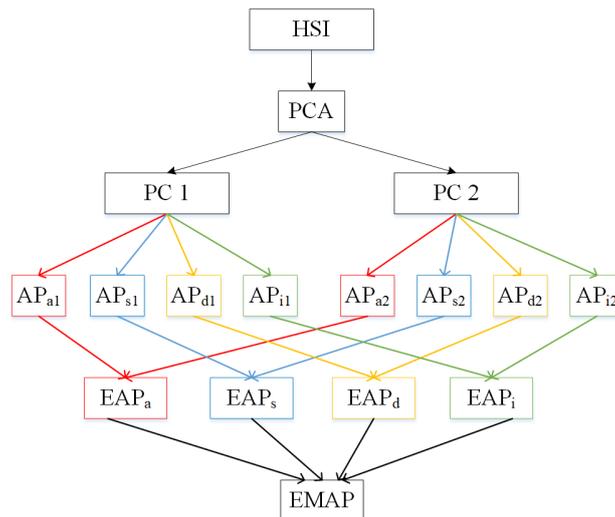


图 3-3 高光谱图像的 EMAP 纹理特征提取示意图

Fig. 3-3 Flowchart of EMAP feature extraction for HSI

式中 EAP 特征的各下标依次对应前文所述的四种不同属性, EAP_a 表示利用区域面

积属性对高光谱图像提取出的前两个主成分计算获得的扩展属性剖面特征。为了更加完整地显示高光谱图像中地物的空谱信息，本节将扩展的多属性剖面特征 EMAP 与原始高光谱数据中的地物光谱信息进行堆叠，获得空谱域上的地物信息表示，重表达后的地物样本集包含了光谱信息、空间纹理信息和空间位置信息，为后续地物鉴别性的空谱特征提取奠定基础。

为了方便后续的高光谱数据表示和使用，假设原始的高光谱数据集为 $\mathbf{X} = [\mathbf{X}^L, \mathbf{X}^U] = [\mathbf{x}_1^L, \mathbf{x}_2^L, \mathbf{x}_i^L, \dots, \mathbf{x}_n^L, \mathbf{x}_1^U, \mathbf{x}_2^U, \mathbf{x}_j^U, \dots, \mathbf{x}_m^U] \in \mathcal{R}^{d_{spe} \times z}$ 其中 d_{spe} 代表光谱波段数， z 代表数据集中样本的总数目， \mathbf{X}^L 和 \mathbf{X}^U 分别表示带有标签的标记样本集和无类别信息的无标记样本集。提取出的 EMAP 纹理特征表示为 $\mathbf{X}^E \in \mathcal{R}^{d_{spa} \times z}$ ，其中 d_{spa} 代表空间特征维度，经级联后得到的数据可表示为 $\mathbf{E} = [\mathbf{X}; \mathbf{X}^E] \in \mathcal{R}^{d \times z}$ ，其中 $d = d_{spa} + d_{spe}$ 代表高光谱数据重新表示后的空谱信息维度。

3.3.2 基于空谱信息联合距离度量的改进 NPE 算法

邻域保持嵌入算法 NPE 是一种无监督的特征提取方法，通过挖掘高维空间数据的局部信息，并在低维空间中保留了高光谱中的局部流形结构，应用于高光谱数据时，每个像素样本均可被表示为相邻样本点的线性组合，组合系数构成了权重矩阵，通过构造样本连接图来表达样本之间的相似性，图中的节点是高维空间中的点，节点与节点之间的连线（赋予不同的权重）可表示节点之间的相似关系，由权重较大的边所连接的两节点很大可能属于相同的类，因而当高维数据嵌入到低维特征空间中时，样本之间的相关性被保留下来。但传统的 NPE 只利用了光谱信息度量样本之间的相似性，由于高光谱图像存在着“同物异谱”和“同谱异物”等现象，因而，很容易错选不同类别的样本作为近邻样本参与重构，从而造成较大的重构误差，导致最终的分类结果不理想。

高光谱图像除了具有“图谱合一”的特点以外，同类地物目标的空间相关性也较强，特别是同一类别的地物样本往往在空间上也体现近邻关系，即呈现空间一致性。此外，高光谱图像中存在着空间邻近域内异类地物相似度高于同类地物，或是空间距离相对较远的像素属于同类地物等多种情况，而在传统的流形重构过程中，忽视了像素点与其所选近邻像素点之间的空间信息，因而无法有效地挖掘出高维数据隐含的本质流形结构，导致高光谱图像地物空谱特征有效性下降。针对上述问题，本节对传统的 NPE 算法进行改进，考虑到在同一幅高光谱图像中，同类地物在空间上的分布通常具有一定的关联性，引入高光谱图像在二维空间中的空间坐标作为一种辅助信息，结合前一节重表达后的地物光谱和纹理等空谱信

息，对传统的样本相似度量方式进行改进，以空谱信息联合的形式共同衡量样本间的相似度，从而更加贴合高光谱图像的数据特点，提升低维流形嵌入的可靠性。本节所提出的改进 NPE 算法，对空谱域重表达后的数据集 \mathbf{E} 进行流形结构的挖掘，其实现的过程可简化为如下的核心步骤：

(1) 不同样本点 \mathbf{e}_i 和 \mathbf{e}_j 间基于空谱信息联合的相似度衡量可表示为：

$$p_{ij} = \exp(-s_{ij}^2/\mu) \cdot \exp(-d_{ij}^2) \quad (3-7)$$

$$s_{ij} = \|\mathbf{e}_i - \mathbf{e}_j\|_2 \quad (3-8)$$

$$d_{ij} = \sqrt{(\mathbf{r}_i - \mathbf{r}_j)^2} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (3-9)$$

$$\mu = \frac{1}{z(z-1)/2} \sum_{i=1}^z \sum_{j=i+1}^z (\|\mathbf{e}_i - \mathbf{e}_{i+1}\|_2 + \dots + \|\mathbf{e}_i - \mathbf{e}_z\|_2) \quad (3-10)$$

其中， s_{ij} 表示样本点间基于光谱和空间纹理信息的距离， d_{ij} 表示不同样本点在图像上的空间位置距离， $\mathbf{r}_i = [x_i, y_i]$ 代表样本在高光谱对应二维图像中的空间坐标信息， μ 是数据集在空谱重表达后样本之间的距离均值。

(2) 寻找每个样本点 \mathbf{e}_i 的 k 个近邻样本，计算权重矩阵 \mathbf{Q} 的目标函数和约束条件可表示为：

$$\min_{\mathbf{Q}} \sum_i \|\mathbf{e}_i - \sum_j \mathbf{Q}_{ij} \mathbf{e}_j\|^2 \quad \text{s.t.} \sum_j \mathbf{Q}_{ij} = 1, j=1, 2, \dots, k \quad (3-11)$$

(3) 在低维映射空间中，样本点之间仍然满足这种邻域流形结构，因而变换矩阵 \mathbf{T} 可通过优化以下问题求解：

$$\min \sum_i \|\mathbf{y}_i - \sum_j \mathbf{Q}_{ij} \mathbf{y}_j\|^2 \quad (3-12)$$

其中 $\mathbf{y}_i = \mathbf{T}^T \mathbf{e}_i$ ，通过引入约束项 $\sum_i \mathbf{y}_i \mathbf{y}_i^T = \mathbf{I}$ ，上式进一步转换成以下问题：

$$\mathbf{T} = \operatorname{argmax}_{\mathbf{T}} \frac{|\mathbf{T}^T \mathbf{E} (\mathbf{E})^T \mathbf{T}|}{|\mathbf{T}^T \mathbf{E} \mathbf{M} (\mathbf{E})^T \mathbf{T}|} \quad (3-13)$$

式中 $\mathbf{M} = (\mathbf{I} - \mathbf{Q})^T (\mathbf{I} - \mathbf{Q})$ ， \mathbf{I} 为单位矩阵。

(4) 利用拉格朗日乘子法，将公式(3-13)转化为求解广义特征值的问题

$$\mathbf{E} (\mathbf{E})^T \boldsymbol{\varphi} = \lambda \mathbf{E} \mathbf{M} (\mathbf{E})^T \boldsymbol{\varphi} \quad (3-14)$$

按照广义特征值由大到小的顺序 $\lambda_1, \lambda_2, \dots, \lambda_t$ ，选取相应的特征向量 $\boldsymbol{\varphi}_1, \boldsymbol{\varphi}_2, \dots, \boldsymbol{\varphi}_t$ ，从而得到投影变换矩阵 $\mathbf{T} = [\boldsymbol{\varphi}_1, \boldsymbol{\varphi}_2, \dots, \boldsymbol{\varphi}_t]$ 和原始数据的低维嵌入特征 $\mathbf{Y} = \mathbf{T}^T \mathbf{X}$ 。

在改进的 NPE 算法中，对每个目标样本进行近邻样本的选取时，高光谱图像

中待选样本大体上可分为三类，第一类为空间距离近且空谱相似度高的近邻样本，第二类为空间距离近且空谱相似度低的近邻样本，第三类为空间距离远且空谱相似度高的近邻样本，其中，第一类近邻样本具有最大的可能性和待重构的目标样本属于同一类别。如图 3-4 所示，改进的 NPE 利用公式(3-7)中样本相似性的度量方式，倾向于优先选取第一类近邻样本，即所提方法以最大的概率为每一个目标样本优先选取同类别的近邻样本，加强了同类地物的聚合能力，从而有效地挖掘出高光谱中本质的流形结构。为了更加清晰地阐述所提改进 NPE 算法的优势，本节提出了一种评估所选近邻样本可靠性的方法，利用近邻样本与待重构目标样本的语义类别一致性，对近邻样本的可靠性进行度量，进而反映出度量方式和重构模型的有效性。

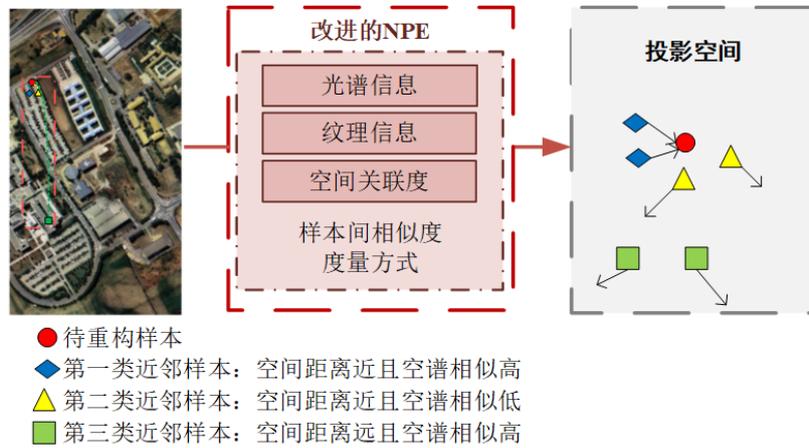


图 3-4 改进的 NPE 近邻样本选取示意图

Fig. 3-4 Principle diagram of nearest neighbors selection in the improved NPE

对于空谱域信息重表达后的高光谱数据集 E 而言，其对应的近邻样本矩阵可表示为 $N \in \mathfrak{R}^{z \times k}$ ，其中 z 和 k 分别代表数据集样本的数目和选取近邻样本的数目，近邻样本矩阵 N 中的元素 N_{ij} 代表样本 e_i 的第 j 个近邻样本。假设 $V \in \mathfrak{R}^{z \times k}$ 表示近邻样本矩阵 N 每个近邻样本对应的真实类别标签矩阵，则对于高光谱数据集中样本 e_i 的第 j 个近邻样本 N_{ij} 而言，其可靠性可定义为：

$$H_{ij} = \begin{cases} 0, & \text{if } l(e_i) \neq V_{i,j} \\ 1, & \text{if } l(e_i) = V_{i,j} \end{cases} \quad (3-15)$$

其中 $l(e_i)$ 代表样本 e_i 真实类别，即如果样本 e_i 和其近邻样本属于同一类别，则赋予这类近邻样本高可靠度，反之，赋予低可靠度。对于整个高光谱数据而言，根据真实的类别信息，通过检验每一个样本和它的近邻样本的类别标签是否相同，进而统计得到整个数据集中类别与待重构样本标签一致的近邻样本数目。本节将

待重构的目标样本集 E 类别标签与对应近邻样本矩阵 N 第 j 列上的近邻样本标签进行比对和统计，相应地，近邻样本矩阵 N 第 j 列近邻样本的可靠性可表示为：

$$R_j = \sum_{i=1}^z H_{ij} / z \quad (3-16)$$

3.3.3 基于可靠邻域结构的高光谱多维空谱特征提取

特征提取的有效性对于高光谱图像分类效果起着极其重要的作用，根据是否使用带标签的样本，高光谱特征提取方法可分为无监督、监督和半监督三种特征提取方法。半监督特征提取方法即利用了标签样本的类别信息，同时也学习了大量无标签样本的内部信息，因此与无监督和监督特征提取方法相比，能够大大提高高光谱图像的分类精度。考虑到监督特征提取方法局部线性判别分析法 LFDA 能够基于样本局部特性挖掘标签样本的类别信息，但其性能依赖于标签样本的数目，而本章提出的改进 NPE 算法旨在挖掘数据中隐含的高可靠邻域结构信息，但缺失了具有判别能力的类别信息，基于二者的互补性，本节将 LFDA 和改进的 NPE 算法相结合，弥补彼此的不足，实现基于类别信息、光谱纹理信息和空间位置等空谱信息联合的高光谱半监督空谱特征提取，算法流程图如图 3-5 所示，值得注意的是，传统的半监督特征提取方法往往将标记样本集和无标记样本集进行分割处理，仅仅利用无标记的样本数据集进行局部线性结构的学习，本节所提的方法是对样本数据集整体进行流形嵌入结构的挖掘，从而提升特征提取过程的泛化性和有效性。

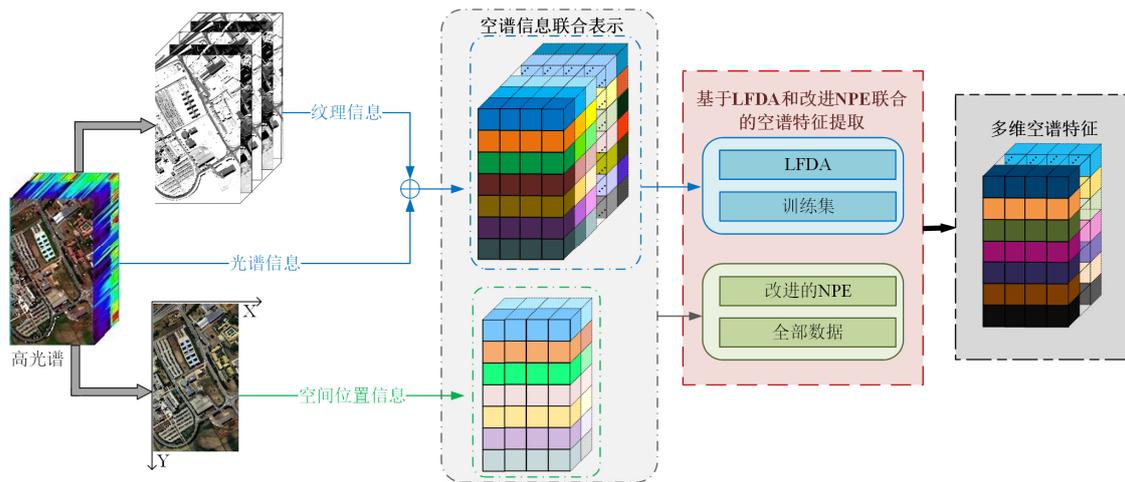


图 3-5 基于可靠邻域结构的高光谱图像空谱特征提取流程图

Fig. 3-5 Flowchart of the hyperspectral image spectral-spatial feature extraction method based on reliable neighborhood structure

局部线性判别分析法 LFDA 通过最大化局部类内协方差矩阵和局部类间协方

差矩阵比获得最佳投影矩阵，局部类内协方差矩阵和局部类间协方差矩阵可分别表示为：

$$\begin{aligned} \mathbf{S}^b &= \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n W_{i,j}^b (\mathbf{e}_i^L - \mathbf{e}_j^L)(\mathbf{e}_i^L - \mathbf{e}_j^L)^\top \\ \mathbf{S}^w &= \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n W_{i,j}^w (\mathbf{e}_i^L - \mathbf{e}_j^L)(\mathbf{e}_i^L - \mathbf{e}_j^L)^\top \end{aligned} \quad (3-17)$$

式中 W_{ij}^b 和 W_{ij}^w 为权重系数，满足以下条件：

$$\begin{aligned} W_{ij}^w &= \begin{cases} A_{ij} / n_c, & \text{if } y_i = y_j = c \\ 0, & \text{if } y_i \neq y_j \end{cases} \\ W_{ij}^b &= \begin{cases} A_{ij} (1/n - 1/n_c), & \text{if } y_i = y_j = c \\ 1/n, & \text{if } y_i \neq y_j \end{cases} \end{aligned} \quad (3-18)$$

系数 A_{ij} 表示同一类别间不同样本之间的相似性，可由核函数进行表示：

$$A_{ij} = \exp\left(-\frac{\|\mathbf{e}_i^L - \mathbf{e}_j^L\|^2}{\gamma_i \gamma_j}\right) \quad (3-19)$$

通过进一步改写，可将 LFDA 最佳投影的求解表示为以下的广义特征值求解问题：

$$\begin{aligned} \mathbf{E}^L \mathbf{P}^b (\mathbf{E}^L)^\top &= \lambda \mathbf{E}^L \mathbf{P}^w (\mathbf{E}^L)^\top \varphi \\ \mathbf{P}^b &= (\mathbf{D} - \mathbf{W}) - (\mathbf{D}^w - \mathbf{W}^w) \\ \mathbf{P}^w &= \mathbf{D}^w - \mathbf{W}^w \end{aligned} \quad (3-20)$$

其中， \mathbf{D} 和 \mathbf{D}^w 为对角矩阵，其对角元素分别满足以下条件

$$\mathbf{D}_{ii} = \sum_{j=1}^n W_{ij}^b \quad \mathbf{D}_{ii}^w = \sum_{j=1}^n W_{ij}^w \quad (3-21)$$

$$W_{ij} = \begin{cases} 1/n, & \text{if } y_i \neq y_j \\ A_{ij} / n, & \text{if } y_i = y_j \end{cases} \quad (3-22)$$

考虑到现有的半监督流形特征提取方法往往将标签样本集和无标签样本集分别进行单独处理，只利用标签样本集提取鉴别的语义类别信息，而从无标签样本集挖掘数据潜在的流形结构信息，忽视了样本之间的关联性，难以有效捕捉同类地物间的本质特征。因此，本节以无标签样本集扩充的形式保留高光谱图像数据的空间一致性和类别连续性，将由标记样本集和无标记样本集构建的数据样本集进行高光谱数据内在流形结构的学习。假设扩充后的数据集表示为 $\mathbf{O} = [\mathbf{E}^L, \mathbf{E}]$ ，数据集 \mathbf{O} 与重表达后的数据集 \mathbf{E} 内含相同的多样性信息，如类别信息、空间信息、光谱信息等。利用 LFDA 和改进的 NPE 算法各自的优势，将公式(3-14)和(3-20)对

应的广义特征值求解问题相结合，半监督空谱特征的提取方法可表示为：

$$\mathbf{O} \begin{bmatrix} \mathbf{P}_{n \times z}^b & \mathbf{0}_{n \times z} \\ \mathbf{0}_{z \times n} & \mathbf{I}_{z \times z} \end{bmatrix} \mathbf{O}^T = \lambda \mathbf{O} \begin{bmatrix} \mathbf{P}_{n \times z}^w & \mathbf{0}_{n \times z} \\ \mathbf{0}_{z \times n} & \mathbf{M}_{z \times z} \end{bmatrix} \mathbf{O}^T \varphi \quad (3-23)$$

利用前 u 个最大特征值对应的特征向量组成数据集 \mathbf{E} 的投影矩阵，具体可表示为：

$$\mathbf{J} = [\mathbf{j}_1, \mathbf{j}_2, \dots, \mathbf{j}_u] (u \ll d_{spa}) \quad (3-24)$$

最终，基于高可靠邻域结构提取出的地物空谱特征表示为 $\mathbf{F} = \mathbf{J}^T \mathbf{E}$ ，利用标记样本集的特征表示 \mathbf{F}^L 和语义标签 \mathbf{Y}^L 对分类器进行训练，结合原始无标记样本集 \mathbf{X}^U 对应的空谱特征 \mathbf{F}^U 实现对各无标样本的类别标签预测。为了更加清晰地表述本章所提出的特征提取方法，算法 3-1 列出了主要步骤，所提方法不仅利用了已知地物的语义类别信息，而且联合了图像中地物的光谱信息、纹理信息和空间位置信息等不同类型的地物信息，共同构建出高度可靠的地物邻域结构，进而将原始高维数据投影到低维的流形特征空间中，加强同类地物紧密度的同时，削弱了不同类别地物间的关联度，提取出更具判别性的地物空谱特征，从而提升高光谱地物分类精度，改善高光谱图像整体的解译效果。

算法 3-1 基于可靠邻域结构的高光谱空谱特征提取和分类方法

输入： 高光谱数据集 $\mathbf{X} = [\mathbf{X}^L, \mathbf{X}^U] \in \mathfrak{R}^{d_{spe} \times z}$ 其中标记样本集 \mathbf{X}^L 的语义标签 \mathbf{Y}^L

1. 利用 EMAP 提取纹理信息 \mathbf{X}^E 构建空谱信息的数据重表达 $\mathbf{E} = [\mathbf{X}; \mathbf{X}^E]$
2. 利用公式(3-7)度量样本之间的相似性，构建基于可靠邻域结构的改进 NPE 方法
3. 联合特征提取方法 LFDA 和改进的 NPE，构建基于扩充数据集 $\mathbf{O} = [\mathbf{E}^L, \mathbf{E}]$ 的半监督特征提取方法
4. 利用公式(3-23)求解 u 个最大特征值对应的特征向量，获得高光谱数据集的多维空谱特征表示 $\mathbf{F} = [\mathbf{F}^L, \mathbf{F}^U] \in \mathfrak{R}^{u \times z} (u \ll d_{spa})$
5. 利用标记样本集的空谱特征表示 \mathbf{F}^L 和语义类别 \mathbf{Y}^L 训练分类器，获得无标记样本集特征表示 \mathbf{F}^U 对应的类别标签 \mathbf{Y}^U

输出： 高光谱数据集 \mathbf{X} 的多维空谱特征表示 \mathbf{F} 及无标记样本集的类别标签 \mathbf{Y}^U

3.4 实验结果及分析

3.4.1 实验数据与设置

考虑到高光谱图像中地物区分的准确性是验证特征提取方法优异的有效评估手段，因此，后续使用高光谱分类结果来论证所提方法的有效性。为了突出所提方法特征提取的能力，本节采用相对简单的分类器即最近邻分类器 NN 获取最终

的地物分类结果，首先通过在不同的高光谱图像数据进行消融实验以证明所提方法的有效性，并对所提方法中主要的核心参数对分类模型性能的影响进行了分析和研究，最后为了验证所提的空谱特征方法在面向高光谱分类任务时的有效性，选取了近年来的高光谱图像空谱分类方法进行对比实验。实验数据选用上一章中介绍的印第安纳 IP, 帕维亚大学 PU 和休斯顿大学 HU 等三组国外高光谱图像数据集，这几组国外高光谱数据集包含了不同的成像场景和地物种类，是目前业内公开且广泛使用的数据集，以及两组分别拍摄于唐岛湾和雄安地区的国内高光谱数据集进行所提方法适用性分析，各数据集的详细采集情况和地物类别信息已阐述在第二章中，此处不再赘述。对于所提方法涉及到的 EMAP 纹理特征提取，基于前期的理论分析和文献参考，选用面积 a 、边界框对角线长度 d 、标准差 s 和惯性矩 i 等四项属性参数^{[39][106]}，各项参数的取值范围分别设置为 $a = \{10, 30, 50, 70, 90\}$ ， $d = \{10, 25, 40\}$ ， $s = \{0.05, 0.15, 0.25, 0.35\}$ 和 $i = \{0.2, 0.3, 0.4\}$ 。在具体的实验过程中，随机选取不同数目的标记样本进行 5 轮重复实验，将多轮实验的定量化评价指标进行均值计算，从而对不同分类方法的性能进行合理性的评估和分析。

3.4.2 消融实验与模型参数分析

3.4.2.1. 消融实验

为了说明本章所提改进 NPE 算法的有效性，在进行高光谱地物分类任务之前，本节采用主成分分析法 PCA^[29]和邻域保持嵌入法 NPE^[31]等传统的无监督特征提取方法以及近年来所提的 Laplacian 正则化协同表示特征提取法 LRCRP^[51]，与改进 NPE 算法进行地物聚类对比实验，利用 t 分布随机邻域嵌入 (t -Distributed Stochastic Neighbor Embedding, t -SNE)^[132]进行可视化对比分析。图 3-6、图 3-7 和图 3-8 分别展示了不同数据集上这三种方法进行相同维度的特征提取后，经 t -SNE 变换后得到的二维可视化聚类图，并根据已知的语义信息进行地物类别区分，不同颜色代表不同语义类别，从图中显示的聚类结果能够更加直观地看出不同方法的地物特征提取能力，其中 NPE 和改进的 NPE 算法近邻样本数目均设定为 2。对于 PCA 和 NPE 这两种特征提取方法，不同类别的地物样本混杂在一起，可分性较差，LRCRP 利用了全局信息和局部流形结构，不同类别间的地物可分性得到了一定程度的改善，而本章所提的改进 NPE 算法明显增加了类间样本之间的距离，同一类别的地物样本倾向于聚集在一个集群中，不同集群之间的分界线也比较明显，这说明不同类别之间的地物可区分性有了明显的提升，在后续的地物分类任务中结合已知的地物类别信息，将有助于提取出更具鉴别性的地物空谱特征，从而改善高光谱图像的地物分类结果。

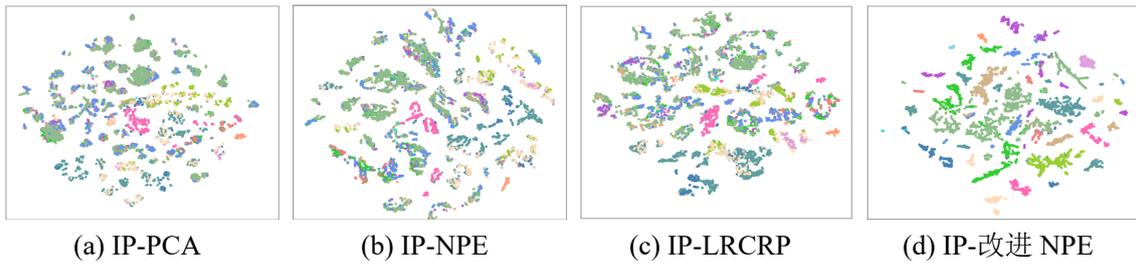


图 3-6 不同方法在 IP 数据集上的地物特征 t -SNE 可视化对比

Fig. 3-6 t -SNE visualization comparison of different feature extraction methods on the IP dataset

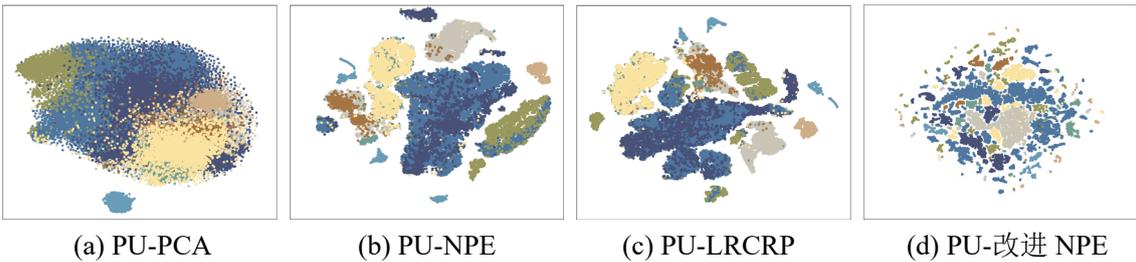


图 3-7 不同方法在 PU 数据集上的地物特征 t -SNE 可视化对比

Fig. 3-7 t -SNE visualization comparison of different feature extraction methods on the PU dataset

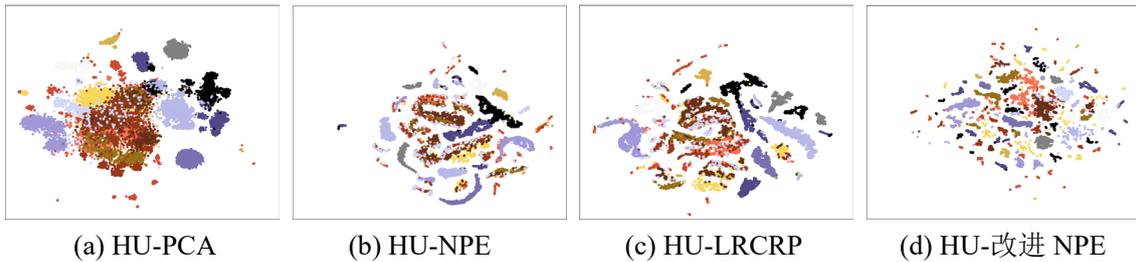


图 3-8 不同方法在 HU 数据集上的地物特征 t -SNE 可视化对比

Fig. 3-8 t -SNE visualization comparison of different feature extraction methods on the HU dataset

为了进一步验证本章所提特征提取算法的有效性，本节选取了一些相关的特征提取算法进行比较，包括局部线性判别分析法 LFDA、邻域保持嵌入法 NPE、半监督局部判别分析法（Semi-supervised Local Discriminant Analysis, SELD）^[133]和基于加权的半监督局部线性判别方法（Weighted Semi-supervised Local Discriminant Analysis, WSLDA）^[134]等。此外，本节还设计了针对所提方法各部分有效性验证的消融实验，这里将空谱信息的使用方式和邻域结构的构建模式考虑在内，搭建了基于 LFDA 和 NPE 算法的对比特征提取方法，不同条件下各对比特征提取方法的构建详情如表 3-1 所示。为了方便叙述，这里对不同的特征提取方法（Feature Extraction, FE）进行简化命名，其中数据集重表达表示待处理的样本数据是经由高光谱光谱信息和纹理信息堆叠后得到的空谱信息数据，邻域结构代表高维数据中流形结构挖掘方式所使用的样本集形式，基于所有样本集的邻域结构构建方式即从全部样本数据中挖掘内在的流形结构，相似度度量的差异则是表达

出高光谱图像中各类信息使用的区别。FE 5 即本章提出的方法，基于空谱重新表达后的高光谱数据，根据光谱信息、纹理信息和空间位置信息等空谱信息联合的距离度量方式，衡量样本之间的相似度，从所有样本集构建地物的邻域结构。

表 3-1 消融实验中不同条件下的半监督特征提取方法详情

Table 3-1 Detailed information of semisupervised feature extraction under various conditions for ablation experiments

方法编号	特征提取	数据集	邻域结构	相似度度量
FE 1	LFDA+NPE	原始	所有样本集	光谱信息
FE 2	LFDA+NPE	重表达	无标记样本集	光谱信息+纹理信息
FE 3	LFDA+改进 NPE	原始	无标记样本集	光谱信息+空间位置信息
FE 4	LFDA+改进 NPE	重表达	无标记样本集	光谱信息+纹理信息 +空间位置信息
FE 5	LFDA+改进 NPE	重表达	所有样本集	光谱信息+纹理信息 +空间位置信息

考虑到印第安纳 IP 数据集中已知地物类别的样本数目不均衡性，实验中对该数据集的每类地物分别随机抽取了 3%、5%、10%和 15%的样本作为训练样本，对于帕维亚大学 PU 数据集，每类地物则分别随机抽取了 0.5%、1%、3%和 5%的样本构建标记样本集，对于休斯顿大学 HU 数据集，则每类随机抽取 15、30、60 和 90 的标记样本，剩下的其余样本构建测试样本集，用于验证在不同标记样本数量下各个分类方法的鲁棒性。此外，根据理论分析和相关文献中的参数设置，对于上述各对比方法中的核心参数近邻样本的个数和所提地物特征的数目，其数值分别设定为 2 和 30。各个方法在三组不同高光谱数据集上的分类结果如表 3-2 所示，其中粗体所示为最高的分类精度。从表中所列的实验结果可以看出，所提方法在各项指标上都取得了最高的结果，与基于光谱信息的 LFDA、NPE、SELD、WSLDA 和 FE 1 等特征提取方法相比，即使在训练样本数目最少的情况下，本章所提出的空谱特征提取方法对地物分类精度也起到了显著性的提升作用。此外，FE 4 方法在三组不同高光谱数据集上的分类精度明显高于 FE 2 和 FE 3 方法，原因在于这两种方法对高光谱图像中的空谱信息利用不充分，没有准确地揭示出图像蕴藏的地物本质流形结构。虽然 FE 4 方法与本章提出的方法一样，联合利用了光谱信息、纹理信息和空间位置信息等地物信息，但该方法局限于无标记样本集中邻域结构的构建，而本章所提方法能够从全局的角度出发，有效地利用高光谱图像内在的空谱信息，减小重构模型的误差，构建出更为可靠的邻域结构，挖掘出地物潜在的流形结构，因而提取出的地物空谱特征具有更好的类别区分能力，进一步提升了高光谱图像的分类结果。

表 3-2 不同方法在各高光谱数据上的总体分类精度 (%)

Table 3-2 OA (%) of comparative methods on different datasets

数据名称	训练样本	LFDA 原始	NPE 原始	SELD 原始	WSLDA 原始	FE 1 原始	FE 2 重表达	FE 3 原始	FE 4 重表达	FE 5 重表达
IP	3%	56.94	58.33	60.25	58.32	58.60	59.06	74.87	90.44	90.47
	5%	66.44	61.08	63.46	61.36	61.34	62.54	78.07	93.49	93.76
	10%	76.71	64.70	67.02	65.15	65.27	67.86	83.61	96.45	96.65
	15%	79.31	66.64	69.98	66.74	67.09	70.73	85.96	97.09	97.16
	0.5%	73.36	77.32	77.37	76.20	76.09	90.58	81.89	97.29	97.47
PU	1%	81.78	81.50	83.27	80.09	80.05	93.77	85.78	98.33	98.45
	3%	87.30	84.90	86.84	83.29	83.49	96.21	89.15	99.15	99.19
	5%	89.35	86.19	88.76	84.45	84.84	97.31	90.50	99.42	99.46
HU	15	61.04	72.14	83.37	74.51	74.82	82.77	83.93	84.69	85.55
	30	80.49	78.97	89.82	78.26	81.73	88.04	87.66	89.05	89.77
	60	86.78	84.63	92.71	86.18	85.91	91.89	93.24	94.17	94.30
	90	91.15	87.92	95.01	89.98	89.33	96.13	95.39	95.89	96.32

3.4.2.2. 参数敏感度分析

在本章所提出的高光谱空谱特征提取方法中，近邻样本个数与空谱特征数目等核心参数会对最终的特征性能以及后续的分类结果产生一定的影响。为了分析这两个主要参数对所提方法在地物分类性能的影响，本节在空谱特征数目取值范围为{2,5,10,20,30,40,50,60,70,80,90,100}和近邻样本的个数范围为{2,3,5,7}等不同的参量设置情况下，详细讨论两个核心参数对分类结果产生的影响。

(1) 特征数目的影响

第一组实验在近邻样本个数设定为 2 的条件下，讨论所提的特征提取方法在三种不同高光谱数据集上分类结果受空谱特征数目的影响情况。图 3-9 展示了在不同数目的训练样本条件下，在各组高光谱数据集上总体分类精度 OA 随特征数目变化的具体情况。

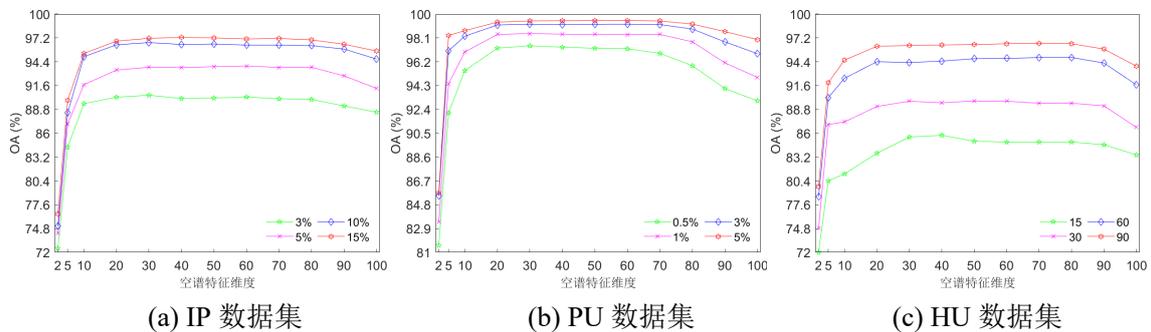


图 3-9 空谱特征维度对所提方法在各组数据集上分类性能的影响

Fig. 3-9 Impact of spectral-spatial feature dimension on the classification performance by the proposed method for each dataset

对于同一幅高光谱图像而言，OA 首先随着空谱特征数目的增加而快速提升，

当特征数目到达 10 时，OA 上升的变化曲线趋于收敛，当特征数目继续增加超过 30 时，OA 数值整体保持平稳状态。但所提特征数目持续增加时，会出现过拟合现象继而导致 OA 呈现下降的趋势。此外，当提取的地物空谱特征维度为 30 时，对于各个数据集在最大训练样本数目和最小样本数目下分类精度分别相差 6.69%，1.99%和 10.77%。显然，训练样本集中的标记样本数目越多，提供具有判别能力的语义类别信息越多，地物分类的精度也相应地随之增加。

(2) 近邻样本个数的影响

第二组实验在特征数目设定为30的条件下，分析近邻样本个数对分类精度的影响，各数据集上的分类结果如图 3-10 所示。从图中所呈现出的结果可以看出，前两组数据集上的总体分类精度OA随着近邻样本数目增加而下降，对于休斯顿大学HU数据集而言，由于受云层遮挡影响存在着大片阴影区域，图像中“同物异谱”和“异物同谱”现象较为显著，因此分类精度并没有严格地呈现出随近邻数目增加而逐渐递减的变化趋势，但从整体的结果上可以看到，当近邻样本个数选定为2时，三组数据集在不同数目的标记样本条件下都取得了最高的分类精度。在高光谱图像数据内在流形结构的挖掘过程中，近邻样本的选取直接决定了重构模型和邻域结构的可靠性，进而影响最终的特征提取和地物类别区分，而现有大多数流形学习特征提取方法只用光谱信息或是部分空谱信息容易选取到不同类别的近邻样本，从而导致了重构误差大和邻域结构不准确。本章所提改进的NPE算法利用高光谱空谱信息联合形式进行样本间的相似度计算，以最大的可能性为每个样本选取同一类别的近邻样本，即前一节中定义的第一类近邻样本，这一类近邻与待重构样本属于同一类别的概率最大，通过构建出高可靠的邻域结构降低重构误差，进而保障后续特征提取的有效性。

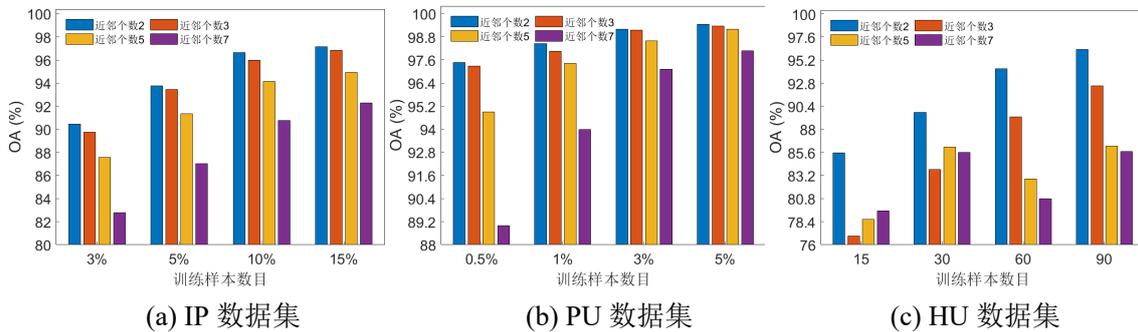


图 3-10 近邻样本数目对所提方法在各数据集总体分类精度的影响

Fig. 3-10 Impact of the number of nearest neighbors on OA by the proposed method for each dataset

为了进一步分析近邻样本可靠性对分类精度的影响，这里对 FE 1、FE 4 和本章所提出的方法即 FE 5 进行详细的研究，并使用上一节定义的公式(3-16)计算不同

情况下近邻样本的可靠性。其中，FE 1 是基于传统的 NPE 方法利用原始的光谱信息从全体样本数据中挖掘局部邻域结构，即为每个无标签样本从全部样本集中选取近邻样本，FE 4 则是基于改进的 NPE 方法，从重表达后的无标签样本数据集里为每个无标签样本选取近邻样本，本章提出的方法则是利用光谱信息、纹理信息和空间位置信息等多维信息进行样本相似度的度量，为每个样本从全部样本集中选取近邻样本进行重构，从整体样本集中挖掘地物潜在的流形结构。简言之，FE 1 和 FE 5 的区别在于对高光谱图像地物信息的使用情况不同，FE 4 和 FE 5 的区别在于邻域结构挖掘模式的不同。FE 1 和本章提出方法 FE 5 为各高光谱数据集中每个样本按照既定的规则筛选近邻样本，表 3-3 列出了经由这两种方法获得的近邻样本可靠性，其中近邻样本的位置序号 1 代表最近邻，序号 2 代表次近邻，依此类推。通过近邻样本的可靠性结果可以看到，本章所提方法的近邻样本可靠性远远高于 FE 1 的近邻样本可靠性，证实了基于空谱信息联合下样本间距离的计算方式明显优于仅依靠光谱信息的样本距离计算方式，能够更加准确地度量样本之间的相似程度，为后续高光谱数据本质流形结构的准确挖掘奠定基础。

表 3-3 不同方法对应近邻样本矩阵中样本的可靠性

Table 3-3 Sample reliability in the nearest neighbor matrix obtained by different methods

方法	邻域结构	数据名称	序号 1	序号 2	序号 3	序号 4	序号 5	序号 6	序号 7
FE 1	NPE-原始	IP	77.37%	73.30%	71.51%	70.33%	68.56%	67.94%	67.32%
	全部样本	PU	90.25%	88.98%	87.99%	87.53%	86.85%	86.61%	86.33%
	改进 NPE-	HU	95.20%	93.22%	91.94%	91.05%	89.71%	88.89%	88.17%
FE 5	重表达	IP	99.97%	99.93%	99.92%	99.73%	99.59%	99.09%	99.02%
	全部样本	PU	100%	100%	99.96%	99.90%	99.83%	99.72%	99.62%
		HU	100%	100%	100%	99.59%	99.59%	99.42%	99.43%

表 3-4、表 3-5 和表 3-6 则分别列出了各数据集在不同数目的标记样本条件下，FE 4 和本章提出方法 FE 5 对于无标签样本集选取到的近邻样本可靠性，两种方法都利用了光谱、纹理和空间位置等地物信息进行样本间相似度的度量，区别在于结构信息的学习范围有所不同，对于每一个无标签样本而言，前者只针对无标记样本数据进行流形结构的挖掘，后者利用全部样本数据挖掘本质流形结构。从表中所列的结果可以看到，对于不同位置的近邻样本可靠性，本章所提的方法整体上都高于方法 4，且随着选取标记样本比例的增加，FE 4 中近邻样本的可靠性呈现下降趋势，整体结果表明从整个数据集择选近邻样本的可靠性高于仅从无标签样本集择选近邻样本的可靠性。对于每一个无标签样本而言，最佳的近邻样本可能存在于带标签的训练样本集中，仅从无标签样本中挖掘邻域结构的可靠性较差且忽视了数据集整体的空间一致性和连续性，因而相较于 FE 4，本章所提方法 FE 5 能够通过空谱信息的联合从整体数据集中筛选近邻样本，保障了邻域结构构

建时的可靠性，从而提升地物鉴别性特征的有效性和分类的精度，与表 3-2 所示的分类结果相吻合。此外，随着选取近邻样本序列号的向后推移，近邻样本与待重构样本相似度也随之降低，二者同属一个语义类别的概率减小，即近邻样本的可靠性下降，导致重构模型误差增大，从而造成分类精度的下降，这也与图 3-10 展示的分类结果随着近邻样本个数的增多而呈现下降趋势相一致，整体上证实了本章所提方法选取最近邻样本和次近邻样本进行数据流形结构挖掘的有效性。

表 3-4 IP 数据无标签样本集对应近邻样本矩阵中不同次序上的样本可靠性

Table 3-4 Sample reliability of different orders in the neighbor sample matrix for unlabeled sample set on the IP

训练样本	方法	邻域结构	序号 1	序号 2	序号 3	序号 4	序号 5	序号 6	序号 7
3%	FE 4	无标签样本	99.97%	99.92%	99.89%	99.73%	99.51%	99.03%	98.76%
	FE 5	全部样本	99.97%	99.93%	99.92%	99.73%	99.59%	99.10%	99.02%
5%	FE 4	无标签样本	99.97%	99.92%	99.91%	99.68%	99.49%	99.01%	98.65%
	FE 5	全部样本	99.97%	99.93%	99.93%	99.72%	99.58%	99.13%	99.03%
10%	FE 4	无标签样本	99.97%	99.93%	99.85%	99.61%	99.38%	98.99%	98.24%
	FE 5	全部样本	99.97%	99.93%	99.93%	99.70%	99.61%	99.10%	98.99%
15%	FE 4	无标签样本	99.95%	99.91%	99.79%	99.54%	99.19%	98.60%	98.38%
	FE 5	全部样本	99.97%	99.92%	99.93%	99.74%	99.56%	99.07%	99.08%

表 3-5 PU 数据无标签样本集对应近邻样本矩阵中不同次序上的样本可靠性

Table 3-5 Sample reliability of different orders in the neighbor sample matrix for unlabeled sample set on the PU

训练样本	方法	邻域结构	序号 1	序号 2	序号 3	序号 4	序号 5	序号 6	序号 7
0.5%	FE 4	无标签样本	100%	100%	99.96%	99.90%	99.83%	99.72%	99.61%
	FE 5	全部样本	100%	100%	99.96%	99.90%	99.83%	99.72%	99.62%
1%	FE 4	无标签样本	100%	100%	99.96%	99.89%	99.83%	99.72%	99.60%
	FE 5	全部样本	100%	100%	99.96%	99.90%	99.83%	99.72%	99.62%
3%	FE 4	无标签样本	100%	100%	99.96%	99.89%	99.81%	99.69%	99.60%
	FE 5	全部样本	100%	100%	99.96%	99.89%	99.83%	99.72%	99.61%
5%	FE 4	无标签样本	100%	100%	99.95%	99.89%	99.79%	99.69%	99.58%
	FE 5	全部样本	100%	100%	99.96%	99.89%	99.83%	99.72%	99.61%

表 3-6 HU 数据无标签样本集对应近邻样本矩阵中不同次序上的样本可靠性

Table 3-6 Sample reliability of different orders in the neighbor sample matrix for unlabeled sample set on the HU

训练样本	方法	邻域结构	序号 1	序号 2	序号 3	序号 4	序号 5	序号 6	序号 7
15	FE 4	无标签样本	100%	100%	100%	99.59%	99.55%	99.43%	99.44%
	FE 5	全部样本	100%	100%	100%	99.59%	99.59%	99.42%	99.43%
30	FE 4	无标签样本	100%	100%	99.98%	99.56%	99.53%	99.42%	99.42%
	FE 5	全部样本	100%	100%	100%	99.59%	99.59%	99.43%	99.44%
60	FE 4	无标签样本	100%	100%	99.94%	99.58%	99.54%	99.38%	99.24%
	FE 5	全部样本	100%	100%	100%	99.58%	99.59%	99.41%	99.43%
90	FE 4	无标签样本	100%	100%	99.85%	99.59%	99.55%	99.39%	99.01%
	FE 5	全部样本	100%	100%	100%	99.60%	99.61%	99.42%	99.44%

3.4.3 对比实验与分析

为了更好地验证本章所提空谱特征方法在高光谱图像分类任务上的有效性，本节选取了基于高光谱空谱信息的典型分类方法和近年来所提的新型分类方法进行对比实验，包括基于空谱信息联合的局部流形表示方法 RLMR^[50]，基于随机多图 RMGs 的高光谱分类方法^[49]，不变属性轮廓 IAPs 分类方法^[43]和基于空间峰值感知的协同表示 SPaCR^[52]以及采用深度学习模型的方法如多尺度三维深度卷积神经网络框架 M3D-DCNN^[54]，三维卷积神经网络 3D CNN^[55]和基于 Transformer 框架的空谱分类方法 SSTN^[59]。针对高光谱图像的数据特点和各方法对应文献中的参数设置，基于流形学习的鲁棒性局部表示方法 RLMR 近邻样本数目和特征维度分别为 50 和 80，基于图集成学习的随机多图 RMGs 方法中图的数目、光谱波段数和 LBP 特征提取中的 patch 大小分别设置为 20，2 和 11，协同表示方法 SPaCR 中的重要参数分别设定为超像素均值宽度 $S_w = 12$ ，空谱距离的补偿系数 $w_s = 0.9$ ，正则化参数 λ 和 β 取值分别为 0.1 和 0.7。对于深度学习对比方法，patch 大小和循环迭代次数分别设置为 7 和 200，其余参数与对比方法相应文献中的设置保持一致，以实现地物类别的高精度判定。

对于本章所提方法，根据前期的理论分析将空谱特征的维度和近邻样本的数目分别设置为 30 和 2。此外，本节仍然采用最近邻 NN 分类器对提取后的地物特征进行类别判定，凸显所提空谱特征的地物类型鉴别能力，更加有效地对不同方法的分类性能进行比对和分析。考虑到深度学习方法需要足够的标记样本进行模型训练，因此在实验过程中，对于各个数据集都选用了前文所述最高比例的标记样本抽取模式，即 IP 数据集每类随机抽取 15%，PU 数据集每类随机抽取 5% 以及 HU 数据集每类随机抽取 90 个样本作为训练集，其余的所有样本用于进行测试，并选用 OA、CA 和 Kappa 系数等评价指标和分类结果图进行定量分析和直观比较。

在第一组对比实验中，选用的各高光谱分类方法在印第安纳 IP 数据集上的分类结果如表 3-7 所示，相应的分类结果图如图 3-11 所示。从表中的分类结果可以看出，本章所提出的空谱特征提取方法在仅使用最近邻分类器的条件下仍然取得了较为理想的分类结果，在 11 种类别的地物区分上都取得了最高的类内分类精度，在图像的解译结果中也呈现出较少的错分样本点。此外，所提方法在类别 2（少耕玉米）和类别 3（玉米）、类别 5（草地/牧场）和类别 14（木材）、类别 7（修剪过的草地/牧场）和类别 8（干草料堆）等光谱相似度极高的地物类别上，也展现出了良好的鉴别能力，取得了较为理想的分类结果。这表明本章所提出的方法能够克服原始高维高光谱图像数据中冗余信息的干扰，最大程度上地利用已知的语义

类别信息和数据蕴含的空谱信息，提取出具有良好鉴别性的地物空谱特征，从而大幅度提升类间光谱区分度低的地物分类精度。

表 3-7 不同方法对印第安纳数据集的分类结果 (%)

Table 3-7 Classification results (%) obtained by different methods for IP dataset

类别编号	RLMR	RMGs	IAPs	SPaCR	3D CNN	M3D-DCNN	SSTN	本章方法
1	100	97.30	78.95	60.53	97.37	84.21	90.48	100
2	87.47	97.20	83.59	85.99	95.71	90.85	94.13	96.04
3	83.92	94.79	84.09	55.40	84.38	81.82	97.52	96.16
4	73.71	91.39	85.50	35.00	96.50	94.50	94.23	94.17
5	95.84	96.87	91.46	90.98	90.98	92.68	95.69	97.28
6	94.44	95.79	94.67	99.35	99.03	99.68	100	99.52
7	90.91	100	91.30	43.48	95.65	95.65	100	100
8	99.75	100	97.04	100	100	100	99.25	100
9	88.89	100	100	18.75	62.50	75.00	88.24	100
10	86.43	96.65	88.24	73.82	88.24	84.36	95.70	97.72
11	88.34	93.98	91.13	90.60	92.81	92.04	96.86	95.15
12	91.30	97.53	73.76	73.36	83.10	89.66	96.54	97.91
13	100	99.42	97.11	99.42	98.84	99.42	100	100
14	96.55	98.98	97.49	97.77	98.42	97.58	98.59	98.98
15	85.20	98.68	91.13	57.19	73.39	78.29	92.06	99.38
16	100	95.06	97.44	84.62	94.87	76.92	90.59	98.73
OA	90.15	96.34	89.57	83.68	92.39	91.30	96.58	97.16
K	88.76	95.82	88.10	81.17	91.34	90.10	96.10	96.76

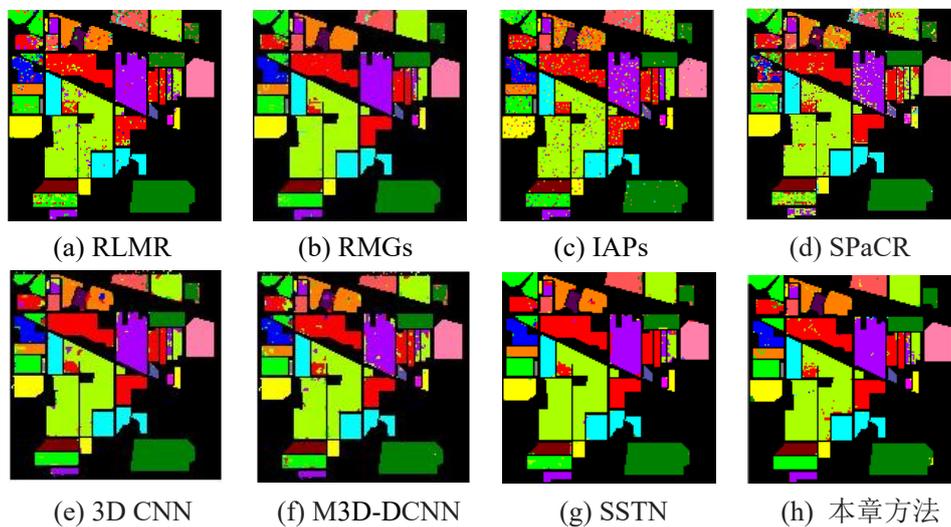


图 3-11 印第安纳数据集上各方法的分类结果图

Fig. 3-11 Classification maps of different methods on the IP dataset

在第二组实验中，不同方法在 PU 数据集上的定量分类结果如表 3-8 所示，为了直观地对比各方法的分类效果，图 3-12 展示了相应的分类结果图。相比于其他高光谱分类方法，本章所提的方法仍取得了最高的分类精度，对于光谱相似度高地物类别如类别 1（柏油路）和类别 7（沥青屋顶）能够良好地进行区分，特别

的是，该数据集的采集区域是城市场景，包含了形状尺寸变化较大的人造地物，很容易出现错分现象。从分类结果图可以看到，所提方法对应的分类图更加地平滑，尤其是在类别 2（草地）、类别 6（裸土）和类别 7 等地物目标区域更为明显。此外，对于空间分布毗邻且光谱相应曲线重合度高的异类地物目标如类别 3（沙砾）和类别 8（砖块），二者的类别边界也较为清晰，这表明本章所提方法能够通过可靠邻域结构的构建挖掘地物样本间的内在关联，从而有效地改善图像的解译效果。

表 3-8 不同方法对帕维亚大学数据集的分类结果 (%)

Table 3-8 Classification results (%) obtained by different methods for PU dataset

类别编号	RLMR	RMGs	IAPs	SPaCR	3D CNN	M3D-DCNN	SSTN	本章方法
1	87.26	99.44	96.16	88.25	94.63	96.19	98.16	99.65
2	86.13	99.17	98.57	99.69	91.98	91.37	99.66	99.94
3	50.92	99.48	85.40	72.65	79.68	85.20	98.15	99.65
4	92.80	99.96	85.98	87.90	95.70	95.02	98.18	95.74
5	92.91	99.84	98.83	99.77	99.77	100	99.92	99.77
6	58.31	99.64	93.41	62.68	98.14	97.63	99.60	99.92
7	60.57	98.89	89.30	80.35	80.11	88.75	99.02	100
8	55.90	97.91	91.11	86.87	98.26	98.31	94.89	98.88
9	81.24	100	97.00	96.77	97.33	99.78	97.16	98.89
OA	77.93	99.26	95.05	89.63	93.32	93.79	98.16	99.46
K	70.34	99.02	93.45	85.94	91.30	91.92	94.88	99.28

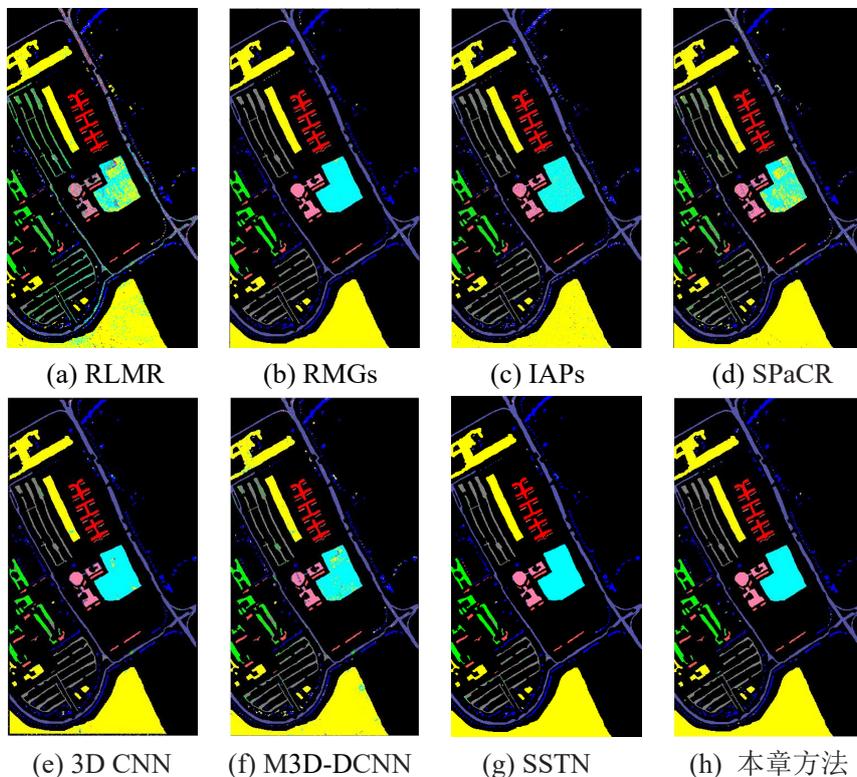


图 3-12 帕维亚大学数据集上各方法的分类结果图

Fig. 3-12 Classification maps of different methods on the PU dataset

在第三组对比实验中，表 3-9 中列出了不同方法在休斯顿大学数据集上的定量分类结果，图 3-13 则展示了各方法的可视化图像解译结果。与上一组高光谱数据集类似，该图像场景也包含了各种不同形态的人造地物，而且图像采集过程受到了云层环境的干扰，导致图像的“同谱异物”和“异物同谱”等现象更为显著，对图像的准确解译带来了极大的挑战。从对比结果可以看到，本章所提的方法取得了最高的总体分类精度 OA 和 Kappa 系数，并在受云层遮挡影响导致类内光谱信息差异度较大的类别 1(健康的草)上取得了最高的类内分类精度。此外，SPaCR、3D CNN 和 M3D-DCNN 等空谱分类方法对于空间上毗邻的相似地物如类别 8(商业区)和类别 9(道路)出现了明显的错分现象，而本章提出的方法不仅通过纹理信息揭示出不同类别地物目标的差异性，同时利用了同类地物在空间分布上的连续性，从而能够更加有效地提取出不同种类地物的显著性特征，因而在类别 7(住宅区)和类别 8(商业区)等容易混淆的地物类别区分上展现出了较强的竞争力，减少了错分样本的数目，并提升了地物分类的准确度。

表 3-9 不同方法对休斯顿大学数据集的分类结果 (%)

Table 3-9 Classification results (%) obtained by different methods for HU dataset

类别编号	RLMR	RMGs	IAPs	SPaCR	3D CNN	M3D-DCNN	SSTN	本章方法
1	98.30	99.14	97.93	96.04	97.42	98.28	94.90	99.91
2	99.31	98.64	98.11	98.80	99.23	98.45	99.73	94.46
3	99.83	99.51	99.67	100	98.02	98.35	99.67	100
4	99.91	99.74	96.27	98.79	98.96	99.48	96.43	96.66
5	96.79	95.39	99.13	99.91	99.74	99.05	96.64	97.34
6	99.57	98.71	96.60	97.45	96.60	97.45	92.34	100
7	94.08	95.96	96.52	94.14	80.81	90.66	93.32	98.00
8	94.18	95.40	93.33	84.75	83.19	86.74	96.99	96.02
9	88.20	88.32	89.24	84.60	71.08	82.70	93.91	97.13
10	93.49	97.44	90.06	95.69	96.31	91.29	95.86	97.66
11	86.96	95.35	94.15	82.18	89.00	82.53	91.75	89.58
12	85.11	93.21	96.68	78.04	89.59	86.26	91.88	96.02
13	85.36	81.87	97.10	70.18	88.92	93.67	85.71	90.34
14	93.37	98.25	97.93	99.70	100	99.70	99.70	92.10
15	99.82	99.82	98.77	98.95	99.47	99.82	99.65	100
OA	94.04	95.93	95.65	91.75	91.51	92.57	95.27	96.32
K	93.54	95.59	95.29	91.06	90.80	91.95	94.88	96.01

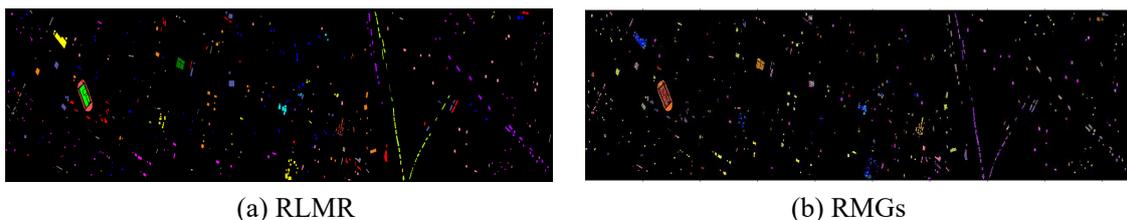


图 3-13 休斯顿大学数据集上各方法的分类结果图

Fig. 3-13 Classification maps of different methods on the HU dataset

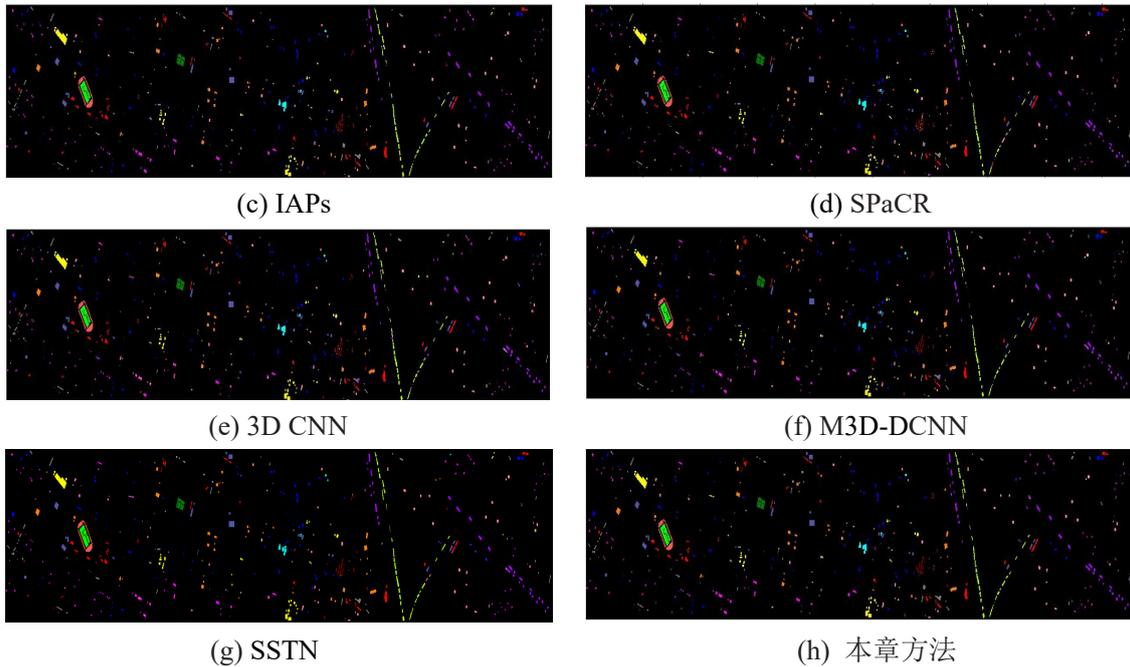


图 3-13 (续图)

3.4.4 国产高光谱图像空谱多维特征提取及分类应用分析

在本章前几节的实验中，利用业内广泛使用的国外高光谱数据集进行了高光谱分类模型的性能验证和分析，为了进一步验证所提方法在国产高光谱图像地物分类任务上的有效性和适用性，本节选用国内唐岛湾区域（山东省青岛市）和雄安新区（河北省保定市）的真实地物图像进行分类实验。选用分类性能较为优异的流形学习方法 RLMR 和深度学习方法 SSTN 作为对比方法，本章所提特征提取方法各参数的设置与前一节保持一致，使用最近邻分类器 NN 和决策树数目为 200 的随机森林 RF^[125]两种分类器进行地物类别区分。每类随机抽取 50 个标记样本作为训练集，剩余样本用于测试，图 3-14 和图 3-15 展示了各方法在两组国内高光谱图像上的地物分类结果图，表 3-10 则列出了各方法的定量化分类结果。

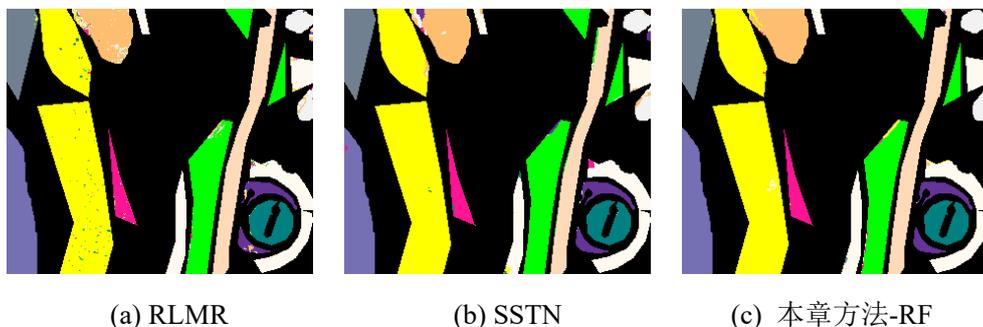


图 3-14 不同方法在唐岛湾地区的高光谱分类结果图

Fig. 3-14 Hyperspectral image classification maps in the Tangdaowan region by different methods

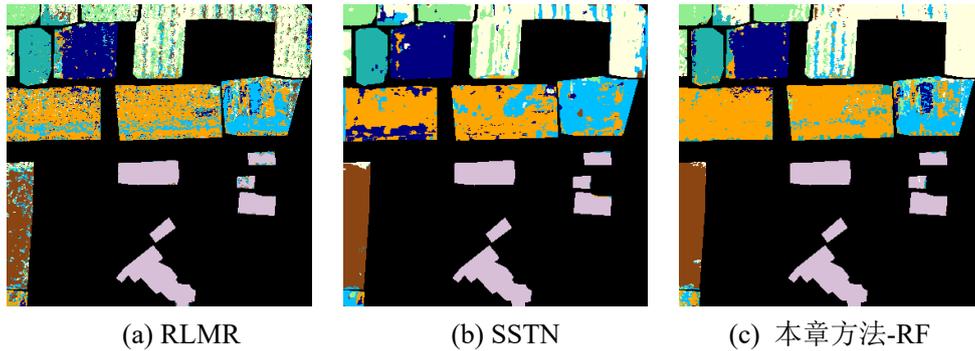


图 3-15 不同方法在雄安区域的高光谱分类结果图

Fig. 3-15 Hyperspectral image classification maps in the Xiongan region by different methods

表 3-10 国产高光谱数据集各方法的分类结果 (%)

Table 3-10 Classification results (%) of different methods on domestic hyperspectral image datasets

类别编号	唐岛湾数据集				雄安数据集			
	RLMR	SSTN	本章方法 NN	本章方法 RF	RLMR	SSTN	本章方法 NN	本章方法 RF
1	100	99.89	98.06	99.73	68.71	94.98	97.42	96.42
2	97.50	99.05	99.32	98.97	82.06	90.18	84.83	87.17
3	99.47	99.55	96.60	99.46	82.79	95.22	74.40	78.87
4	98.93	97.78	98.45	97.50	31.41	54.05	82.17	87.36
5	94.56	96.99	99.92	100	65.44	91.10	85.79	88.70
6	97.68	99.95	99.65	99.35	40.29	56.99	59.05	55.23
7	96.98	83.84	99.74	99.87	72.86	64.80	86.80	86.66
8	92.27	91.78	99.87	99.74	99.10	100	98.02	98.92
9	84.99	77.40	98.95	99.06	—	—	—	—
10	92.88	92.73	93.54	94.65	—	—	—	—
11	100	99.97	100	100	—	—	—	—
OA	97.94	97.56	97.95	98.91	70.95	82.16	82.55	84.20
κ	97.53	97.10	97.56	98.71	65.53	78.79	79.00	80.94

从直观的分类结果图和定量化分类结果可以看出，本章所提的空谱特征提取方法在不同类型的分类器条件下均取得了最高的总体分类精度，且基于集成学习思想的随机分类器 RF 展现出更优异的分类能力，更适用于高光谱图像的地物区分任务。对于唐岛湾数据集中光谱相似度高的异类地物，如类别 7（草地）和类别 9（石楠）、类别 5（木板人行道）和类别 8（砾石道）等，以及雄安数据集中易混淆的地物类别 1（复叶槭）和类别 7（草地），本章所提方法均取得了最高的类内分类精度，表明了所提方法在高光谱数据隐含流形结构挖掘过程中的有效性，能够捕捉类间地物细微的差异性，提升地物特征的判别性。同时，相较于其他两种分类方法，本章所提方法的分类图中地物错分现象更少，更适用于真实场景中复杂区域的类间地物区分。此外，对这两组数据集经由本章所提方法构建地物流形结构的过程进行了分析，结果表明所提方法依据空谱信息联合的方法为每一个目标样本都能筛选到同类别的最近邻样本和次近邻样本，减小了重构模型的误差，因而能更加准确地构建类内地物的本质流形结构，改善类间地物特征的可分性。

3.5 本章小结

由于成像条件的不稳定性和地物背景的复杂性，同一幅高光谱图像中往往存在着同类地物目标具有迥异的光谱响应特性和异类地物目标具有相似的光谱响应特性等现象，通过联合高光谱图像内在的空间信息，可以有效地引导分类模型完成不同地物目标的类别判定。本章面向高光谱分类任务研究了基于可靠邻域结构的地物多维空谱特征提取方法，通过光谱、纹理和空间位置等多维信息的联合构建地物样本可靠的邻域结构，揭示高光谱图像内在的流形结构特性，并结合语义信息提取出地物鉴别性的空谱特征，最终实现地物类别的有效区分。具体而言，首先采用光谱和纹理级联的形式对原始高光谱图像进行地物空谱域的数据重表达，在此基础上，考虑到类内地物在同一幅高光谱场景中空间分布的连续性，提出了一种基于空谱信息联合度量样本相似性的改进 NPE 算法，通过挖掘同类样本的高度相关性，保障重构模型的有效性和邻域结构的可靠性，从而更加准确地揭示高光谱数据内在的流形结构。最后，通过将改进的 NPE 算法和能够挖掘标记样本类别信息的局部线性判别分析法 LFDA 相结合，提取出地物鉴别性的多维空谱特征。实验结果表明，所提方法在成像光谱仪、采集区域等不同条件下获取的高光谱图像分类任务中都展现出了良好的鲁棒性和适应性，能够为地物类别的良好区分提供更具鉴别性的多维空谱特征。

第4章 基于半监督学习和多类型信息融合的高光谱小样本分类

4.1 引言

对于高光谱图像地物解译任务而言，获取大量已知类别的标签样本往往需要业内专家花费大量的时间和精力对关注区域进行人工标注，而现有的高光谱分类模型特别是基于深度学习模型的分​​类方法，往往都需要足够的标记样本对模型进行充分训练，才能获得较为理想的分类结果，不适用于对时效性和造价成本有要求的实际地物解译应用。因此，如何利用有限的标记样本得到较为理想的地物分类精度和图像解译效果，始终是高光谱图像分类应用研究领域里的一项重要难题。考虑到高光谱图像中的同类地物往往在空间分布上呈现密集分布的状态，研究人员利用空间窗口或是超像素块等局部空间区域，挖掘出同类地物在局部空间中潜在的紧密关系，从待分类的目标图像中筛选出满足条件的无标记样本并进行类别标注，规避人工标注数据的高昂成本，从而提升小样本条件下的高光谱图像分类精度。但由于地物尺度差异大、成像场景复杂和目标内部结构精细等原因，现有方法大多数仅依赖于短程空间距离上局部区域的样本筛选，忽视了长程空间距离上同类地物样本间的关联性，此外，现有的高光谱小样本分类方法大多数局限于单一属性的地物特点表达，忽视了不同类型信息表达中地物样本的内在联系，类内地物间密切的关联属性挖掘不充分，造成地物类别区分度不够准确、分类效果不理想等问题。

针对上述问题，本章提出了基于半监督学习和多类型信息融合的高光谱小样本分类方案。在第3章中，所提方法利用空谱信息的联合挖掘出了高光谱数据内在的流形结构，并构建出了地物样本的高度可靠邻域结构，在此基础上，本章首先利用高度可靠的邻域结构和半监督学习机制从无标记样本集中逐步筛选出高质量的伪样本，结合已知的有限语义信息进行类别标注后添加入原始的训练样本集中，从而实现标记样本的数目扩充；然后，考虑同类地物在局部近邻的空间区域中往往会呈现出空间连续性，结合不同类型信息上地物表达出的关联性，自适应地实现目标样本的类别更新，通过有限的标记样本语义信息和高光谱图像蕴含的多类型信息进行有机的结合，改善小样本条件下高光谱图像的解译效果，缓解分类模型性能对标记样本数目的过度依赖。

4.2 高光谱小样本分类任务概述

在上一章中，本文提出了一种基于可靠邻域结构的高光谱空谱特征提取方法，通过空谱信息联合的方式度量样本之间的相似度，挖掘数据集内在的高可靠邻域结构，从而将原始的高维高光谱数据集 $\mathbf{X} = [\mathbf{X}^L, \mathbf{X}^U] \in \mathfrak{R}^{d_{\text{spe}} \times z}$ 投影到低维的特征空间 $\mathbf{F} = [\mathbf{F}^L, \mathbf{F}^U] \in \mathfrak{R}^{u \times z}$ 中，结合标记样本集 \mathbf{X}^L 的语义信息 \mathbf{Y}^L 和最近邻 NN 分类器，实现无标记样本集 \mathbf{X}^U 各样本的类别判定，实验结果表明，所提方法能够有效地利用高光谱数据蕴含的丰富信息，提取出的鉴别性地物特征取得了良好的分类精度。但地物类别的标定需要耗费大量的人力物力，在实际应用中无法保障标记样本数量的充足性，因而在标记样本数目十分有限的条件下，鉴别性语义类别信息大量减少，将导致分类模型的分分类精度和解译效果将大幅度下降。不同标记样本数目下的各数据集图像解译效果如图 4-1 所示，从图中结果可以看出在标记样本数目稀缺的条件下，各数据集分类结果中出现了大量的错分现象，直接影响后续的地物分类应用。

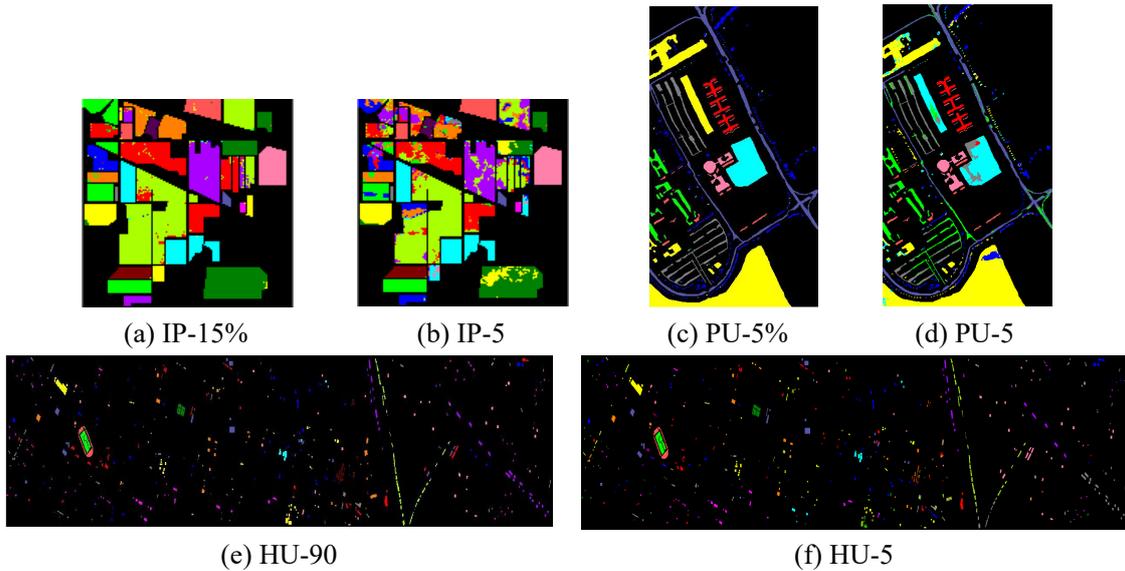


图 4-1 不同标记样本数目下各数据集的图像解译效果

Fig. 4-1 Image interpretation of each dataset with different number of labeled samples

小样本条件是指标记样本的数目远远小于数据的信息维度，而高光谱图像自身存在着较高的光谱信息维度，这会使分类模型的拟合效果差，最终导致分类精度低、图像解译效果差等问题。但由于图像中的地物标注往往成本昂贵且耗时量大，因此，如何利用有限的标记样本和高光谱图像中已知的各类先验知识信息，有效地对不同类型的地物特点进行表征，构建具有良好学习能力和泛化能力的分类模型，缓解分类模型对标记样本的重度依赖是小样本条件下高光谱分类任务面

临的主要难点。样本扩充作为一种最直接的解决方案，意图通过已知的各类数据知识信息对待分类的目标高光谱图像实现智能化的样本扩充，从大量的无标记图像区域中筛选出满足一定条件的样本数据，并按照某种规则赋予相应的语义类别，用以扩充原始有限的标记样本集，直接解决标记样本数目短缺的问题，无需筛选具有相关语义信息的其他高光谱图像，同时也避免了不同场景下进行语义信息迁移时引入的不确定性，能够削弱高光谱分类模型性能对标记样本数目的敏感性，并有效地提升标记样本有限时高光谱图像地物的解译精度。下面对基于样本扩充策略的高光谱图像小样本分类方法，涉及到的关键问题进行概述。

对于已知语义信息的训练数据集 $\mathbf{D}^r = \{\mathbf{d}_i^r\}_{i=1}^{n_r} \in \mathcal{R}^{q \times n_r}$ ，包含有光谱信息维度为 q 的 n_r 个标记样本，其中 $n_r \ll q$ ，由于标记样本的数量十分稀少，仅依靠语义信息难以有效地训练得到具有良好泛化能力的分类模型，因此，研究人员利用有限的语义信息和高光谱图像蕴含的空谱信息对地物特点进行学习，继而从大量无标记信息的测试数据集 \mathbf{D}^e 筛选出满足局部约束条件的伪样本集 \mathbf{D}^{ps} ，实现原始训练集 \mathbf{D}^r 的合理扩充，更新分类模型参数最终完成测试数据集 \mathbf{D}^e 中各个样本归属类别的有效识别，缓解因稀缺标记样本导致的地物难以有效区分、图像解译精度低和高光谱分类应用受制约等问题。在上述的过程中，如何充分地利用高光谱图像数据已知的各类先验信息，制定选取伪样本的有效约束条件，是保障伪样本集高质量和高可靠性的关键要素，也直接影响了模型的分类性能。

4.3 面向高光谱小样本分类条件的样本扩充和类别修正方案

4.3.1 整体模型框架

在上一章的研究工作中，所提出的特征提取方法通过高光谱图像中的空谱联合信息对样本间距离进行建模，能够有效地衡量不同样本之间的空谱差异性，从而在特征空间中加强同类样本之间聚合性的同时，削弱了异类样本之间的相关性。结合前期的研究基础和基于样本扩充策略小样本分类方法的深度分析，本章设计了基于半监督学习和多类型信息融合的高光谱小样本分类方法，旨在缓解标记样本的稀缺性对图像解译造成的各种不利影响，整体分类模型的流程图如图 4-2 所示，主要包括所样本扩充和类别修正两个主要部分。首先，借助于第 3 章中空谱信息联合下构建出的样本高度可靠邻域结构，结合有限的标签语义信息，预测未标记样本的标签信息，利用可靠邻域关系中样本的关联性和语义信息的一致性，对大量的无标签样本进行逐级处理，筛选后得到带有伪标签信息的伪样本数据集，再对原始的标记样本集进行扩充，经循环迭代后，最终实现样本扩充。然后，本

章进一步提出了基于局部同质区域语义信息引导的地物类别修正方案，利用同类样本在高光谱图像中的空间上下文关联信息，对剩余的无标记样本进行语义标签的修正，最终改善小样本条件下高光谱图像的地物分类结果。

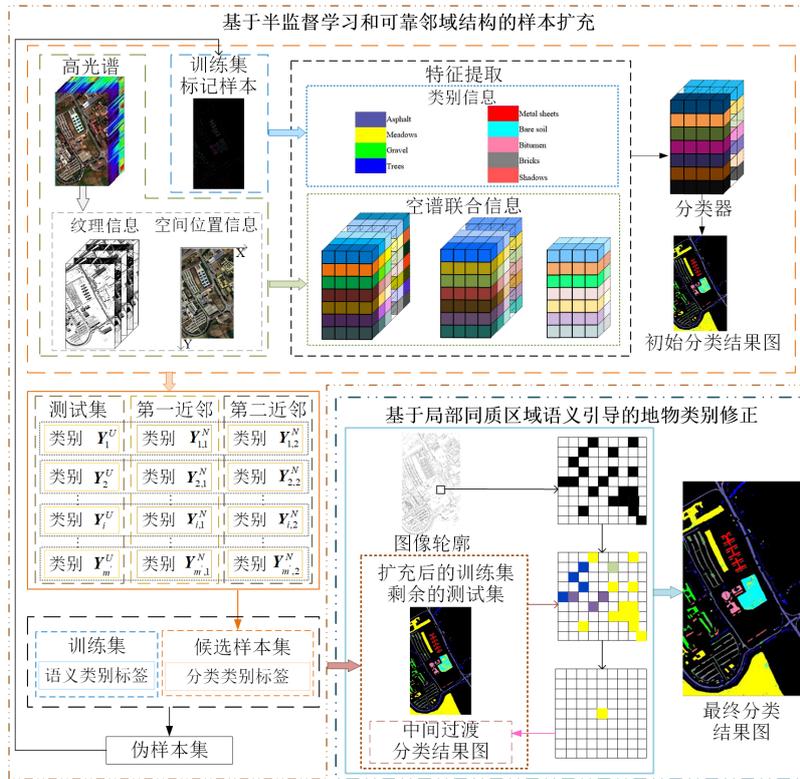


图 4-2 基于半监督学习和多类型信息融合的高光谱小样本分类框架

Fig. 4-2 Flowchart of the proposed hyperspectral classification method with small sample size based on semisupervised learning and multiple information fusion

4.3.2 基于半监督学习和可靠邻域结构的样本扩充

对于高光谱图像数据而言，除了具有丰富的光谱信息外，还蕴含着不同类型的空间信息，如地物样本在图像中的空间位置信息、纹理信息、边缘轮廓信息等，利用这些不同类型的信息在地物特点描述的互补性和多样性，可以从不同角度对同一类型的地物样本构建更加全面的连接关系。在第 3 章的研究工作中，通过光谱信息和纹理信息的联合利用，对高光谱数据进行空谱域上的重新表达，更加清晰地揭示高光谱图像中样本的空谱信息，假设重表达后的高光谱数据表示为 $\mathbf{X} = [\mathbf{X}^L, \mathbf{X}^U] \in \mathbb{R}^{d \times z}$ ，其中 d 表示基于光谱信息和纹理信息级联后的空谱信息维度， $z = n + m$ 表示数据集中样本的总体数目， n 和 m 则分别代表已知类别信息的标记样本数目和待确定类别的未标记样本数目。标记样本集 \mathbf{X}^L 的标签信息可分别表示为 $\mathbf{Y}^L = \{y_1^L, y_2^L, \dots, y_n^L \mid y_i \in \mathbb{R}^C, i = 1, 2, \dots, n\}$ ，其中 C 为已知标签的类别数目。在上一

章中，利用局部线性判别分析法 LFDA 和改进 NPE 算法的联合，可以实现高光谱图像中地物的鉴别性空谱特征提取，其计算过程可表示为：

$$[\mathbf{X}^L, \mathbf{X}] \begin{bmatrix} \mathbf{P}_{n \times n}^b & \mathbf{0}_{n \times z} \\ \mathbf{0}_{z \times n} & \mathbf{I}_{z \times z} \end{bmatrix} [\mathbf{X}^L, \mathbf{X}]^T = \lambda [\mathbf{X}^L, \mathbf{X}] \begin{bmatrix} \mathbf{P}_{n \times n}^w & \mathbf{0}_{n \times z} \\ \mathbf{0}_{z \times n} & \mathbf{M}_{z \times z} \end{bmatrix} [\mathbf{X}^L, \mathbf{X}]^T \varphi \quad (4-1)$$

通过理论分析和实验结果验证，通过上式可将原始高维度的地物样本投影到低维的流形特征空间中，同类地物能够以更加紧密的状态聚集在特征空间中。此外，改进的 NPE 算法利用光谱信息、纹理和空间位置信息的联合衡量不同样本之间的相似性，为待重构的目标样本以最大的可能性从全部的样本集中筛选其同类别近邻样本，实验结果表明近邻样本的数据越多，与待重构目标样本属于同一语义类别的概率越低，即近邻样本的可靠性降低，而仅仅选用一个近邻样本时容易造成同类地物在特征投影空间中出现多个聚集中心，当近邻样本个数为 2 时，邻域结构的可靠性最高，相应的分类方法精度也最大。基于上一章的研究内容，本节选用最近邻样本和次近邻样本对每个目标样本进行重构表示，并将高可靠邻域结构中的语义信息一致性设定为样本扩充过程的筛选条件。

小样本条件下标记样本的数目远远小于数据的特征维度，重构数据集 \mathbf{X} 可表示为 $\mathbf{X} = [\mathbf{X}^L, \mathbf{X}^U] \in \mathbb{R}^{d \times z}$ ($n \ll d$)，相应的近邻样本结构矩阵可表示为 $\mathbf{N} = [\mathbf{N}^L; \mathbf{N}^U] \in \mathbb{R}^{z \times 2}$ ，其中 $\mathbf{N}^L \in \mathbb{R}^{n \times 2}$ 和 $\mathbf{N}^U \in \mathbb{R}^{m \times 2}$ 分别表示标记样本集和无标记样本集对应的近邻样本矩阵。 \mathbf{N}^L 和 \mathbf{N}^U 二者既可能包含训练集中的标记样本也可能包含测试集中的无标记样本，即近邻样本矩阵中的各个样本可能位于标记样本集也可能位于无标记样本集，通过上一阶段的特征提取和基于最近邻分类器 NN 的类别判定，可以获取到无标记样本集的初始分类标签 \mathbf{Y}^U ，通过整合已知的标记样本集语义信息 \mathbf{Y}^L 和无标记样本集的初始分类结果 \mathbf{Y}^U ，可以获得近邻样本矩阵 \mathbf{N} 对应的语义类别矩阵 \mathbf{Y}^N ，具体可表示为 $\mathbf{Y}^N = [\mathbf{Y}^{NL}; \mathbf{Y}^{NU}] \in \mathbb{R}^{z \times 2}$ ，其中 \mathbf{Y}^{NL} 和 \mathbf{Y}^{NU} 分别为标记样本集的近邻样本标签矩阵和无标记样本集的近邻样本标签矩阵。为了更加直观地说明，表 4-1 列出了数据集 \mathbf{X} 的近邻样本矩阵及其类别信息矩阵，初始阶段通过高光谱图像已知的各类先验信息可以获得数据集 \mathbf{X} 的近邻样本矩阵 \mathbf{N} 和无标记样本的初始语义类别标签 \mathbf{Y}^U ，对于任意一个标记样本 \mathbf{x}_i^L 而言，其最近邻样本和次近邻样本分别为 $\mathbf{N}_{i,1}^L$ 和 $\mathbf{N}_{i,2}^L$ ，二者互不相同，但这两个样本可能都位于标记样本集 \mathbf{X}^L 中也可能都属于无标记样本集 \mathbf{X}^U ，也可能一个隶属于标记样本集 \mathbf{X}^L 另一个属于无标记样本集 \mathbf{X}^U 。具体而言，近邻样本的类别信息由该样本归

属的样本集决定，例如若目标样本 \mathbf{x}_i^L 的最近邻样本 $N_{i,1}^L \in \mathbf{X}^L$ ，则 $\mathbf{Y}_{i,1}^L$ 由训练集样本语义信息 \mathbf{Y}^L 确定；若 $N_{i,1}^L \in \mathbf{X}^U$ ，则 $\mathbf{Y}_{i,1}^L$ 由测试集的初始分类结果 \mathbf{Y}^U 决定。同理，对于每一个无标记样本 \mathbf{x}_j^U 邻域结构中的近邻样本语义标签，也由其数据集 \mathbf{X} 中的位置决定，最终整理后可获得近邻样本矩阵 \mathbf{N} 的类别标签矩阵 \mathbf{Y}^N 。

 表 4-1 数据集 \mathbf{X} 的近邻样本矩阵及其类别标签矩阵

 Table 4-1 The nearest neighbor matrix and its corresponding class label matrix of the dataset \mathbf{X}

样本	标记样本集 \mathbf{X}^L			无标记样本集 \mathbf{X}^U			
	已知 标签	邻域结构	邻域结构 类别矩阵	样本	预测 标签	邻域结构	邻域结构 类别矩阵
\mathbf{x}_1^L	y_1^L	$N_{1,1}^L N_{1,2}^L$	$\mathbf{Y}_{1,1}^{NL} \mathbf{Y}_{1,2}^{NL}$	\mathbf{x}_1^U	y_1^U	$N_{1,1}^U N_{1,2}^U$	$\mathbf{Y}_{1,1}^{NU} \mathbf{Y}_{1,2}^{NU}$
...
\mathbf{x}_i^L	y_i^L	$N_{i,1}^L N_{i,2}^L$	$\mathbf{Y}_{i,1}^{NL} \mathbf{Y}_{i,2}^{NL}$	\mathbf{x}_j^U	y_j^U	$N_{j,1}^U N_{j,2}^U$	$\mathbf{Y}_{j,1}^{NU} \mathbf{Y}_{j,2}^{NU}$
...
\mathbf{x}_n^L	y_n^L	$N_{n,1}^L N_{n,2}^L$	$\mathbf{Y}_{n,1}^{NL} \mathbf{Y}_{n,2}^{NL}$	\mathbf{x}_m^U	y_m^U	$N_{m,1}^U N_{m,2}^U$	$\mathbf{Y}_{m,1}^{NU} \mathbf{Y}_{m,2}^{NU}$

上一章的研究结果表明，所提方法通过空谱信息联合构建出的近邻样本结构具有高度的可靠性，近邻样本有很大的概率与待重构目标样本属于同一语义类别，即高度可靠邻域结构展现出的样本语义一致性具有较高的置信度，在此基础上，本节首先通过对比无标记样本集中每个无标记样本 \mathbf{x}_j^U 与其近邻样本集 $[N_{j,1}^U, N_{j,2}^U]$ 的类别信息，基于邻域结构中语义信息的一致性从无标记样本集中筛选出候选样本集 \mathbf{X}^C ，具体的求解过程可表示为如下过程：

$$\begin{aligned} \mathbf{X}^C &= \bigcup_j \mathbf{X}_j^U \text{ s.t. } \mathbf{Y}_j^U = \mathbf{Y}_{j,1}^{NU} \text{ 且 } \mathbf{Y}_j^U = \mathbf{Y}_{j,2}^{NU} \\ \mathbf{Y}^C &= \bigcup_j \mathbf{Y}_j^U \text{ s.t. } \mathbf{Y}_j^U = \mathbf{Y}_{j,1}^{NU} \text{ 且 } \mathbf{Y}_j^U = \mathbf{Y}_{j,2}^{NU} \end{aligned} \quad (4-2)$$

为了进一步从候选样本集 \mathbf{X}^C 中筛选出高置信度的伪样本集，利用已知标记样本集 \mathbf{X}^L 中准确的语义类别信息进一步比对每个标记样本 \mathbf{x}_i^L 与其位于候选样本集 \mathbf{X}^C 的近邻样本类别信息，消除无标记样本初始类别预判与邻域结构中一致性语义信息的歧义性，最终确定用于样本扩充的伪样本数据集 \mathbf{X}^P 及其类别标签 \mathbf{Y}^P ，相应的求解过程可表示为：

$$\begin{aligned} \mathbf{X}^P &= \bigcup_i \mathbf{X}_i^C \text{ s.t. } \mathbf{X}_i^C \in N_j^L \text{ 且 } \mathbf{Y}_i^C = \mathbf{Y}_j^L \\ \mathbf{Y}^P &= \bigcup_i \mathbf{Y}_i^C \text{ s.t. } \mathbf{X}_i^C \in N_j^L \text{ 且 } \mathbf{Y}_i^C = \mathbf{Y}_j^L \end{aligned} \quad (4-3)$$

相应地，用于样本扩充的伪样本数据集 \mathbf{X}^P 中涵盖的地物类别数目 C^P ，可通

过对其类别标签 \mathbf{Y}^P 进行统计获得，具体的计算过程可表示为：

$$C^P = \sum_{i=1}^C \mathbf{P}_i^P \quad \text{其中} \quad \mathbf{P}_i^P = \begin{cases} 1 & \text{if } i \in \mathbf{Y}^P \\ 0 & \text{if } i \notin \mathbf{Y}^P \end{cases} \quad (4-4)$$

其中 C^P 的数值大小表明了伪样本数据集 \mathbf{X}^P 中地物类别数目的多少，为了避免引入不均衡的语义信息，经伪样本数据集 \mathbf{X}^P 统计出来的地物类别总数 C^P 应与待解译高光谱图像已知的地物类别总数 C 保持一致，满足设定的条件后最终得到了本轮可用于样本扩充的伪样本数据集 \mathbf{X}^P 及其类别标签 \mathbf{Y}^P 。对原始有限的标记样本集进行扩充并缩减无标记的样本集后，再进行新一轮的特征提取和缩减后剩余无标注样本的类别标注，并利用上述两级筛选流程进一步选取出满足条件的高置信度伪样本集 \mathbf{X}^P ，用于扩充标记样本的数量，通过几轮循环迭代过程，直至没有满足条件的伪样本出现或是 C^P 不满足设定条件为止。本节将半监督学习和高可靠的邻域结构相结合，利用邻域结构中的语义信息对齐，逐级筛选出高质量、高准确度的伪样本集，并同时类内语义信息的有效性和不同类别语义信息的平衡性进行综合考量，最终实现对原始标记样本集的有效扩充。为了更加清晰地表述本节所提出的样本扩充策略，其求解过程如算法 4-1 所示。

算法 4-1: 样本扩充的求解过程

输入: 原始标记样本集 \mathbf{X}^L 和无标记的样本集 \mathbf{X}^U ，语义标签信息 \mathbf{Y}^L 及类别数目 C

1. 利用公式(4-1)和已知标签信息 \mathbf{Y}^L 进行分类器训练，获得 \mathbf{X}^U 的初始分类标签 \mathbf{Y}^U
2. 求解公式(4-2)，从 \mathbf{X}^U 中筛选候选样本集 \mathbf{X}^C ，确定其相应标签信息 \mathbf{Y}^C
3. 求解公式(4-3)，从 \mathbf{X}^C 中确定用于扩充的伪样本集 \mathbf{X}^P 及其类别标签 \mathbf{Y}^P ，同时通过公式(4-4)计算出 \mathbf{X}^P 涵盖的地物种类数目 C^P
4. **while** $\mathbf{X}^P \neq \Phi$ 且 $C^P = C$
5. 更新原始的样本集，扩充后的标记样本集 $\mathbf{X}^{L'} = \mathbf{X}^L \cup \mathbf{X}^P$ 及标签 $\mathbf{Y}^{L'} = \mathbf{Y}^L \cup \mathbf{Y}^P$
缩减后的剩余无标记样本集 $\mathbf{X}^{U'} = \mathbf{X}^U - \mathbf{X}^P$
6. 利用公式(4-1)和扩充标记样本集 $\mathbf{X}^{L'}$ 及 $\mathbf{Y}^{L'}$ ，重新计算空谱特征并对分类器进行训练，获得 $\mathbf{X}^{U'}$ 的类别标签 $\mathbf{Y}^{U'}$
7. 求解公式(4-2)，从 $\mathbf{X}^{U'}$ 中筛选候选样本集 \mathbf{X}^C ，确定其相应标签信息 \mathbf{Y}^C
8. 求解公式(4-3)，从 \mathbf{X}^C 中确定用于扩充的伪样本集 \mathbf{X}^P 及其类别标签 \mathbf{Y}^P ，同时通过公式(4-4)计算出伪样本集涵盖的地物种类数目 C^P
9. **end while**

输出: 扩充后标记样本集 $\mathbf{X}^{L'}$ 和剩余无标记样本集 $\mathbf{X}^{U'}$ 及相应的标签信息 $\mathbf{Y}^{L'}$ 和 $\mathbf{Y}^{U'}$

4.3.3 基于局部同质区域语义信息引导的地物类别修正

经过上一阶段的样本扩充后,原始的标记样本集 \mathbf{X}^L 得到了有效的扩充,扩充后的标记样本集和类别标签可分别表示为 $\mathbf{X}^{L'}$ 和 $\mathbf{Y}^{L'}$, 缩减后剩余的无标记样本集 $\mathbf{X}^{U'}$ 也经 $\mathbf{X}^{L'}$ 训练后的分类器被赋予了相应的预测类别标签 $\mathbf{Y}^{U'}$ 。此处,为了将初始标记样本集 \mathbf{X}^L 训练分类器后,得到的无标记样本集标签结果 \mathbf{Y}^U 和扩充后标记样本集 $\mathbf{X}^{L'}$ 对分类器训练后得到的剩余无标记样本集分类结果 $\mathbf{Y}^{U'}$ 进行区分,本节将前者 \mathbf{Y}^U 命名为初始分类结果,后者 $\mathbf{Y}^{U'}$ 命名为中间过渡分类结果,需要进一步的修正得到最终的精细化分类结果。考虑到高光谱图像中的同类地物在地理空间上往往呈现毗邻密集分布以及不同类型的地物尺寸差异度大、内部结构精细等情况,而高光谱图像中地物空间位置关联度反映了地物的空间分布信息,图像梯度则描绘出地物的边缘轮廓信息,鉴于此,本节综合利用高光谱图像蕴含的多类型空间信息,对剩余无标记样本集中的各个样本逐一提取其局部同质区域,并利用复杂背景下局部同质空间内语义信息的高度关联性引导对目标样本的标签类别进行自适应修正,从而进一步提升小样本条件下高光谱图像的地物分类精度。

考虑到高维度的高光谱图像包含了一定的冗余信息,本节首先利用主成分分析法 PCA 提取图像的前两个主成分,进而计算整幅图像的地物边缘轮廓信息。通过在图像中不断平移 Sobel 算子,获取水平方向的梯度信息 \mathbf{P}_h 和垂直方向的梯度信息 \mathbf{P}_v , 通过公式(4-5)将二者相结合获得整体图像的梯度表示为:

$$\nabla \mathbf{P} = \frac{\exp(-\mathbf{P}_h) + \exp(-\mathbf{P}_v)}{2} \quad (4-5)$$

然后,通过归一化操作后最终获得用于反映地物边缘轮廓的图像梯度信息 \mathbf{G} 。对于缩减后剩余无标记样本集 $\mathbf{X}^{U'}$ 中的任意一个样本 $\mathbf{X}_i^{U'}$ 而言,其在高光谱图像中的空间位置可表示为 (x_i, y_i) , 以该目标样本的位置为中心,利用尺寸为 $w \times w$ 的空间窗口确定其局部近邻空间区域。假设该局部窗口内的梯度信息和局部空间近邻样本集可分别表示为 $\mathbf{G}^{U'}$ 和 \mathbf{X}^A , 那么,在以目标样本 $\mathbf{X}_i^{U'}$ 为中心的局部窗口内,其同质样本集 \mathbf{X}^H 可通过下式进行求解:

$$\mathbf{X}^H = \bigcup_j \mathbf{X}_j \text{ s.t. } \mathbf{G}_j = \mathbf{G}^{U'} \text{ 且 } \mathbf{X}_j \in \mathbf{X}^A \quad (4-6)$$

考虑到局部窗口往往是由相似特性样本组成的像素集合区域,其内部的地物样本在类别信息上呈现出高度的一致性,因此,本文将局部窗口引入类别修正方案中,通过筛选目标样本在局部窗口内的同质样本集,进而统计局部窗口内的主

体语义信息，引导目标样本完成类别标签的自适应修正。对于空间窗口内的中心样本 $\mathbf{X}_i^{U'}$ 而言，当其处于不同类型地物的边界时，不加区分地利用窗口语义信息对中心样本进行修正，很容易造成较大的类别误判，因此，本节利用空间分布信息和边缘轮廓信息的联合共同筛选目标样本具有高信任度的同质样本集 \mathbf{X}^H ，减少异类地物样本对同质样本集选取的干扰。假设局部同质样本集 \mathbf{X}^H 包含着 ν 个地物样本，对应的标签类别为 \mathbf{Y}^H ，这些样本可能隶属于不同的地物类别，每个类别所包含的样本数目可通过下式进行求解：

$$\mathbf{N}^H = (n_1^H, n_2^H, \dots, n_C^H) \mid n_c^H = \sum_{i=1}^{\nu} (\mathbf{Y}_i^H = c), c = 1, 2, \dots, C \quad (4-7)$$

如果 $\mathbf{X}_i^{U'}$ 的同质样本集 \mathbf{X}^H 绝大多数样本都属于同一个语义类别 c ，表明该局部空间主体上被该类别的地物样本覆盖，那么，对于局部窗口内的中心样本点其类别可通过下式进行修正：

$$\mathbf{Y}_i^{U''} = \begin{cases} c & \text{if } n_c^H = \max(\mathbf{N}^H) \text{ 且 } n_c^H > (\nu/2) \\ \mathbf{Y}_i^{U'} & \text{else} \end{cases} \quad (4-8)$$

换言之，基于不同类型空间信息的融合筛选出了 $\mathbf{X}_i^{U'}$ 局部窗口内的同质样本集 \mathbf{X}^H ，通过对其类别标签 \mathbf{Y}^H 进行统计，进而确定该局部窗口区域主体隶属的地物类别，从而对中心样本 $\mathbf{X}_i^{U'}$ 进行标签修正。通过对测试集 $\mathbf{X}^{U'}$ 中的全部样本进行逐一类别修正，最终获得更新后的标签类别结果 $\mathbf{Y}^{U''}$ ，并以修正后的新类别结果替代前期的中间过渡分类结果 $\mathbf{Y}^{U'}$ ，重复执行上述操作，直至实现全局自适应的精细化类别修正。同时，为了避免局部类别修正循环迭代引起过多的运算量，本节计算前后两次分类结果中变化类别的数目 C' ，并将引入超参数 C^{con} 设定为类别修正方案的循环截止条件，具体的计算过程可表示为

$$C' = \sum_{i=1}^r C_i^U \text{ 其中 } C_i^U = \begin{cases} 1 & \text{if } \mathbf{Y}_i^{U'} = \mathbf{Y}_i^{U''} \\ 0 & \text{else } \mathbf{Y}_i^{U'} \neq \mathbf{Y}_i^{U''} \end{cases} \quad (4-9)$$

综上所述，本节通过空间分布信息和边缘梯度信息的联合利用，筛选出局部窗口内目标样本的同质样本集，基于同质样本集中最大覆盖率的语义类别修正窗口中心样本的类别标签，缓解小样本条件下图像解译过程中的边界模糊、地物错分等现象，从而得到更加精细化的高光谱地物分类结果，具体的求解过程在算法4-2中进行了归纳总结。

算法 4-2: 基于局部同质区域的地物类别修正

输入: 扩充后的标记样本集 $X^{U'}$ 和标签信息 $Y^{U'}$, 剩余的无标记样本集 $X^{U''}$ 和中间过渡类别标签 $Y^{U''}$ 以及超参数 C^{con}

1. 利用公式(4-6)计算 $X^{U'}$ 中每个样本 $x_i^{U'}$ 的局部同质样本集 X^H
2. 利用公式(4-7)和(4-8)对 $X^{U'}$ 的类别标签 $Y^{U'}$ 进行修正, 获得修正后的新标签类别 $Y^{U''}$ 并通过公式(4-9)计算变化类别数目 C'
3. 更新无标记样本集的类别标签 $Y^{U''} = Y^{U''}$
4. **while** $C' \neq 0$
5. 利用公式(4-6)计算 $X^{U''}$ 中每个样本 $x_i^{U''}$ 的局部同质样本集 X^H
6. 利用公式(4-7)和(4-8)对 $X^{U''}$ 的类别标签 $Y^{U''}$ 进行修正, 获得标签类别 $Y^{U''}$ 并通过公式(4-9)计算修正类别的样本个数 C'
7. 更新测试集类别标签 $Y^{U''} = Y^{U''}$ 和修正类别的样本个数 $C' = C'$
8. **if** $C' < C^{con}$
9. **break**
10. **endif**
11. **end while**

输出: 剩余无标记样本集 $X^{U''}$ 修正后的最终分类标签结果 $Y^{U''}$

4.4 实验结果及分析

4.4.1 实验数据与设置

在本章各分类方法的性能验证过程中, 实验数据与第 3 章一致同样选用了三组国外高光谱数据集和两组国内高光谱数据集进行所提小样本分类方法的鲁棒性和适应性验证分析, 纹理特征 EMAP 的各属性参数与上一章中的参数设置保持一致, 空谱特征的维度和近邻样本的个数等核心参数也与前期设置相同, 分别设定为 30 和 2。同时, 为了更好地验证所提出小样本分类方法各部分的有效性, 本章同样也使用最简单的最近邻 NN 分类器。此外, 为了节省运算时间, 在基于类别修正的精细化分类方案中, 超参数 C^{con} 的取值设定为 5。为了更好地测试模型的泛化性能, 每类地物的标记样本数目范围为 $\{3, 5, 7\}$, 在每组小样本条件下重复实验 5 次, 剔除训练样本随机抽取带来的不确定性, 将计算出的平均结果作为最后的分类结果进行对比分析。

4.4.2 消融实验与参数分析

本章提出了一种基于半监督学习和多类型信息融合的高光谱小样本分类方法, 该方法包含两部分内容, 其一是利用可靠邻域结构和半监督学习实现样本的扩充,

另一部分则是基于类别修正的精细化分类，最终改善小样本条件下的高光谱图像解译效果。在具体的实验过程中，本节首先比对了不同训练样本数目下各个数据集基于原始标记样本集 \mathbf{X}^L 的初始阶段分类结果、基于扩充后训练集 $\mathbf{X}^{L'}$ 的中间阶段分类结果和完成精细化类别修正后的最终阶段分类结果，其中中间阶段分类结果由两部分组成，一部分是伪样本数据集 \mathbf{X}^P 的类别标签 \mathbf{Y}^P ，另一部分是剩余无标记样本集 $\mathbf{X}^{U'}$ 经扩充后标记样本集 $\mathbf{X}^{L'}$ 训练分类器后获得的类别标签 $\mathbf{Y}^{U'}$ ，最终阶段分类结果则是由伪样本数据集标签信息 \mathbf{Y}^P 和类别修正后的类别标签 $\mathbf{Y}^{U'}$ 组成。此外，在类别修正的精细化分类过程中，局部空间的窗口尺寸设定为 11×11 ，各个数据集在不同标记样本数目下的总体分类精度 OA 如图 4-3 所示。从柱状图对比结果可以看出，对于所有的数据集，本章所提分类方法中的每一部分对总体分类精度都有稳步的提升作用，最终改善小样本条件下图像的解译效果。具体而言，对于印第安纳 IP、帕维亚大学 PU 和休斯顿大学 HU 等三个数据集，样本扩充策略在不同数目的标记样本下 OA 值平均分别提升了 2.6%、1.6% 和 1.9%，基于类别修正的精细化分类方案在样本扩充策略的基础上进一步地改善了分类结果，将总体分类精度 OA 分别再次提升了 7.6%、3.8% 和 1.2%。除此之外，标记样本包含着鉴别性的语义信息，对无标记的样本类别区分能力起到关键作用，因而随着标记样本数目的增多，所提方法的分类精度也得到了显著的提升。

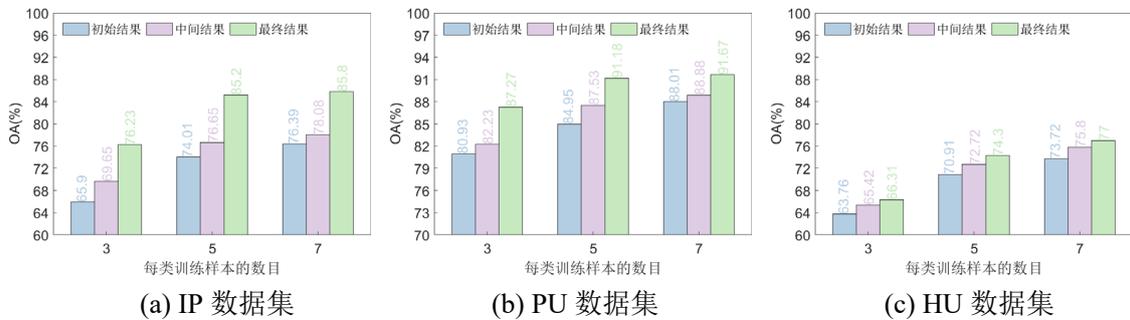


图 4-3 不同训练样本数目下各数据集各阶段的总体分类精度

Fig. 4-3 OA in different stages of the proposed method on all the datasets with varying number of training samples

对于本章所提的样本扩充策略，伪样本集的质量直接影响标记样本集扩充的有效性，类别错误预测的伪样本将会影响模型的分类性能，因此本节对不同条件下各个数据集筛选出的伪样本数量和伪样本准确率进行了统计，实验结果如表 4-2 所示。从表中所列结果可以看出，基于半监督学习和高可靠邻域结构的样本扩充方案能够以较高的可信度筛选出用于样本扩充的伪样本集，且随着标记样本数目的增加，伪样本的数量也随之增加，原因在于标记样本集的数目越多，可靠的先验知识越多，能够从增加的语义信息中择选出更多准确的伪样本，用于扩充原始

有限的标记样本集，从而改善高光谱图像整体的分类结果。除此之外，为了更加直观地显示样本扩充策略对原始训练集的影响，图 4-4 绘制了每类标记样本数目为 5 的条件下，原始标记样本集 X^L 和添加伪样本集后的扩充标记样本集 $X^{L'}$ 在每个数据集中的空间分布情况，从图中展示的标记样本空间分布结果可以看到，本章所提方法能够挖掘同类样本隐含的密切关联，因而筛选出的伪样本并非全部集中分布在原始标记样本的空间邻近区域。

表 4-2 样本扩充过程中添加的伪样本数目与准确性

Table 4-2 The number and accuracy of the pseudo samples in the sample augmentation scheme

初始标记样本每类数目	IP 数据集		PU 数据集		HU 数据集	
3	506	100%	31	99.02%	553	100%
5	617	99.91%	156	100%	1030	100%
7	605	100%	232	99.55%	1425	100%

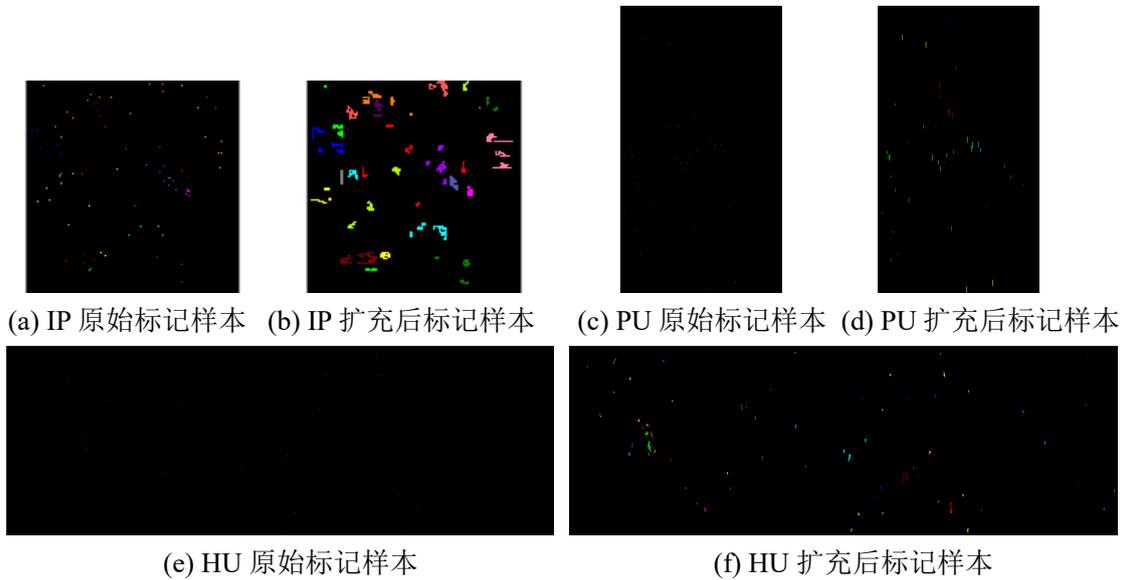
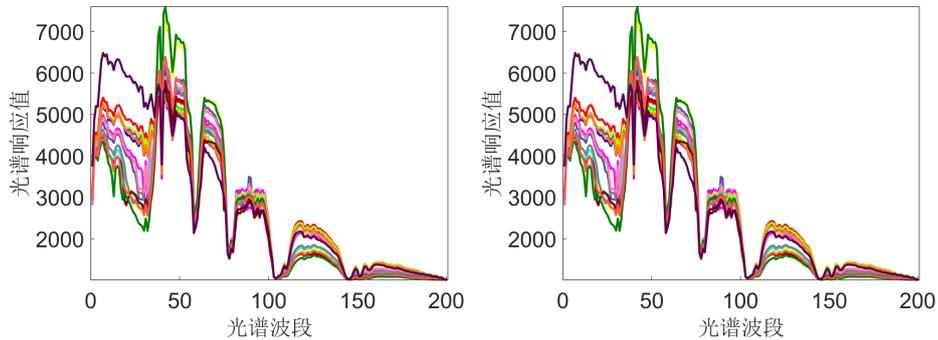


图 4-4 各个数据集的原始标记样本集与扩充后标记样本集的样本空间分布

Fig. 4-4 Labeled sample distribution of the initial training sample set and the enlarged sample set for each dataset

图 4-5、图 4-6 和图 4-7 则是显示了各数据集扩充后训练集和真值图对应的各类地物平均光谱响应曲线，从图中展示的结果可以看到，添加伪样本集对有限的标记样本集进行扩充后，不同类别的地物样本平均光谱响应曲线比较接近高光谱数据集原始真值图对应的各类地物平均光谱响应曲线。结合前面的实验结果分析可以说明，本章所提出的方法能够规避传统样本扩充方法集中于局部区域样本筛选的局限性，从相距较远的空间区域上克服异类地物样本光谱相似性的干扰，从大量的无标记样本中选取满足条件的高质量伪样本，减少异常样本点对构造有效伪样本集的影响，并通过捕捉同类样本间空谱信息表达中的内在关系，增加类内地物信息的多样性，避免过度地引入高度相似的重复同类样本信息对地物类别

区分的不利影响。

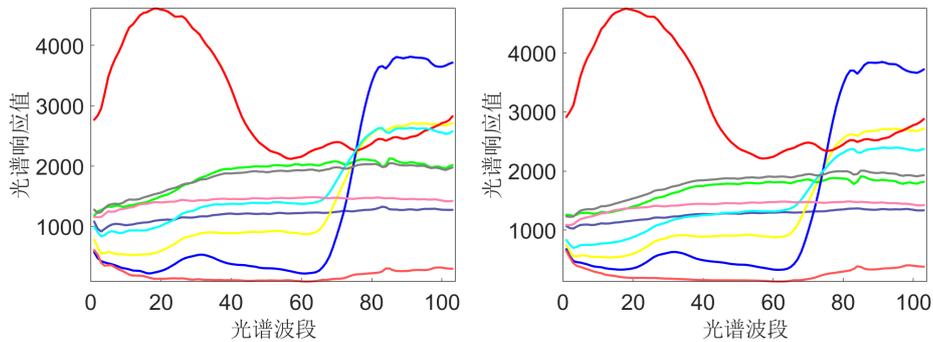


(a) 扩充后每类地物平均光谱响应曲线 (b)真值图中每类地物平均光谱响应曲线

图 4-5 印第安纳数据集中各类地物样本的均值光谱响应曲线

Fig. 4-5 Mean spectral response curves of different ground objects

in the labeled sample set after sample augmentation and the ground truth map of IP dataset

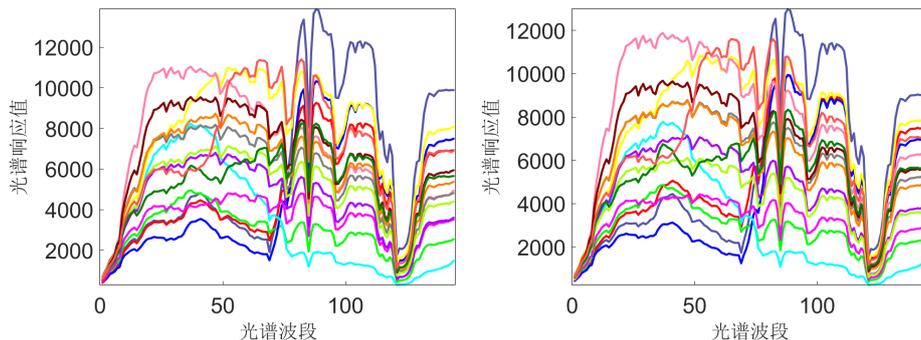


(a) 扩充后训练样本平均光谱响应曲线 (b)真值图对应各类样本平均光谱响应曲线

图 4-6 帕维亚大学数据集中各类地物样本的均值光谱响应曲线

Fig. 4-6 Mean spectral response curves of different ground objects

in the labeled sample set after sample augmentation and the ground truth map of PU dataset



(a) 扩充后训练样本平均光谱响应曲线 (b)真值图对应各类样本平均光谱响应曲线

图 4-7 休斯顿大学数据集中各类地物样本的均值光谱响应曲线

Fig. 4-7 Mean spectral response curves of different ground objects

in the labeled sample set after sample augmentation and the ground truth map of HU dataset

除此之外，本节对所提类别修正方案中的关键参数窗口尺寸进行了分析，在

不同数目的标记样本和不同尺寸的空间窗口条件下，所提方法在各个数据集上的总体分类精度 OA 如图 4-8 所示，从图中结果可以看出，OA 值随着窗口尺寸的增大整体上呈现先升高后降低的趋势。经上一阶段的样本扩充后，所提方法对剩余的无标记样本集执行类别修正方案，以每个无标记样本为局部空间窗口的中心，通过空间分布信息和边缘轮廓信息的联合，实现基于局部同质区域信息引导的中心样本类别修正。如果空间窗口的尺寸过小，很难覆盖到足够数量的局部同质样本，导致无法合理地预测当前区域主体的地物类别，反之，如果窗口的尺寸过大，可能会引入不相关的干扰样本，破坏对中心样本类别的准确预判。通过适当尺寸的空间窗口，可以揭示出局部同质区域内的主体语义信息，从而进一步提升小样本条件下的高光谱图像地物分类结果。

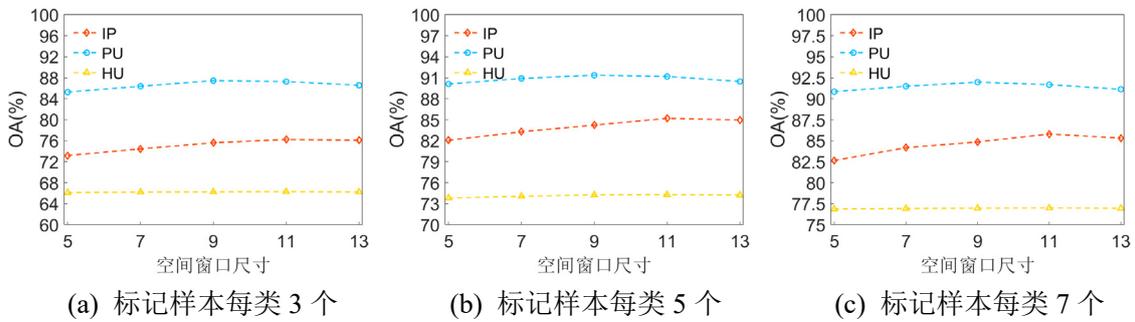


图 4-8 不同标记样本数目下窗口尺寸对各数据集分类精度的影响

Fig. 4-8 OA results as the change of window size with different number of labeled samples per class for each dataset

4.4.3 分类性能对比和分析

为进一步证明本章所提方法在高光谱小样本分类任务中的有效性，本节选择了近年来所提的方法进行地物分类性能的比较，包括基于不变属性轮廓空间特征 IAPs 的分类方法^[43]、3D CNN^[55]，以及面向小样本条件下的高光谱分类方法如基于超像素引导的样本扩充方法 SGTSE^[72]、基于自监督学习和知识蒸馏的分类方法 SSAD^[79]、基于深度少样本学习的分类方法 DFSL^[85]和基于跨域少样本学习的分类方法 DCFSL^[87]。此外，考虑到本章所提方法涉及到高光谱图像多类型空间信息的利用，在实验过程中额外增加了基于双重空间信息融合（Fusion of Dual Spatial Information, FDSI）的高光谱对比分类方法^[135]，该方法由预处理特征提取和后处理空间优化两部分组成，前者基于结构剖面空间特征得到地物的 SVM 分类结果，后者经扩展的随机游走得到基于空间优化的分类结果，最终通过决策级融合策略获得地物类别标签。根据实验数据的特性，不变属性特征提取方法 IAPs 中的核心参数卷积核数目和其在空间各向同性滤波的半径分别设置为 3 和 2，SGTSE 中超像

素分割数目为 500, SSAD 的初始学习率和权重衰减系数分别为 0.0001 和 0.00005, DCFSL 的训练轮数和学习率分别设置为 1000 和 0.01, 其余各参数与相应文献中的设置保持一致, 以满足对各数据集整体上的最优的解译效果。此外, 由于 DFSL 方法使用了 HU 数据集作为源域, 因此本节仅用 DFSL 对其他两组数据集进行分类性能的验证。对于本章所提的小样本分类方法, 各项参数的设置与前一节消融实验中所述保持一致。

第 1 组实验在印第安纳 IP 数据集上进行, 对于每一个类别, 从给定的标记样本集中每类随机选取 5 个标记样本作为训练集, 采用剩余样本作为测试集验证各个模型的分类精度, 各个方法的类内分类精度 CA、总体分类精度 OA 和 Kappa 系数等定量结果分别记录在表 4-3 中, 各对比方法相应的分类结果图、本章所提方法的初始分类结果图和最终分类结果图及真值图则在图 4-9 中进行显示。从表中所列的结果可以明显看出, 相较于其他方法, 本章所提出的方法获得了最高数值的总体分类精度 OA 和 Kappa 系数, 分别是 85.20% 和 0.8323。与 SGTSE、DFSL 和 DCFSL 等小样本分类方法相比, 本章所提的方法能够有效地区分光谱相似的地物, 如类别 2 (免耕玉米) 和类别 3 (少耕玉米), 且在绝大多数的地物类别上都表现出了良好的区分能力, 而其他方法对应的分类结果图则存在着较为显著的错分现象。

表 4-3 不同方法在印第安纳数据集上的分类结果 (%)

Table 4-3 Classification results (%) of each method on the IP dataset

类别编号	训练/测试集	3DCNN	IAPs	FDSI	SSAD	SGTSE	DFSL	DCFSL	本章方法
1	5/41	73.66	38.25	100	90.24	97.56	58.28	96.10	94.63
2	5/1423	35.05	61.95	71.65	43.98	58.90	58.98	30.24	84.12
3	5/825	19.71	45.03	71.50	65.55	71.71	55.68	36.51	70.08
4	5/232	28.19	35.92	83.39	81.12	90.95	29.75	68.10	94.57
5	5/478	45.98	76.32	92.23	72.89	80.50	96.91	68.66	81.59
6	5/725	54.79	97.70	96.71	95.59	93.05	99.26	88.96	97.54
7	5/23	84.35	34.14	43.79	100	96.52	30.96	95.65	86.96
8	5/473	84.02	98.77	99.46	98.18	100	99.91	74.16	99.92
9	5/15	98.67	10.25	78.37	100	100	10.08	98.67	98.67
10	5/967	45.07	48.10	72.71	82.63	80.21	49.82	59.96	86.33
11	5/2450	26.06	72.41	90.80	69.73	70.89	76.07	57.05	77.93
12	5/588	22.93	44.61	60.50	55.58	67.79	52.04	34.93	84.52
13	5/200	81.20	99.13	97.78	99.80	99.10	94.60	99.20	92.90
14	5/1260	58.43	93.63	92.99	96.29	94.38	95.81	81.16	92.65
15	5/381	9.92	66.91	82.04	61.94	93.70	62.66	56.27	94.70
16	5/88	76.14	91.47	77.27	100	94.32	87.00	97.50	80.45
OA	—	39.51	64.80	80.33	73.82	78.56	66.97	58.94	85.20
K	—	32.84	60.47	77.77	70.33	75.82	63.12	53.77	83.23

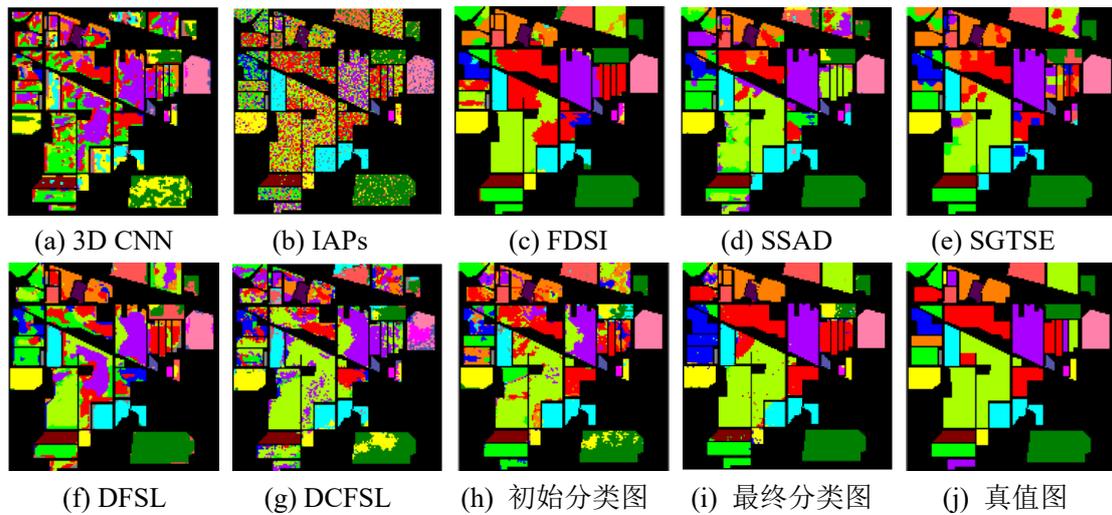


图 4-9 不同方法在印第安纳数据集上的分类结果图

Fig. 4-9 Overall classification maps obtained by different methods for IP dataset

在第 2 组实验中,对帕维亚大学 PU 数据集依据不同方法进行地物分类,表 4-4 详细地列出了各类别的训练样本和测试样本数量,以及不同方法所得到的总体分类精度 OA、每类地物的分类精度 CA 和 Kappa 系数,相应的各方法分类结果图、本章所提方法的初始分类结果图及最终分类结果图如图 4-10 所示。从展示的实验结果可以看到,所提方法展现出了明显优于其他方法的分类性能,得到了最优的地物分类结果。

表 4-4 不同方法在帕维亚大学数据集上的分类结果 (%)

Table 4-4 Classification results (%) of each method on the PU dataset

类别编号	训练/测试集	3D CNN	IAPs	FDSI	SSAD	SGTSE	DFSL	DCFSL	本章方法
1	5/6626	44.03	87.67	84.51	22.84	80.45	92.98	78.40	94.67
2	5/18644	59.06	96.93	92.40	81.47	82.44	96.35	73.11	91.10
3	5/2094	33.58	64.33	54.74	69.43	94.89	56.74	62.40	97.55
4	5/3059	77.80	83.79	79.34	92.87	75.63	75.90	90.02	64.95
5	5/1340	83.40	99.92	93.15	100	78.10	99.87	98.70	100
6	5/5024	34.65	44.88	84.80	16.41	97.67	49.63	72.08	98.30
7	5/1325	70.60	68.09	90.17	95.92	100	42.89	79.26	100
8	5/3677	66.96	58.29	80.77	39.40	84.10	59.28	48.76	95.49
9	5/942	98.15	93.86	84.47	98.32	44.78	99.08	99.56	59.58
OA	—	56.62	73.42	83.92	62.74	83.76	73.21	73.98	91.18
κ	—	46.58	67.16	78.78	51.99	79.25	66.74	66.85	88.47

相比第一组实验印第安纳 IP 数据集的农业场景,帕维亚大学 PU 数据集覆盖了城市基本土地区域,其包含着各种尺度、形状不尽相同的人造地物,还包含着空间结构较为复杂的地物类别,如类别 3 (砂砾)和类别 8 (砖石),更容易出现错分现象。从各方法的图像解译对比结果可以看出,SSAD、DFSL 和 DCFSL 等小

样本分类方法都存在着地物类别边缘破碎、同类地物错分的椒盐现象，而本章所提的方法综合地利用了高光谱图像中地物的多种类型信息表示，更加有效地捕捉类内地物样本间的紧密关系，构建出同类地物间的深层次关联，从而改善小样本条件下的地物分类结果。此外，本章所提的方法在内部结构比较精细的地物目标如类别3、类别5（金属板）和类别8上都取得了最高的类内分类精度，不同类别的地物边界也更加地清晰，且对光谱高度相似的地物类别如类别1（柏油路）和类别7（沥青屋顶）以及分布规模较大的地物如类别2（草地），本章所提出的方法也取得了较为理想的分类结果。

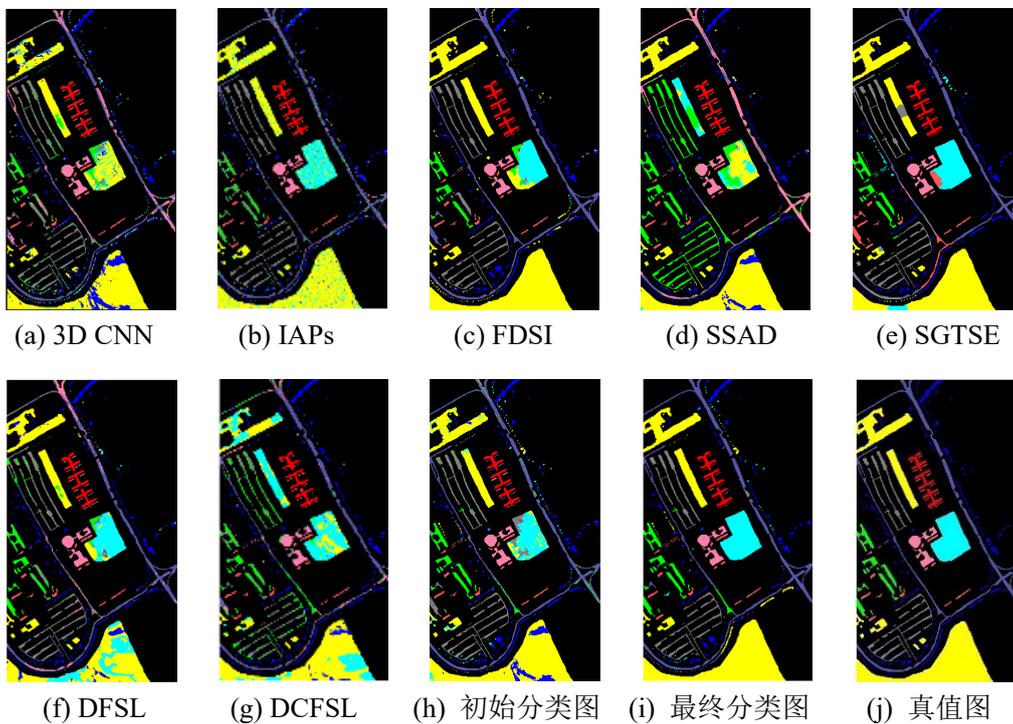


图 4-10 不同方法在帕维亚大学数据集上的分类结果图

Fig. 4-10 Overall classification maps obtained by different methods for PU dataset

第3组实验在休斯顿大学HU数据集上进行，该数据集拍摄于城市功能区用地，其空间结构较前两组数据更为复杂，且存在云层覆盖的阴影区域。训练和测试样本的数量以及各方法的总体分类精度OA、类内分类精度CA和Kappa系数列于表4-5中，相应的各方法分类结果图如图4-11所示。与小样本分类方法相比，提出的方法对光谱相似度高地物类别9（道路）和类别10（高速公路）都展现出了较好的区分度，类内的分类精度都明显优于其他方法。对于空间分布较广的地物目标如类别10和类别11（铁路），也取得了较为准确的解译结果。与前两组的实验结果类似，本章提出的方法在该数据集上也取得了最高的分类精度，分类结果图也展现出更加清晰、更加明确的类别边界，且通过比较三组实验中的初始

分类图和最终分类结果图可以看到，经由所提方法获得的高光谱地物分类结果图，错分情况明显减少，地物类别的区分度得到了显著提升，整体上证明了所提方法在高光谱小样本分类任务上的有效性和鲁棒性。此外，结合各组数据集上的实验结果可以看到，IAPs、FDSI 等方法通过深层次地挖掘地物的空间信息，缓解语义信息不足造成的地物类别预测不准确，表现出了与 SGTSE、DCFSL 等小样本分类方法相媲美的分类性能，这也从侧面表明空间信息的有效利用有助于提升类内地物的鉴别能力，而本章所提方法利用高光谱图像中多类型的空间信息揭示类内地物样本间的内在关联，因此在面向小样本分类任务时展现出更为理想的解译效果。

表 4-5 不同方法在休斯顿大学数据集上的分类结果 (%)

Table 4-5 Classification results (%) of each method on the HU dataset

类别编号	训练/测试集	3D CNN	IAPs	FDSI	SSAD	SGTSE	DCFSL	本章方法
1	5/1246	73.71	94.00	78.08	85.67	74.67	87.09	77.17
2	5/1249	68.04	85.47	60.03	84.63	54.44	87.58	71.32
3	5/692	71.59	98.41	99.91	99.28	100	95.14	99.86
4	5/1239	48.72	77.45	65.46	72.72	41.99	89.67	63.16
5	5/1237	99.50	90.82	95.69	100	90.74	95.47	95.04
6	5/320	61.25	96.19	89.56	82.34	91.25	82.75	84.81
7	5/1263	37.17	79.27	86.22	64.69	46.59	48.99	50.96
8	5/1239	45.76	54.27	56.85	42.78	40.15	41.39	36.93
9	5/1247	32.99	68.43	57.17	71.29	32.62	51.48	72.09
10	5/1222	21.19	52.82	63.95	34.25	85.50	61.49	85.42
11	5/1230	22.80	54.06	87.36	47.48	84.49	53.81	86.65
12	5/1228	40.26	59.06	80.32	39.09	51.03	63.11	61.87
13	5/464	39.22	37.33	69.60	50.00	84.31	78.06	84.27
14	5/423	79.24	93.87	93.43	99.76	100	74.89	100
15	5/655	95.73	93.74	96.65	100	100	91.39	99.82
OA	—	52.96	70.09	72.05	68.48	66.27	71.11	74.30
κ	—	49.31	67.74	69.80	66.05	63.74	68.81	72.26

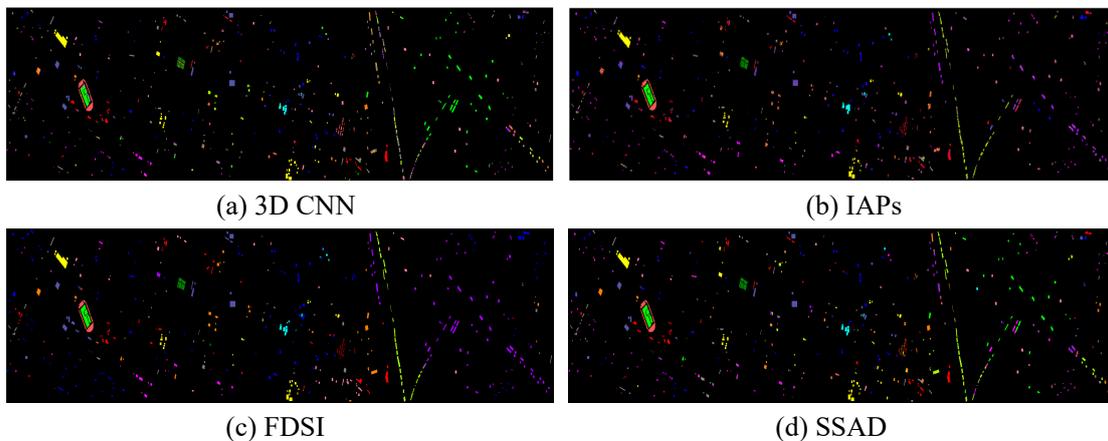


图 4-11 不同方法在休斯顿大学数据集上的分类结果图

Fig. 4-11 Overall classification maps obtained by different methods for HU dataset

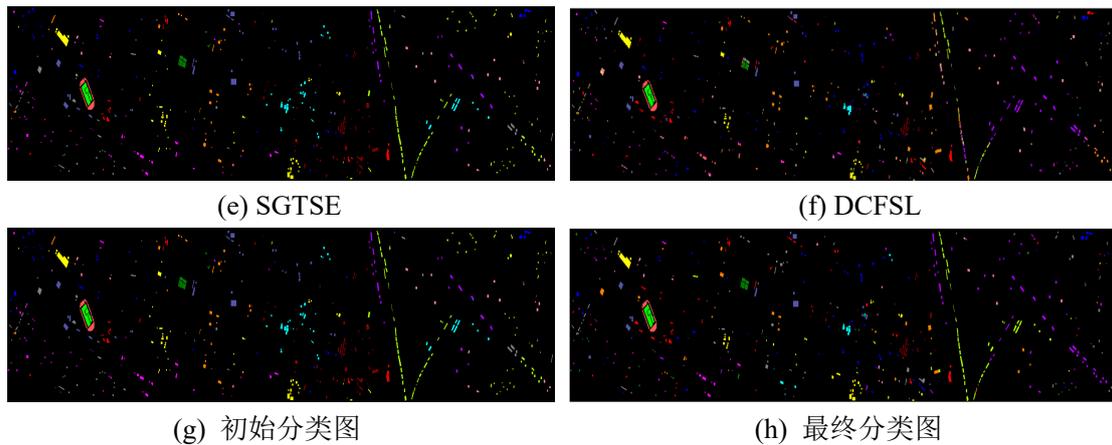


图 4-11 (续图)

4.4.4 国产高光谱图像小样本分类应用分析

为了进一步验证所提高光谱小样本分类方法的有效性，本小节选用两组国内高光谱图像数据进行地物分类应用分析，相应信息已在第2章中做了详细的介绍，此处不再赘述。对于各组高光谱数据集，每类随机抽取5个标记样本作为训练集，其他剩余样本作为测试集，本章所提方法中各项参数与前一节的参数设置保持一致。基于本章所提的样本扩充方案，两组数据集经扩充后的标记样本与原始标记样本空间分布示意图如图4-12所示，实验结果表明，所提方法通过半监督学习和可靠邻域结构对无标记样本进行筛选，能够选取出与真实类别标签一致的伪样本集，实现高质量的样本扩充，解决标记样本数目短缺的问题。

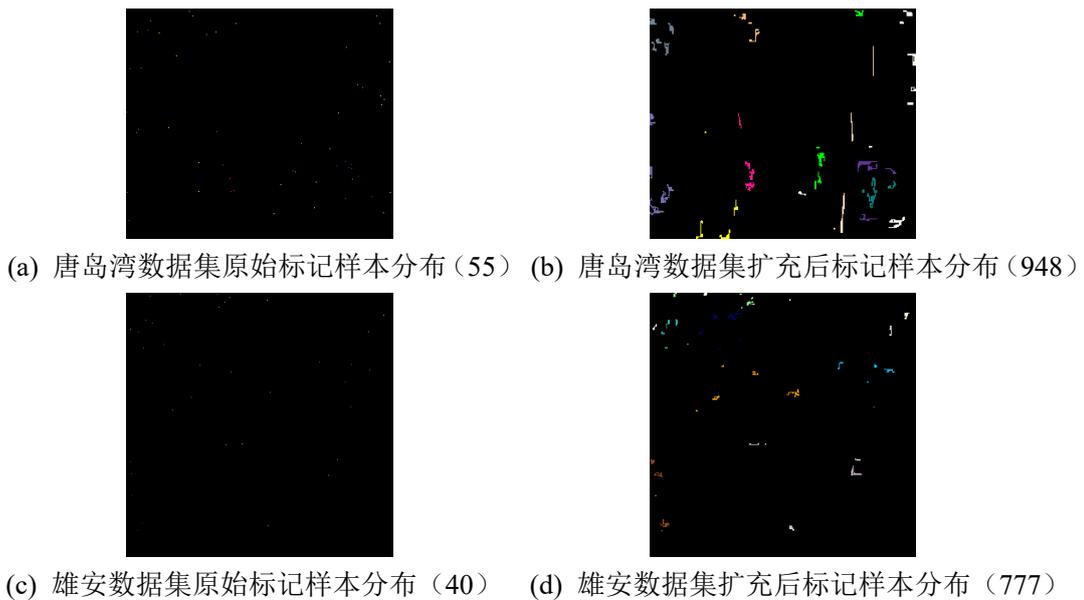


图 4-12 各国内高光谱数据集中标记样本分布示意图

Fig. 4-12 Labeled sample distribution in domestic hyperspectral image datasets

此外,本节选用在上一节高光谱小样本分类性能验证中表现较为优异的 FDSI、SSAD 和 DCFSL 作为对比方法,不同类型地物的类内分类精度 CA、总体分类精度 OA 和 Kappa 系数等分类指标结果如表 4-6 所示,两组数据集上各方法对应的分类结果图如图 4-13 和图 4-14 所示。从表中所列的结果可以看到,相较于前一章所提高光谱特征提取方法得到的初始结果,本章所提方法能够显著地提升小样本条件下的地物分类精度,对于不同真实区域场景中的地物识别效果得到了明显的改善。与其他两种小样本分类方法相比,本章所提方法在各组国内真实场景获取的高光谱数据集上都取得了最高的整体分类指标,特别是对于唐岛湾区域中空间分布较为广泛及不规则的地物类别 2 (石板路) 以及雄安区域中易混淆地物类别 1 (复叶槭)、类别 5 (杨树) 和类别 7 (草地) 等,都取得了最高的类内分类精度,从高光谱图像分类结果对比图中,同样可以看出本章所提方法错分情况更少。

表 4-6 小样本条件国产高光谱数据集上各方法的分类结果 (%)

Table 4-6 Classification results (%) obtained by different methods on domestic hyperspectral image datasets with small sample size

类别 编号	唐岛湾数据集					雄安数据集				
	FDSI	SSAD	DCFSL	初始 结果	最终 结果	FDSI	SSAD	DCFSL	初始 结果	最终 结果
1	100	99.31	99.36	58.16	99.97	95.17	98.47	98.37	95.81	100
2	78.56	93.57	67.36	61.65	99.90	88.29	34.98	65.02	66.61	87.25
3	98.74	99.00	97.50	85.90	99.74	92.78	53.31	49.15	53.39	69.25
4	99.84	96.55	90.02	76.99	99.92	51.69	69.84	81.51	75.06	99.75
5	69.20	95.74	99.63	87.73	100	48.42	98.37	61.40	83.91	99.64
6	97.93	91.75	98.53	99.56	100	52.77	59.85	47.10	35.87	37.23
7	92.70	91.19	83.75	57.07	61.79	81.54	86.78	68.72	79.66	89.08
8	98.19	69.48	99.03	51.63	95.42	99.93	99.74	97.42	92.95	98.71
9	89.82	56.56	70.67	68.89	99.56	—	—	—	—	—
10	94.36	80.43	89.67	30.28	38.98	—	—	—	—	—
11	100	99.13	98.72	53.17	99.91	—	—	—	—	—
OA	89.01	94.33	91.93	70.93	94.78	77.05	64.07	67.25	68.37	81.62
K	87.28	93.25	90.45	65.68	93.71	73.06	58.83	61.23	62.63	77.88



图 4-13 小样本条件下唐岛湾数据集各方法的分类结果图

Fig. 4-13 Classification maps by different methods with limited training samples for Tangdaowan



图 4-13 (续图)

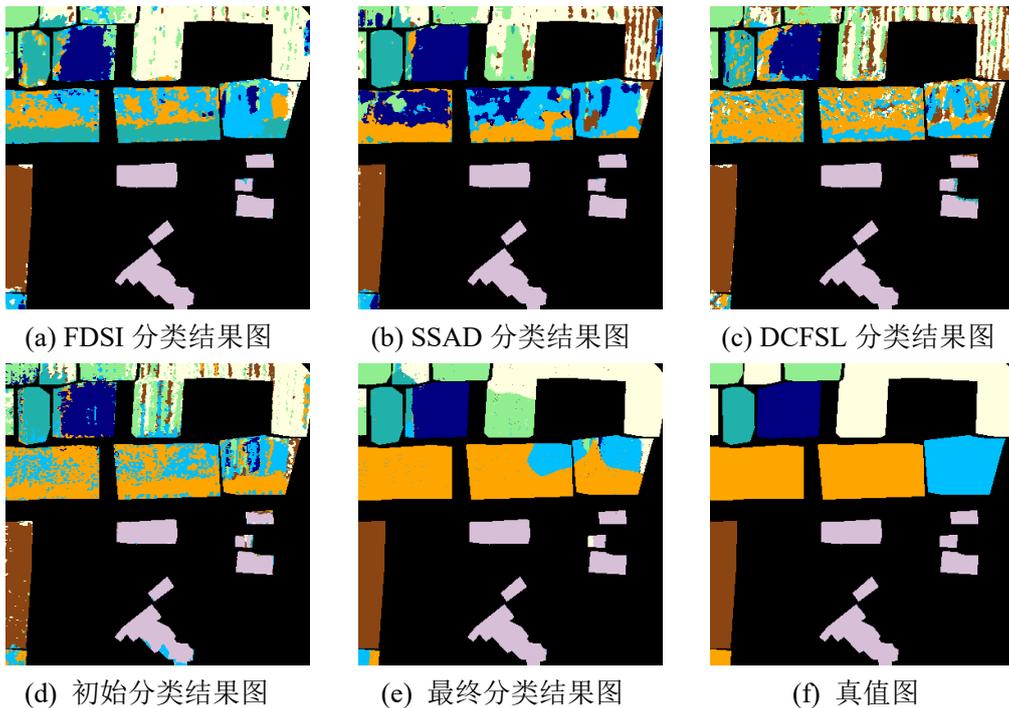


图 4-14 小样本条件下雄安数据集各方法的分类结果图

Fig. 4-14 Classification maps by different methods with limited training samples for Xiongan

4.5 本章小结

在实际应用中，高光谱图像分类任务往往面临着标记样本获取困难、语义信息稀缺导致的地物鉴别能力弱、图像解译效果差等问题，针对上述问题，本章研究了基于半监督学习和多类型信息融合的高光谱小样本分类方法，主要包括样本扩充和类别修正两个部分。具体来说，首先以第 3 章中基于高光谱图像空谱信息联合挖掘出的地物流形结构为基础，设计了基于半监督学习和可靠邻域结构的样本扩充策略，联合有限的语义信息和邻域结构体现出的语义信息一致性进行导向性的高质量伪样本筛选，实现原始标记样本集的有效扩充。然后，提出了一种基于局部同质区域语义信息引导的样本类别修正方案，在对不同类型空间信息进行

地物特性表示关联的基础上，通过整合局部空间中类内地物在多类型信息表示上展现出的相关性，实现目标样本的类别自适应修正，减少样本类别的判定错误，最终获取更加精细化的地物分类结果。实验结果表明，本章所提方法在不同成像条件获取到的国内外多组高光谱数据集上都表现出较为优异的类间地物区分能力，与近年来的小样分类方法相比，所提方法的分类结果图中错分情况较少，对空间分布、尺寸大小差异度较大的地物目标和易混淆的地物类型都展现出极富竞争力的分类性能。

第5章 基于高程信息辅助的高光谱图像分类

5.1 引言

高光谱图像是通过被动式的遥感光学系统采集到的三维立方体数据，虽然能够提供地表目标丰富的光谱信息和空间信息，但由于数据采集过程受外界因素影响较大，导致光谱信息存在较大的不确定性，而通过主动式采集方式获取到的 LiDAR 数据，受环境干扰度小，能够提供地物高程、结构及地表分布等信息，因此，相较于单一模态的高光谱图像分类任务而言，利用 LiDAR 数据辅助高光谱图像进行地物分类的优势不言而喻。目前，LiDAR 数据辅助下的高光谱分类方法大多采用特征级的多源异构信息融合方式，集中于提取地物更高阶、更抽象的特征，但忽视了多源数据在地物特点描述时自身表达出的特异性和多样性，没有深入剖析多源数据中地物的本质特性，缺少更加完善的地物特征表示。此外，不同层次上的多源数据融合优缺点日渐凸显，有效地平衡不同层次上的信息融合也将对后续地物类别的精确识别起到关键性的影响。针对上述情况，如何充分地利用高光谱和 LiDAR 数据中的互补性信息，构建学习能力更强、适用性更广泛的多模态数据融合模型是实现后续高光谱与 LiDAR 数据协同下高精度地物分类的基础。

考虑高光谱图像中不同视图下的信息表示在描述同一地物目标时展现出的多样性和差异性，本章将多视图学习^[136]思想应用到多源异构遥感数据的地物分类中，利用多模态数据信息表示的多样性挖掘出地物的多视图特征表示，提升不同类别间的地物鉴别能力，并结合不同层次上多模态信息融合的互补性，提高信息利用率的同时改善地物解译效果。具体的实现过程主要包含三个部分，首先利用不同模态数据中同一属性空间信息在反映地物特点时的一致性和不同属性空间信息在地物表达上的互补性和多样性，构建基于光谱信息、高程信息和多属性空间信息联合的多视图数据表示 (Multi-view Data Representation, MVDR)。然后，设计了针对上一阶段重表达后多源数据的特征级信息融合方式，构建出基于多分支双通道图卷积网络 (Multi-branch Dual-channel Graph Convolutional Networks, MB-DCGCNs) 的多视图特征提取模型，去除地物目标在多视图信息表示中的冗余信息，并提取出具有辨识度的地物多视图特征表示。随后，为了充分利用多视图特征的差异性和互补性，提出了一种渐进式高置信度的地物分类方法 (Progressively High-confidence Label Assignment, PHCLA)，引入决策级的信息融合策略整合不同视图下的地物分类结果，揭示出同一类型样本在不同视图特征表示下的潜在关联，并利用像素级的多源信息融合方案挖掘出地物语义信息与像素

样本表示之间的紧密关系，最终通过多视特征学习和多级信息融合（Multi-view Feature Learning and Multi-level Information Fusion, MVFL-MLIF）的方式，从整体上提升分类结果的可靠性和准确性。

5.2 图卷积网络模型

传统卷积神经网络CNN的感知区域往往是固定尺寸的局部卷积核视野，仅利用空间窗口对内部的中心像素和相邻像素进行加权计算，难以有效地整合空间上分布较远的像素样本信息，而且卷积操作局限于欧式空间，对于排列不规则的数据很难直接应用。以3D CNN模型为例，在处理高光谱图像数据时往往直接选取以像元样本为中心半径为 r 的正方形窗口邻域，以局部正方形邻域内的立方体数据作为输入，通过卷积层、池化层和全连接层实现地物的特征提取，其结构示意图如图 5-1 所示。其中，核心的卷积层部分是通过将输入数据不同维度上的二维卷积结果加和实现三维卷积操作，位于第 i 层的特征提取层，在第 j 个特征中位置为 (x,y,z) 的神经元连接值的公式可表示为：

$$v_{ij} = g \left(b_{ij} + \sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} w_{ijm}^{pqr} v_{(i-1)m}^{(x+p)(y+q)(z+r)} \right) \quad (5-1)$$

其中， R_i 为光谱维上卷积核的大小， w_{ijm}^{pqr} 代表次序为 m 特征中第 (p,q,r) 个神经元对应的权重。根据具体的学习任务设定相应的卷积层、池化层、激活层和全连接层等，最终可实现对高光谱数据的地物特征提取和类别判定。

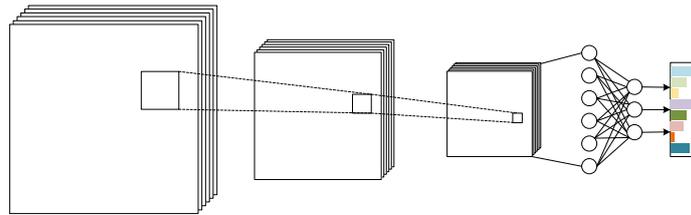


图 5-1 3D CNN 特征提取示意图

Fig. 5-1 Schematic diagram of feature extraction by 3D CNN

图神经网络（Graph Neural Networks, GNNs）的概念最初由Scarselli等人^[137]首次提出，意图在非欧式空间中进行节点之间的信息聚合和传播，实现具有复杂结构的数据处理和分析，一经问世便以其独特的性质被广泛应用于社交网络、生物医学、交通运输网络等领域^[138]。作为图神经网络中最为经典的模型图卷积网络GCN起源于图信号处理，引用了滤波器的概念定义图卷积操作，可以视作去除输入数据信号中的噪音，旨在对目标节点图结构中的近邻节点进行信息聚合，从而获得更高级的图特征表示。传统的卷积神经网络CNN依赖于固定尺寸的感受野进

行局部卷积核内节点运算操作，进而得到中心节点的局部特征信息，然后向后面更高级的特征提取模块进行传递并再次整合，而图卷积网络GCN则是依赖于图结构中的邻域结构并非图像空间中距离节点位置近的局部毗邻结构，且其近邻节点的数目可变，因而更适用于不规则分布数据的特征提取和表示。

按照卷积操作方式的区分，图卷积网络GCN可以分为空域图卷积和频域图卷积两类，前者主要是根据节点之间的空间关系定义卷积核，后者基于Fourier变换操作将空域上的输入信号及卷积操作转换到频域进行处理，解决了在图结构上难以直接进行卷积操作的问题，更适用于高光谱图像的处理，后续将详细地介绍频域图卷积的实现过程。Bruna等^[139]首次引用卷积核的概念定义频域图卷积操作，在此基础上，Kipf和Welling^[140]进一步提出了基于频域的半监督图卷积网络概念，并以分层逐级的传播规则实现了端到端的特征提取，其实现过程主要是利用简化的Chebyshev多项式逼近图卷积核，将频域卷积核定义为信号和滤波器函数的乘积项，通过滤波操作进行相邻节点的信息聚合，从而更新目标节点特征。对于具有图结构的数据而言，假设可由 $\mathbf{G} = \{\mathbf{V}, \mathbf{E}, \mathbf{A}\}$ 进行表示，其中 \mathbf{V} 表示节点集合， $|\mathbf{V}| = n$ 表示图上 n 节点数目， $\mathbf{A} \in \mathcal{R}^{n \times n}$ 表示邻接矩阵，在无向图中 \mathbf{A} 为对称矩阵，其元素表征了节点之间的相互连接关系。角矩阵 \mathbf{D} 的对角元素 $D_{ii} = \sum_j A_{ij}$ 代表第 i 个节点的度。相应地，图的拉普拉斯矩阵 \mathbf{L} 是一个对称半正定矩阵，可表示为：

$$\mathbf{L} = \mathbf{D} - \mathbf{A} \quad (5-2)$$

对应了 n 个线性无关的特征向量，从而构成了 n 维空间中标准的正交基，进一步可以获得归一化的实对称拉普拉斯矩阵的表示形式：

$$\mathbf{L}_{sym} = \mathbf{I} - \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \quad (5-3)$$

式中 \mathbf{I} 为单位矩阵，通过对归一化实对称拉普拉斯矩阵 \mathbf{L}_{sym} 进行特征分解，可以得到 $\mathbf{L}_{sym} = \mathbf{U} \mathbf{\Lambda} \mathbf{U}^{-1}$ ，其中 $\mathbf{U} = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n)$ 表示矩阵 \mathbf{L}_{sym} 对应 n 个相互正交的特征向量集合， $\mathbf{\Lambda}$ 为对角矩阵，其元素 λ_i 为对应特征向量 \mathbf{u}_i 的特征根。结合前文所述，在文献[140]中图傅里叶变换以正交矩阵 \mathbf{U} 中的特征向量作为基函数，通过对节点进行基于基函数的线性组合，将节点的频域卷积操作转换为基于基函数的处理和分分析，从而得到图卷积的一般形式可表示为：

$$\mathbf{g}_\theta * \mathbf{x} = \mathbf{U} \mathbf{g}_\theta \mathbf{U}^T \mathbf{x} \quad (5-4)$$

其中， \mathbf{x} 代表了图中的节点信号，滤波函数 \mathbf{g}_θ 可看作是图拉普拉斯矩阵的特征值函数，由待学习参数 θ 和图拉普拉斯矩阵对应特征值组成的对角矩阵 $\mathbf{\Lambda}$ 共同决定。

为了降低模型参数量和减少计算复杂度，上式可通过Chebyshev的 K 阶多项式 T_k 进行近似拟合，得到上式(5-4)的如下简化形式：

$$g_{\theta}(\Lambda) \approx \sum_{k=0}^K \theta'_k T_k(\bar{L}) \quad (5-5)$$

式中 $\bar{L} = \frac{2}{\lambda_{\max}} L_{sym} - I$ ， θ'_k 和 λ_{\max} 分别表示Chebyshev系数向量和 L_{sym} 的最大特征值。

通过将 K 取值设定为1，卷积层的公式可进一步简化为：

$$g_{\theta} * x \approx \theta \left(I + D^{-1/2} A D^{-1/2} \right) x \quad (5-6)$$

为了学习节点自身的信息和增强运算的稳定性，引入邻接矩阵和角矩阵自归一化项，即 $\bar{A} = A + I$ 和 $\bar{D}_{ii} = \sum_j \bar{A}_{ij}$ ，则图卷积网络GCN在第 l 层的卷积层公式可表示为：

$$H^{(l)} = \delta \left(\bar{D}^{-1/2} \bar{A} D^{-1/2} H^{(l-1)} W^{(l)} \right) \quad (5-7)$$

其中， δ 是激活函数项， $H^{(l)}$ 和 $H^{(l-1)}$ 表示第 l 层和第 $l-1$ 层的节点特征信息， $W^{(l)}$ 表示GCN网络中第 l 层可训练的权重参数，最终，目标节点通过不断聚合周围节点的特征信息进行自我特征表示的不断更新。基于图神经网络GCN的特征提取及分类结构示意图如图 5-2 所示，相比于CNN卷积网络结构，图卷积网络GCN更适用于非欧式距离空间中节点间拓扑关系的挖掘，通过聚合空间分布上近邻或相距较远的节点上下文信息，以图结构的形式实现节点间特征信息的传递、变换和聚合，能够有效地提取出节点长程的属性关联特征，而高光谱图像中地物样本间的关系往往呈现隐性且复杂等特点，同类地物样本很可能在图像上相距较远、空间分布也并非都是规则的形态，因此，图卷积网络模型更适用于捕捉高光谱图像中地物之间的细节性信息和隐含关联，进而提取出能够反映节点之间复杂关系的特征表示，改善图像解译效果^[141]。

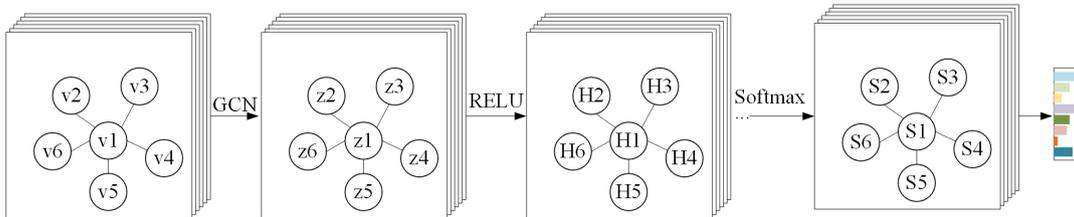


图 5-2 基于 GCN 结构的特征提取示意图

Fig. 5-2 Schematic diagram of feature extraction by GCN

5.3 基于高光谱与 LiDAR 多源数据融合的地物分类模型

5.3.1 整体模型框架

尽管高光谱图像蕴含着丰富的空谱信息，但其被动式的采集方式导致图像质量受外界因素影响大，加剧了地物“同物异谱”和“同谱异物”等情况，导致地物识别精度不高、分类结果椒盐现象严重，直接影响图像后续的应用分析。LiDAR 数据作为一种主动式激光脉冲获取的遥感数据，不受大气、光照等环境条件影响，能够获取观测区域全天时的高程信息，弥补了高光谱成像光谱仪在成像过程中将三维空间场景退化为二维空间影像时所丢失的高程信息。针对于同一目标观测区域，采集到的高光谱图像和 LiDAR 数据地物特点如图 5-3 所示，为了更加方便地显示在不同数据形式下地物的特点，这里引入空间坐标系作为辅助说明，从图中可以看到，对于空间分布接近且内在材质一致的不同类型地物目标如道路 (Road) 和商业区 (Commercial) 而言，虽然光谱响应曲线高度一致但在高程信息上呈现出明显的不同；而同一类型的地物目标如健康的草 (Healthy grass)，虽受云层遮挡等成像条件影响导致光谱响应曲线差异度较大，但具有十分接近的高程信息。因此，借助于 LiDAR 数据的辅助，不仅可以弥补高光谱图像缺失的高程信息，还能够提升高光谱分类模型面临光谱相似度高的异类地物和光谱差异度高的同类地物等情况时的地物区分能力，从而缓解光谱信息不确定性对图像解译效果的影响。

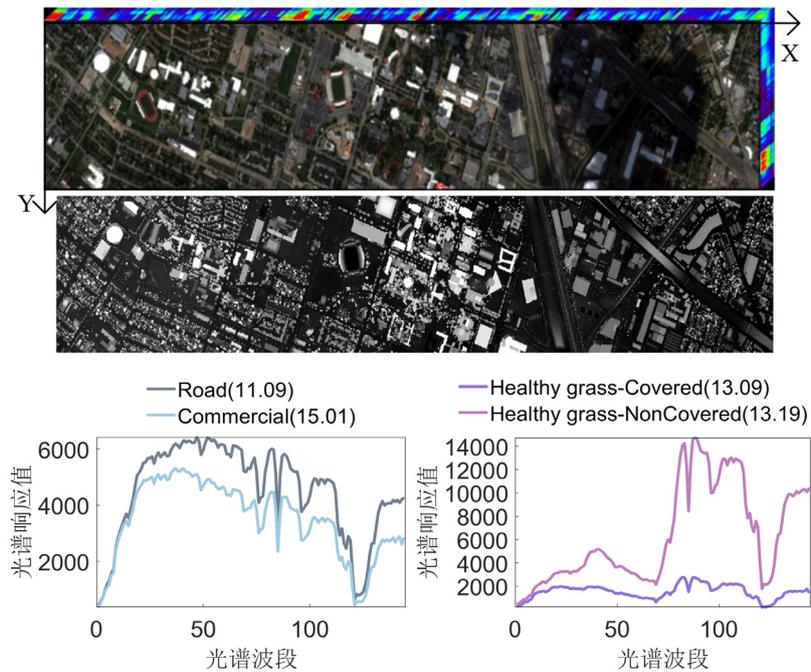


图 5-3 多源遥感数据中典型地物地光谱和高程信息表示

Fig. 5-3 Spectral-elevation information representations of typical landcovers in the multi-source data

随着地表成像背景越来越复杂，单一模态的遥感图像数据已无法满足地物高精度分类的要求，而高光谱和 LiDAR 数据能够以多模态的信息表征地表目标的不同特性，在地物属性表达上具有良好的合作性和互补性，因此被广泛应用于多源数据联合下的地物分类任务中。但现有的方法并未深入地构建地物在高光谱和 LiDAR 等多源数据表示中的内在相互关联，同时也存在着多源信息利用不充分等问题，导致高光谱和 LiDAR 数据联合下的地物特征判别性弱、分类精度低等问题。基于上述情况，本章提出了多视特征学习和多级信息融合框架下的高光谱与 LiDAR 数据协同分类方法，整体框图如图 5-4 所示，所提的地物分类模型主要包含三个部分，分别是基于多属性空间信息的多源数据重表达 MVDR、基于多分支双通道图卷积 MB-DCGCNs 的多视特征提取模型以及基于多级信息融合的渐进式高置信度地物分类模型 PHCLA，下面将对各部分进行详细的阐述。

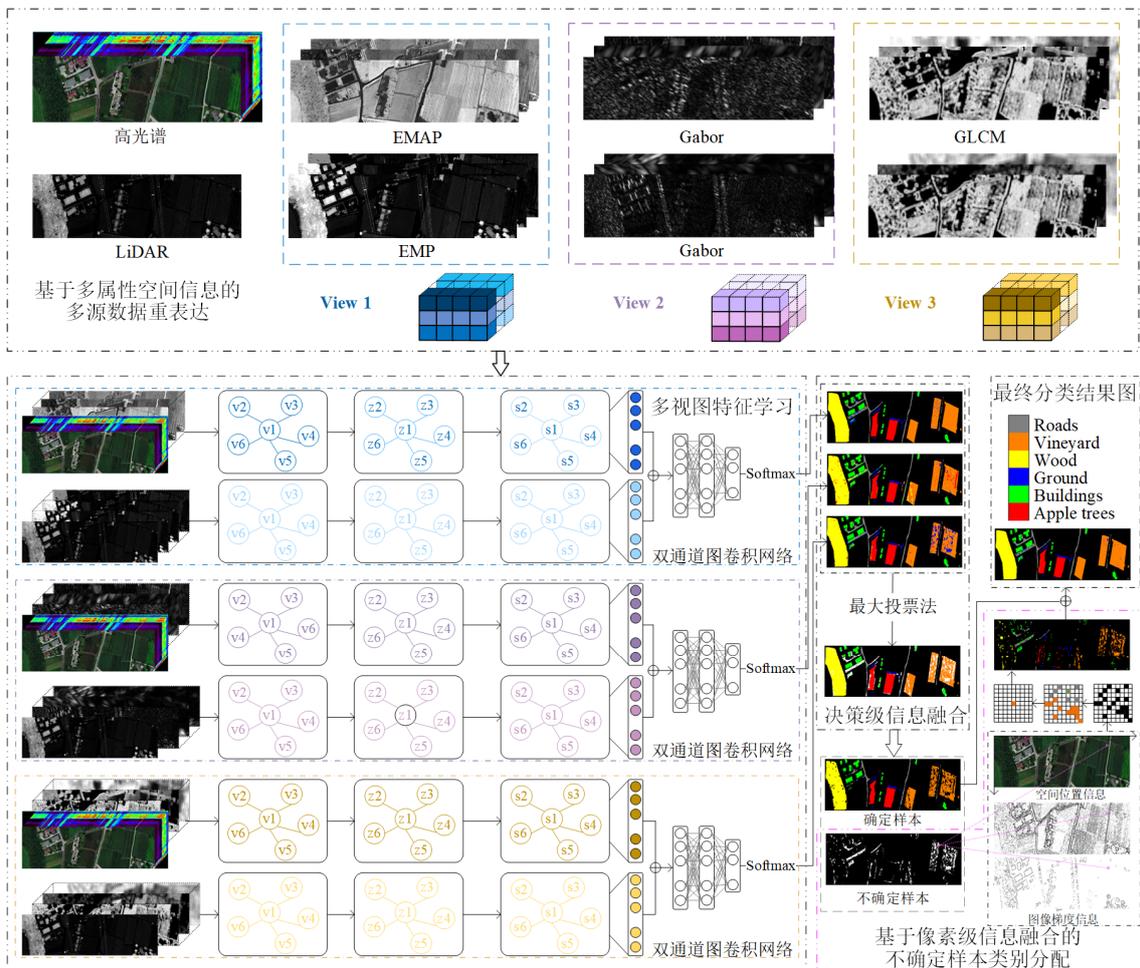


图 5-4 多视特征学习和多级信息融合框架下的高光谱与 LiDAR 协同分类示意图

Fig. 5-4 Overview of joint classification of hyperspectral and LiDAR data based on MVFL-MLIF

5.3.2 基于多属性空间信息的多源数据多视图重表达

对于多源遥感数据高光谱和 LiDAR 数据而言，除了基于采集原理获取的地物光谱和高程信息以外，还蕴含着多种不同类型的空间信息，下面以高光谱图像数据为例，对其包含的多样性地物信息表示进行阐述，如图 5-5 所示，对于每一个像元样本而言，在光谱维度上具有一维的光谱响应向量，能够反映地物样本物理结构、化学成分等内在信息，在二维图像中，不同类别地物的分布情况可通过地物样本的空间位置信息进行表达，此外，EMAP、Gabor 和 GLCM 等方法能够提取出地物的几何尺寸、形状方向和纹理结构等不同方面的空间特征^{[39][44]}，捕捉地物不同属性的空间信息，上述不同类型的信息从不同的视图描述同一个像元样本，能够构建出更为全面、更加完整的地物信息表示。基于此，本节采用上述三种不同类型的空间特征提取方法挖掘多源数据中地物的多属性空间信息表示，从而为后续多视互补性的多源地物信息表示奠定基础，其中扩展的多属性剖面特征 EMAP 提取过程已在第 3 章中详细介绍过，此处不再赘述，主要对后两种空间特征提取方法进行介绍。

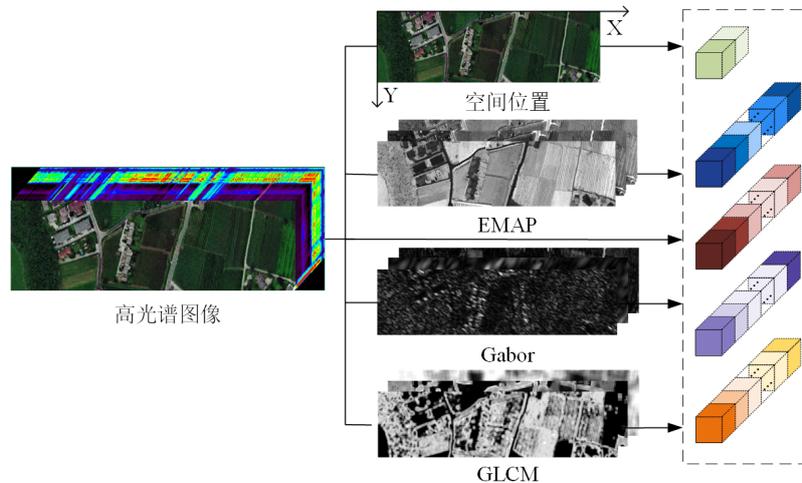


图 5-5 高光谱图像中地物样本的多视图信息示意图

Fig. 5-5 The diagrammatic sketch of each individual pixel featured by multiple information in the HSI

Gabor 滤波器的频率和方向表达同人类视觉系统类似，在二维的空间域中可表示为由正弦平面波调制的高斯核函数，通过引入窗函数进行高斯函数的短时傅里叶变换，Gabor 滤波器展现出了在空间域和频率域中较好的分辨能力，能够有效地从不同的方向、尺度等方面对局部特性进行描述，同时对图像中的边缘信息也有较高的敏感度。对于二维 Gabor 滤波器而言，其脉冲响应的对应 Fourier 变换是其调和函数的 Fourier 变换和高斯函数 Fourier 变换的卷积，计算公式可表示为：

$$\begin{aligned}
 g_{f,\theta}(x,y) &= \frac{1}{2\pi} \exp\left(-(\alpha^2 x^2 + \beta^2 y^2)\right) \exp(j2\pi\omega x') \\
 x' &= \left(x - \frac{m+1}{2}\right) \cos\theta + \left(y - \frac{n+1}{2}\right) \sin\theta \\
 y' &= \left(x - \frac{m+1}{2}\right) \sin\theta + \left(y - \frac{n+1}{2}\right) \cos\theta
 \end{aligned} \tag{5-8}$$

式中, f 表示正弦函数的频率, θ 表示高斯函数的方向角, (x, y) 是对应的空间变量, (m, n) 则是滤波器的尺寸, ω 是正弦波的频率参数, (α, β) 代表高斯函数锐化参数。从上式可以看到, Gabor 滤波器包含了多个变量参数, 由于多源遥感数据中地物尺度差异性大、内在结构复杂, 因此, 通过设定不同的参数取值, 构建出由多个滤波器组成的 Gabor 滤波器组, 能够有效地提取出高光谱和 LiDAR 数据中方向、尺度、空间纹理等更为丰富的空间特征表示。

灰度共生矩阵 GLCM 利用统计分析法研究图像灰度空间的相关特性, 进而描述出图像的纹理特征, 方法简单易于计算, 提取出的空间特征对尺寸差异性大的不同类型地物都具有一定的鲁棒性, 能够有效地反映图像地物内在的空间属性信息。例如, 在图像大小为 $H \times W$ 的灰度图像 f 上, 对于某一指定的像素在特定区域与其一定距离内的相邻像素间的灰度关系矩阵, 可以表示为像素对的联合分布概率, 即对于灰度值为 (i, j) 的像素对, 在偏移方向角为 φ 、相距为 d 的位置上出现的概率可以表示为:

$$P(i, j | \varphi, d) = \{(x, y), (x + \Delta x, y + \Delta y) \in H \times W | f(x, y) = i, f(x + \Delta x, y + \Delta y) = j\} \tag{5-9}$$

其中, (x, y) 为参考像元在图像中的位置坐标, Δx 和 Δy 为空间位置的偏移量, 由偏移方向角 φ 和偏离距离 d 共同确定, 利用两个位置上像素联合概率定义灰度共生矩阵, 从而反映出图像中的灰度值分布情况及相似像素对应的位置分布特性。在此基础上, 本章基于不同大小的空间窗口生成高光谱和 LiDAR 数据的灰度共生矩阵, 并进一步计算角二阶矩、熵、对比度、峰度、偏度、均匀性和逆差分矩阵等二次统计特征参数, 通过组合这七种特征参数来构建空间特征, 从而更好地适应复杂场景中地物尺寸的多变性。

高光谱和 LiDAR 多源数据内含丰富的地物多视表示信息, 如光谱信息、高程信息和不同类型的空间信息等, 这些信息从不同角度描述地物不同方面的特点, 为了更加完备地构建地物的信息表示, 本节在第 3 章的基础上, 利用多源数据中地物样本在特定属性空间信息下的内容表达一致性, 构建具有多样性和互补性的多视图多源地物重表达形式。假设原始的高光谱数据表示为

$\mathbf{H} = [\mathbf{H}^{tr}, \mathbf{H}^{te}] \in \mathfrak{R}^{d_{Spe} \times N}$ ，其中 d_{Spe} 表示相应的光谱波段数目， N 表示数据集包含的样本总体数目。相应地，由标记样本构建的训练集可以表示为 $\mathbf{H}^{tr} = \{\mathbf{h}_i^{tr}\}_{i=1}^{N_{tr}} \in \mathfrak{R}^{d_{Spe} \times N_{tr}}$ ，对应的类别标签为 $\mathbf{Y}^{tr} = \{y_i^{tr}\}_{i=1}^{N_{tr}} \in \mathfrak{R}^{C \times N_{tr}}$ ，每一个标记样本被标注为 1 到 C ，不同的数字编号对应不同的地物类别。作为辅助信息的 LiDAR 数据可表示为 $\mathbf{L} \in \mathfrak{R}^{d_{Ele} \times N}$ ，其中 d_{Ele} 表示相应的高程信息维度。假设 $\mathbf{X}^{Hm} \in \mathfrak{R}^{d_m^{Hspa} \times N}$ 和 $\mathbf{X}^{Lm} \in \mathfrak{R}^{d_m^{Lspa} \times N}$ 分别表示从高光谱和 LiDAR 多源数据中提取出的不同属性空间特征，其中视图序号与对应的空间属性如所提方法整体框架图 5-4 所示， d_m^{Hspa} 和 d_m^{Lspa} 分别代表高光谱图像和 LiDAR 数据在第 m^{th} ($m = 1, 2, 3$) 视图下的空间信息维度，则每个视图下基于光谱信息、高程信息和特定属性空间信息联合进行多源数据的重表达，其具体的重表达数据形式为：

$$\begin{aligned}
 \mathbf{R}_m^H &= [\mathbf{H}; \mathbf{X}^{Hm}] \in \mathfrak{R}^{d_m^H \times N} \\
 \mathbf{R}_m^L &= [\mathbf{L}; \mathbf{X}^{Lm}] \in \mathfrak{R}^{d_m^L \times N}
 \end{aligned} \tag{5-10}$$

式中， $d_m^H = d_{Spe} + d_m^{Hspa}$ 和 $d_m^L = d_{Ele} + d_m^{Lspa}$ 分别代表高光谱和 LiDAR 数据经重表达后第 m^{th} 视图中的数据维度。相比于原始的多源数据，重表达的多视图多源数据更加显性对地物的光谱、空间和 高程信息进行了表示，便于后续的特征提取模型对多源数据中多视信息的联合利用。整体而言，基于多属性空间信息重表达的多源多视图数据包含着更丰富、更完整的地物特性表达，各个视图之间既存在着共享的信息，如光谱、高程、空间位置信息和语义信息，也存在着特异性即具有不同属性的空间信息，这些不同属性的空间信息在描述地物特点时各自拥有不同的特色。后续，本章将设计多视图特征提取方法，消除重构后多视图多源遥感数据内在的冗余信息，深度地挖掘出地物在多源数据表达中的相互联系，从而提取出更具鉴别性的地物特征。

5.3.3 基于多分支双通道图卷积网络模型的地物多视图特征提取

近年来，深度学习算法在遥感图像分类领域的应用越来越广泛，通过自动提取出的高层次抽象语义特征实现地物类别的有效区分，然而现有基于深度学习的高光谱和 LiDAR 多源联合分类模型，大多集中于提取单一层面的地物特征，忽视了多源数据中地物信息多样性的挖掘，没有充分地协同利用多源数据蕴含的多视信息，不足以构建地物丰富的特征表示，存在着多源异构信息融合有效性亟待加强、地物本质特征挖掘困难以及高精度地物解译难以实现等问题。针对上述问题以及高光谱图像中样本之间的非欧式长程拓扑关系，本节使用图神经网络 GCN 作

为基础模块,利用GCN上节点之间传播的特征信息,结合可微的聚合和更新函数,隐式地传递并增强节点的特征表达。在此基础上,对于上一节中重表达后的多源多视图数据,为了保留每个视图各自原有的信息特点,本节首先设计了双通道图卷积网络模型(Dual-channel Graph Convolutional Networks, DCGCNs),用于同一视图下多源数据中同类地物的共性特征提取,然后构建了多分支双通道图神经网络模型MB-DCGCNs,从重表达后的多源多视图数据中学习到具有互补性和多样性的多视图地物特征表示。

对于高光谱图像数据而言, $\mathbf{G}_m^H = [\mathbf{V}_m^H, \mathbf{A}_m^H]$ 表示每一个视图下基于高光谱重构数据的图结构,其中 \mathbf{V}_m^H 表示节点的集合, \mathbf{A}_m^H 表示邻接矩阵,其元素 $\mathbf{A}_{ij,m}^H$ 表征了节点 $\mathbf{V}_{i,m}^H$ 和 $\mathbf{V}_{j,m}^H$ 之间的相互连接关系,可表示为

$$\mathbf{A}_{ij,m}^H = \exp\left(-\frac{\|\mathbf{x}_{i,m}^H - \mathbf{x}_{j,m}^H\|^2}{\sigma^2}\right) \quad (5-11)$$

其中 (i, j) 表示元素在邻接矩阵 \mathbf{A}_m^H 中的位置, m 代表相应的视图序列号, σ 用于控制径向基核数中的宽度。 $\mathbf{x}_{i,m}^H$ 和 $\mathbf{x}_{j,m}^H$ 分别代表节点 $\mathbf{v}_{i,m}^H$ 和 $\mathbf{v}_{j,m}^H$ 对应的第 m 视图下重表达后的地物空谱信息。 $\mathbf{v}_{i,m}^H$ 在第 l 层图卷积中的特征表示可由其近邻进行联合表达,具体的表示为

$$\hat{\mathbf{h}}_{i,m}^{H(l)} = \sum_{j,j \neq i} \hat{\mathbf{A}}_{ij,m}^H \hat{\mathbf{h}}_{j,m}^{H(l-1)} + \hat{\mathbf{h}}_{i,m}^{H(l-1)} \quad (5-12)$$

其中 $\hat{\mathbf{A}}_m^H = (\mathbf{D}_m^H)^{-1/2} \mathbf{A}_m^H (\mathbf{D}_m^H)^{1/2}$ 是归一化的邻接矩阵, $\mathbf{D}_m^H = \text{diag}(d_{1,m}^H, \dots, d_{N,m}^H)$ 是对角矩阵,其对角元素表示邻接矩阵 \mathbf{A}_m^H 相应第 i 行的元素总和。为了避免图卷积过程中出现梯度消失等情况,对 \mathbf{A}_m^H 和 \mathbf{D}_m^H 进行再次的归一化处理,利用 $\tilde{\mathbf{A}}_m^H = \mathbf{A}_m^H + \mathbf{I}$ 和 $\tilde{\mathbf{D}}_{ii,m}^H = \sum_j \tilde{\mathbf{A}}_{ij,m}^H$ 增强网络模型训练过程中的稳定性。相应地,在第 l 层的节点信息可表示为

$$\hat{\mathbf{H}}_m^{H(l)} = (\tilde{\mathbf{D}}_m^H)^{-1/2} \tilde{\mathbf{A}}_m^H (\tilde{\mathbf{D}}_m^H)^{1/2} \mathbf{H}_m^{H(l-1)} \quad (5-13)$$

后续结合非线性激活函数RELU,最终可得到第 l 层的输出特征表示

$$\begin{aligned} \tilde{\mathbf{H}}_m^{H(l)} &= \text{ReLU}\left(\hat{\mathbf{H}}_m^{H(l)} \mathbf{W}^{H(l)} + \mathbf{b}^{H(l)}\right) \\ &= \text{ReLU}\left((\tilde{\mathbf{D}}_m^H)^{-1/2} \tilde{\mathbf{A}}_m^H (\tilde{\mathbf{D}}_m^H)^{1/2} \mathbf{H}_m^{H(l-1)} \mathbf{W}^{H(l)} + \mathbf{b}^{H(l)}\right) \end{aligned} \quad (5-14)$$

相应地,同一视图下的LiDAR数据分支在第 l 层的特征可表示为

$$\begin{aligned}\tilde{\mathbf{H}}_m^{L(l)} &= \text{ReLU}\left(\hat{\mathbf{H}}_m^{L(l)}\mathbf{W}^{L(l)} + \mathbf{b}^{L(l)}\right) \\ &= \text{ReLU}\left((\tilde{\mathbf{D}}_m^L)^{-1/2}\tilde{\mathbf{A}}_m^L(\tilde{\mathbf{D}}_m^L)^{1/2}\mathbf{H}_m^{L(l-1)}\mathbf{W}^{L(l)} + \mathbf{b}^{L(l)}\right)\end{aligned}\quad (5-15)$$

以 l 层为最终图卷积层时, 将上述同一视图中两个通道上分别学习到的地物特征进行级联, 最终得到光谱、单一属性空间信息和高程信息协同利用下的地物单视图特征表示为

$$\tilde{\mathbf{H}}_m^{(l)} = \left[\tilde{\mathbf{H}}_m^{H(l)} \parallel \tilde{\mathbf{H}}_m^{L(l)} \right] \quad (5-16)$$

为了进一步剔除级联后特征中的冗余信息并进一步挖掘出地物的多源本征特征, 利用全连接层对级联后的空间-光谱-高程地物特征进行融合, 结合softmax分类器最终得到第 m 视图下多源地物的类别预测结果

$$\hat{\mathbf{Y}}_m = \text{softmax}\left\{f_{FC2}\left[f_{FC1}\left(\tilde{\mathbf{H}}_m^H \parallel \tilde{\mathbf{H}}_m^L\right)\right]\right\} \quad (5-17)$$

式中, $f_{FC}(\cdot)$ 和 \parallel 分别表示全连接操作和级联操作。在具体的模型训练过程中, 以特定的学习率和优化算法对多分支双通道图神经网络MB-DCGCNs模型中各个分支进行独立的训练, 对于各个分支网络中的参数由下式中的交叉熵损失确定

$$\mathcal{L}\left(\hat{\mathbf{Y}}_m^r, \mathbf{Y}^r\right) = -\sum_i \mathbf{Y}_i^r \log\left(\hat{\mathbf{Y}}_{i,m}^r\right) \quad (5-18)$$

其中 \mathbf{Y}^r 是已知的语义类别信息, $\hat{\mathbf{Y}}_{i,m}^r$ 则代表标记样本集中第 i 个样本对应的预测类别标签, 即第 m 个视图中经双通道图卷积DCGCNs模块预测得到的样本类别结果。本节所设计的DCGCNs模块能够从特定属性的空间信息、光谱和高程信息中挖掘特定视角下的多源地物鉴别性特征, 基于此构建出的MB-DCGCNs模型从多源多视图数据中提取出地物具有多样性和互补性的空间-光谱-高程特征, 从而提高地物特征表示的完整性和鲁棒性。考虑到每一个视图自身的特有性质和多视图间的互补和一致性信息, 由MB-DCGCNs模型获得的多视图地物分类结果将输送入到后续基于决策级和像素级信息融合的分类标签分配模型中, 生成最后统一的地物分类结果。

5.3.4 基于多级信息融合的渐进式高置信度地物分类

在上一阶段基于特征级的多源信息融合过程中, 多分支双通道图卷积网络模型 MB-DCGCNs 从重构的多源多视图数据表示中学习到了地物不同空间属性下的多样性多视图特征, 各个视图既有各自的独有特点也有共享信息, 考虑到不同视图的地物特征对于不同类别的地物分类贡献程度可能有所差异, 即不同视图下的地物特征对不同的语义类别区分度不同, 简单的跨视图特征级联不仅导致最终的鉴别性特征维度高且信息冗余, 还会破坏不同类别地物的显著性特征表示, 因此

在地物多视图特征提取之后，依据各分支模块独自训练产生各自完全独立的分类结果。为了综合地利用特定视图下的特有信息和不同视图间的互补信息，本节首先采用决策级的信息融合方式，利用最大投票法对各个视图分类结果进行整合，挖掘同类地物在不同视图下的共享信息，克服单一视图下地物特征表示的局限性和类别判定的不准确，提升整体地物分类的可靠性，这里对多分支分类结果完全一致的样本称为确定样本，而多分支分类结果不完全一致的其余样本称为不确定样本。然后，基于同类地物在毗邻空间区域上呈现出的语义一致性，对不确定的样本进行局部同质区域语义信息引导下的像素级类别分配，最终实现渐进式高置信度的多源地物分类。

假设原始高光谱数据中无标记样本集 $\mathbf{H}^{te} \in \mathfrak{R}^{d_{spe} \times N_{te}}$ 的单视图分类结果为 $\mathbf{Y}_m^{te} \in \mathfrak{R}^{N_{te} \times C}$ ，无标记样本 \mathbf{h}_i^{te} 在第 m 视图下的预测标签可表示为 $y_{i,m}^{te} \in \{1, C\}$ ，将多视图的地物预测标签结果基于最大投票法进行决策级整合，得到的无标记样本集分类结果可表示为：

$$\mathbf{Y}^{te} = \begin{cases} \mathbf{Y}_{i,1}^{te} & \text{if } \mathbf{Y}_{i,1}^{te} = \mathbf{Y}_{i,2}^{te} \text{ and } \mathbf{Y}_{i,2}^{te} = \mathbf{Y}_{i,3}^{te} \\ 0 & \text{else} \end{cases} \quad (5-19)$$

经过决策级的信息融合后，无标记样本可分为两类，一类是被赋予了类别标签的确定样本，该类样本在各个视图下的类别标签完全一致。另一类不确定样本在各视图下的类别标签并不统一，需要进一步地明确各个不确定样本的标签类别，相应的不确定样本集可表示为：

$$\mathbf{H}^{um} = \left\{ \mathbf{h}_i^{um} \right\}_{i=1}^{N_{um}} \in \mathfrak{R}^{d_{spe} \times N_{um}} \quad (N_{um} \ll N_{te}) \quad (5-20)$$

对于高光谱和 LiDAR 数据而言，基于梯度信息的地物边缘轮廓示意图如图 5-6 所示，对于高光谱图像中标注的橙色区域，由于云层覆盖导致光谱信息异常，无法构建清晰的地物边界，而 LiDAR 数据轮廓示意图中的红色区域，由于缺乏地物细节性的信息表示，不足以刻画出地物目标内部的精细结构。此外，在实际的场景中，同类地物往往在空间分布上呈现高度集中的态势，结合第 4 章中小样本分类条件下基于局部同质区域的地物类别修正方案，本节通过联合多源数据中地物的空间位置信息和梯度信息，为每一个不确定样本筛选出以其为中心的空间同质区域，利用同质区域的语义信息一致性进行引导，实现基于像素级多源信息融合的不确定样本地物类别判定。具体的实现过程，首先利用 Sobel 算子分别计算出高光谱数据的梯度信息 \mathbf{P} 和 LiDAR 数据的梯度信息 \mathbf{Q} ，用以表征多源数据中地物的边缘轮廓信息。然后，通过局部空间窗口划定不确定样本集中每一个样本 \mathbf{h}_i^{um} 的

空间毗邻空间，假设该样本的多源梯度信息和局部空间样本集可分别表示为 $[P^H; Q^H]$ 和 H^A ，则不确定样本 h_i^m 的同质样本集 H^H 可通过下式进行筛选

$$H^H = \bigcup_j h_j \text{ s.t. } (P_j^H = P_i \parallel Q_j^H = Q_i), h_j \in H^A \text{ and } h_j \notin H^m \quad (5-21)$$

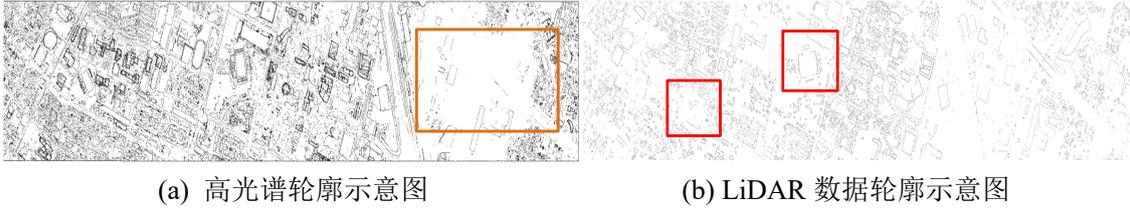


图 5-6 高光谱和 LiDAR 数据的轮廓信息示意图

Fig. 5-6 Overview of edge contour information in the hyperspectral and LiDAR data

同样采用第 4 章中局部同质区域主体语义信息的确定流程，假设同质样本集 H^H 包含了 v 个样本，对应的类别标签为 Y^H ，则同质样本集中不同类别的样本个数可通过下式进行统计

$$\left\{ N^H = (n_1^H, n_2^H, \dots, n_C^H) \mid n_c^H = \sum_{i=1}^v (Y_i^H = c), c = 1, 2, \dots, C \right\} \quad (5-22)$$

其中， n_c^H 代表同质样本集中隶属类别 c 的样本个数，则局部空间窗口内中心样本 h_i^m 的类别可通过下式进行确定

$$Y_i^m = c \text{ s.t. } n_c^H = \max(N^H) \text{ and } n_c^H > (v/2) \quad (5-23)$$

换言之，不确定样本 h_i^m 的类别标签可通过同质区域里最多预测的地物类别进行判定，最终实现多级信息融合下的多源地物高置信度分类。

5.4 实验结果及分析

5.4.1 实验数据与设置

为了验证所提多源分类方法的有效性，本章选择了两组内含高光谱和 LiDAR 数据的多源数据集进行实验论证，这两组多源数据经由不同的传感器采集于不同的区域，包含了丰富的地物类型，二者的相关具体信息已在 2.3 节中给出，这里不再进行赘述。此外，两组多源数据集还包含了标准训练-测试集，其在图像中的分布情况如图 5-7 所示，为了更加公平地比对各分类方法的有效性，本章使用各数据集提供的标准训练-测试集进行分类性能的验证。此外，本章所提的分类方法包含了多视图多源数据重构、多分支双通图卷积模型和渐进式高置信度的地物分类方案等三个主要部分，下面对其中涉及到的参数设置和模块结构进行逐一描述。

为了从多源数据中挖掘出不同类型空间特征信息，基于参考文献的调研分析和前两章的研究内容，对于本章涉及到的多属性空间特征提取方法，扩展的多属性剖面特征 EMAP 与第 3 章中的各项参数设置保持一致；Gabor 滤波器的主要参数波长和方向角取值范围分别设定为 $\{2,3,4,5,6,7,8,9\}$ 和 $\{30^\circ,60^\circ,90^\circ,120^\circ,150^\circ,180^\circ\}$ ；为了提取多尺度的空间信息，选用取值范围在 $\{5, 7, 9, 11, 13\}$ 内的不同尺寸空间窗口进行灰度共生矩阵 GLCM 的特征运算。经上述三种特征方法提取出的 LiDAR 数据多属性空间特征维度分别为 31、48 和 35，高光谱图像的多属性空间特征经由 PCA 提取后的前两个主成分运算得到，因而其特征维数是对应 LiDAR 数据同属性空间特征维数的二倍。双通道图卷积 DCGCNs 模块对重表达后的高光谱和 LiDAR 数据进行特定视图（特定空间属性信息）下的特征提取，每一个通道的前端 Block 包含一层图卷积层、批归一化层和 ReLU 激活层，后端 Block 包含两层全连接和一层 ReLU 激活层。在模型的具体训练过程中，双通道图卷积 DCGCNs 模块中的高光谱通道和 LiDAR 不进行参数共享，从而更好地保留不同模态数据自身的特点，多分支双通图卷积 MB-DCGCNs 模型中的各个分支独立地进行训练，从而对特定视图下特有的地物表示信息进行特征提取，保障多视图特征的多样性和互补性。

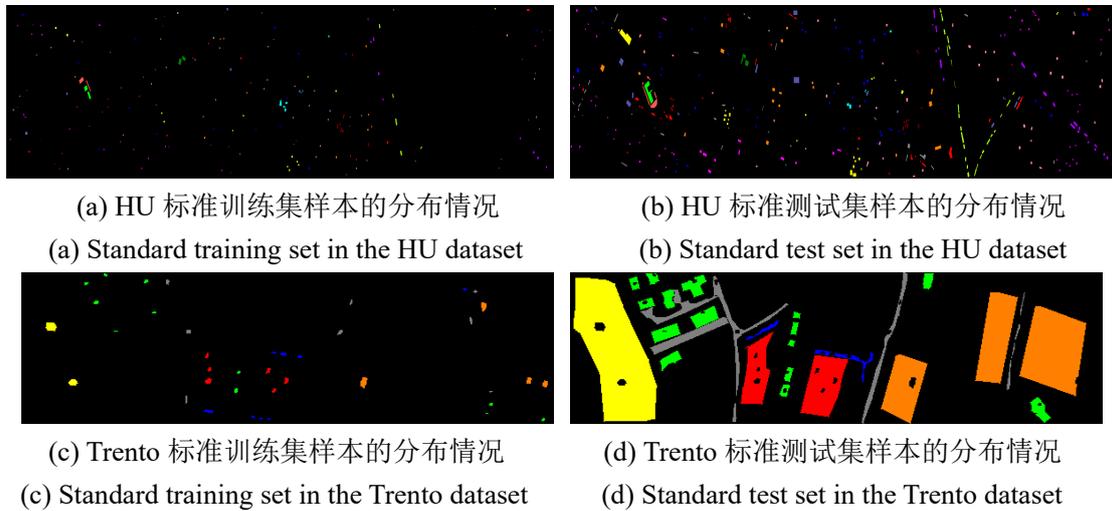


图 5-7 各个数据集中标准训练集和测试集的分布情况

Fig. 5-7 The sample distribution of standard training set and test set in different datasets

5.4.2 消融实验与模型分析

5.4.2.1. 消融实验

本章所提的分类方法包含了多视图多源数据重构 MVDR、多分支双通图卷积 MB-DCGCNs 模型和渐进式高置信度的地物分类 PHCLA 方案等三个主要部分，为

了证明各个部分的有效性，本节设计了一系列的消融实验，从而对整体分类框架中各个部分的作用进行合理性的验证。首先，考虑到传统方法大多使用单一属性的空间信息，本章所提的方法涉及到多源地物的多属性空间信息利用，因此，本节将对各属性空间信息进行基于 DCGCNs 模块的单一视图特征提取和分类，这里沿用前文定义的视图序号进行表示，序号 1、2 和 3 分别对应着不同属性的空间信息 EMAP、Gabor 和 GLCM。为了简化描述，依据图 5-4 中所提方法框架的视图编号顺序，以视图 1 代表基于 EMAP 空间信息的多源分类方法，以此类推。同时，为了更加充分地论证所提多视图特征提取方法的有效性，本节还增添了双视图特征提取对比方法，这类方法使用双分支双通道的图卷积模型进行特征提取，由各分支地物类别概率平均和的最大值来确定样本的最终类别标签。此外，本节去除了所提方法中的 PHCLA 地物类别分配方案，只保留多视特征提取模型 MVFL，用于验证所提方法中多级信息融合策略的有效性。

根据 GCN 相关文献的参数设置^{[44][58]}，对于所提方法中的多分支双通道图卷积 MB-DCGCNs 模型网络训练的最大迭代次数和学习率分别设定为 300 和 0.001，考虑到 HU 和 Trento 数据集原始光谱信息的维度差异以及 LiDAR 数据的多属性空间信息维度不同，对于 HU 和 Trento 数据集在每个分支的高光谱通道上，图卷积层和全连接层的输出特征维度分别设为 128 和 96，对于 LiDAR 数据在各个视图中的图卷积层输出维度依次设定为 16，32 和 32。在渐进式高置信度地物分类方案 PHCLA 中，像素级类别分配的窗口尺寸初设数值设定为 9。各对比方法的参数设置和训练模式与本章所提 MVFL-MLIF 多源分类方法保持一致，相应的地物分类结果如表 5-1 所示。

表 5-1 所提分类方法的消融实验结果

Table 5-1 Classification results of the proposed method for ablation experiments

数据集		单视图			双视图			多视图	
		视图 1	视图 2	视图 3	双视图 1,2	双视图 1,3	双视图 2,3	MVFL	MVFL-MLIF
HU	OA(%)	87.22	79.77	73.84	89.35	86.96	82.98	88.60	91.04
	κ	0.861	0.781	0.717	0.885	0.859	0.816	0.877	0.903
Trento	OA(%)	98.03	90.22	95.50	98.20	98.57	97.19	98.72	99.47
	κ	0.974	0.870	0.940	0.976	0.981	0.962	0.983	0.993

从表中所列结果可以看出，与单视图的分类方法相比，基于双视图、多视图的分类方案意图通过提取不同视图中的地物特征，缓解单一视图特征提取过程中信息利用不充分的问题，因而能获得更高的地物分类精度。但基于双视图或多视图特征提取的对比分类方法，并没有充分地考虑到特定视图下信息的独特性和不同视图中信息间的互补性，仅对各个分支的预测结果进行简单的结合，破坏了每

个视图下学习到的特有地物特征表示在类别判定时的独特性，因而总体分类精度并没有严格地呈现出随着视图信息的增加而上升的现象。本章所提的方法 MVFL-MLIF 在各项分类指标中都取得了最高的数值结果，分类性能明显优于其他对比方法，特别的是，与缺少渐进式高置信度地物分类方案 PHCLA 仅保留多视图特征提取模型的 MVFL 方法相比，通过添加不同级别的多源信息融合策略，所提方法的 OA 值平均提高了 2%。原因在于本章所提的方法考虑到多视图地物特征的互补性和多样性，利用决策级信息融合的方式挖掘出类内地物在多视图特征表示中的潜在关系，通过最大化投票法对多分支分类结果进行整合，后续结合像素级的信息融合方式进一步捕捉局部同质区域内样本之间的像元关系，从而展现出了明显高于单视图、双视图和多视图等特征级信息融合方案的地物识别能力，证明了所提多视特征学习与多级信息融合机制下的多源分类方法中各部分的有效性。

5.4.2.2. 模型参数分析

对于本章所提的多源地物分类方法，多视特征提取模型 MB-DCGCNs 中的特征维度和渐进式高置信度地物分类方案 PHCLA 中的窗口尺寸是影响地物分类准确度的两个关键参数，本小节将主要分析这两个参数对地物分类性能的影响，其余参数的设置与前一节保持一致。图 5-8 绘制了各数据集的总体分类精度 OA 在不同参数取值时的变化情况，特征的间隔基于 LiDAR 特征提取分支中最小的特征维度进行设定，取值为 16。

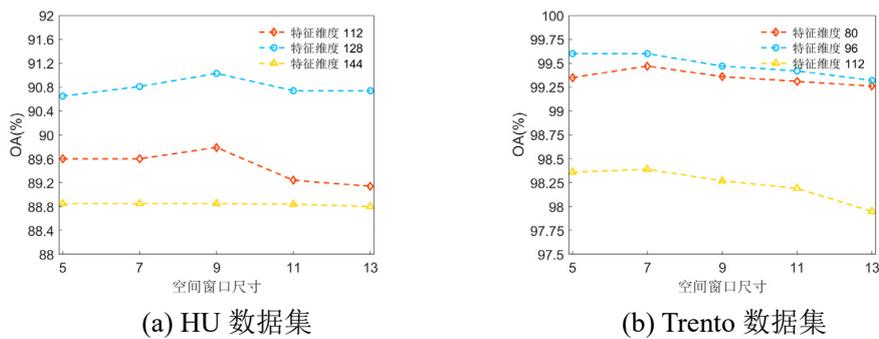


图 5-8 所提方法在不同窗口尺寸和特征维度条件下的分类结果

Fig. 5-8 OA results of the proposed method with varied number of feature and size of spatial window

从图中显示的结果可以看出，在指定大小的空间窗口条件下，OA 在适中的特征维度下取值最高，原因在于特征维度过高容易造成过拟合，特征维度过低无法充分地表示地物的鉴别性信息，而适中的特征维度可以学习到地物更具鲁棒性和鉴别性的多维特征，从而改善地物分类效果。类似于第 4 章中类别修正方案中窗口尺寸对分类结果的影响，OA 结果整体上也呈现出随着窗口尺寸的增大先上升后下降的趋势，其原因是当窗口的空间尺寸较小时，容易导致没有充足的局部上下

文信息用于预测不确定样本的标签类别，造成不确定样本即目标样本的类别预测不准确；随着窗口尺寸的逐渐增大，局部空间中的多源信息变得丰富，可以挑选出更多可靠的局部同质区域样本用以进行目标样本的类别判定。但当窗口尺寸过大时，破坏了空间区域同类样本的局部毗邻分布状态，极易引入其他类别但表征信息相似的干扰样本，导致分类精度下降。此外，与 HU 数据集的成像背景有所不同，Trento 数据集中地物目标主要呈现面状区域性分布，因而倾向于在小尺寸的窗口条件下取得最佳的分类结果。

5.4.3 分类性能对比实验

为了验证本章所提分类方法的有效性，本节选取了近年来基于单源高光谱图像、多源高光谱和 LiDAR 数据的代表性分类方法进行性能比较，这些方法涉及到多视特征学习、GCN 结构、多分支 CNN 结构和最新开发的深度学习模型，主要有基于多分支特征学习框架的 CNN-MFL^[56]，基于多视特征提取的 DMVL^[86]，基于双通道 CNN 特征提取和决策级融合的 EMCNN^[57]和 miniGCNs^[58]等高光谱分类方法，以及基于多视图特征和超像素引导决策融合的 MFSuDF^[116]，基于多级结构特征提取和稀疏低秩融合方法 MSE^[105]，基于编解码器和全连接网络结构的 FCNets^[106]，基于 CNN 多模态深度特征提取的 MDL-CNNs^[106]，基于耦合对抗学习和多级特征融合的 CALC^[118]，基于跨通道重建多模态特征提取的 CCR-Net^[111]，基于编码器解码器的深度融合网络 EndNet^[106]和基于 Transformer 网络模型的 GLT-Net^[110]等多源数据联合分类方法。在实验过程中，对于基于 GCN 结构的分类方法，近邻样本的数目设定为 5，此外，考虑到空间特征提取参数对分类结果的影响，为了更公平地进行分类性能的横向比对，对于包含有 AP 空间特征的对比方法，如 CNN-MFL，FCNets，MDL-CNNs 和 EndNet 等，纹理特征提取的参数设置参照本章所提方法中相应属性的取值范围进行设定，其余的各个对比方法都按照相应的文献和开源代码中描述的最佳实验参数进行运算。

第一组实验在 HU 多源数据集上以标准的训练集和测试集对所有方法进行性能验证，本章所提方法与各高光谱分类方法和多源分类方法的定量化分类结果分别列于表 5-2 和表 5-3，从表中结果可以看出，所提方法在 OA 和 Kappa 系数两项总体指标上均取得了最高的结果，整体上对不同类别的地物都展现出了较为均衡的鉴别能力。此外，基于 EMCNN 的高光谱分类方法采用了特征级和决策级结合的策略，基于 GLT-net 模型的多源分类方法利用近年来的 Transformer 深度模型挖掘多源数据中的全局和局部信息，二者展现出了明显高于其他地物分类方法的性能指标，而本章所提出的方法采用了像素级、特征级和决策级多级信息

融合的方式实现地物分类，更加充分地利用了多源遥感数据中的各类信息进行地物区分，因而获得了更胜于这两种方法的分类结果。

表 5-2 休斯顿大学数据集上不同高光谱方法与所提方法对应的分类结果 (%)

Table 5-2 Classification results (%) of
different HSI classification methods and the proposed method on the HU dataset

类别 编号	训练 样本	测试 样本	CNN-MFL	DMVL	EMCNN	mini GCNs	本章方法
1	198	1053	98.42	66.23	83.40	99.88	83.10
2	190	1064	96.96	53.52	90.74	99.23	85.15
3	192	505	100	88.17	88.58	99.23	100
4	188	1056	95.05	62.16	90.98	99.09	100
5	186	1056	96.31	87.00	94.65	99.15	100
6	182	143	18.29	54.33	100	12.74	100
7	196	1072	64.77	69.55	95.34	64.67	96.64
8	191	1053	71.55	45.50	97.72	80.20	80.25
9	193	1059	80.76	74.62	79.47	79.23	92.73
10	191	1036	85.36	65.33	91.60	74.97	68.53
11	181	1054	80.12	96.36	97.57	85.75	91.37
12	192	1041	75.07	61.36	90.01	86.33	100
13	184	285	94.18	87.12	94.98	71.23	92.98
14	181	247	86.36	98.39	100	99.09	100
15	187	473	99.78	60.76	83.37	97.28	100
OA	—	—	81.22	68.84	90.89	80.07	91.04
K	—	—	79.70	66.19	90.11	78.47	90.29

表 5-3 休斯顿大学数据集上各多源分类方法的分类结果 (%)

Table 5-3 Classification results (%) obtained by each classification methods for multi-source data on the HU dataset

类别 编号	MFSuDF	MSE	FCNets	MDL-CNNs	CALC	CCR-Net	EndNet	GLT-Net	本章方法
1	85.24	80.65	98.87	99.77	97.75	99.66	81.58	100	83.10
2	83.96	96.14	97.91	99.01	99.67	100	83.65	100	85.15
3	41.58	68.61	84.73	98.63	31.26	65.10	100	48.35	100
4	85.29	99.30	98.87	100	98.6	99.90	93.09	97.70	100
5	69.04	96.61	97.21	99.90	100	99.90	99.91	100	100
6	30.68	17.28	22.61	17.23	90.79	19.06	95.10	40.06	100
7	86.02	70.31	72.60	67.68	90.65	77.19	82.65	86.79	96.64
8	76.26	88.06	89.55	93.39	94.30	93.46	81.29	88.52	80.25
9	83.01	68.44	95.08	90.42	98.08	89.53	88.29	92.96	92.73
10	97.39	75.75	98.71	91.98	97.96	92.63	89.00	96.47	68.53
11	86.10	87.60	88.62	94.64	93.72	97.46	83.78	99.88	91.37
12	81.48	68.25	75.92	93.36	88.87	91.37	90.39	85.08	100
13	87.84	96.32	84.94	88.61	95.17	93.02	82.46	98.48	92.98
14	99.2	80.72	95.37	95.63	100	98.31	100	100	100
15	97.21	99.37	99.57	100	93.48	99.15	98.10	94.04	100
OA	77.52	78.84	86.72	87.59	87.69	86.95	88.52	89.03	91.04
K	79.43	77.11	85.62	86.58	86.68	85.87	87.59	88.13	90.29

图 5-9 则展示了各个方法的地物分类结果图和容易混淆的地物类别 7 (住宅区) 和类别 9 (道路) 的局部解译放大图，从呈现的分类图可以看出，虽然不同类别的地物在空间分布上差异性较大，但本章所提出的方法能够获取更为平滑的分类结果，错分样本数目更少。结合定量化的对比分类结果可以表明，本章所提的

方法能够有效地融合高光谱和 LiDAR 数据中的多源异构信息，提取更具鉴别力的地物特征，从而提升不同类别地物的区分能力，改善高光谱图像的地物解译效果。

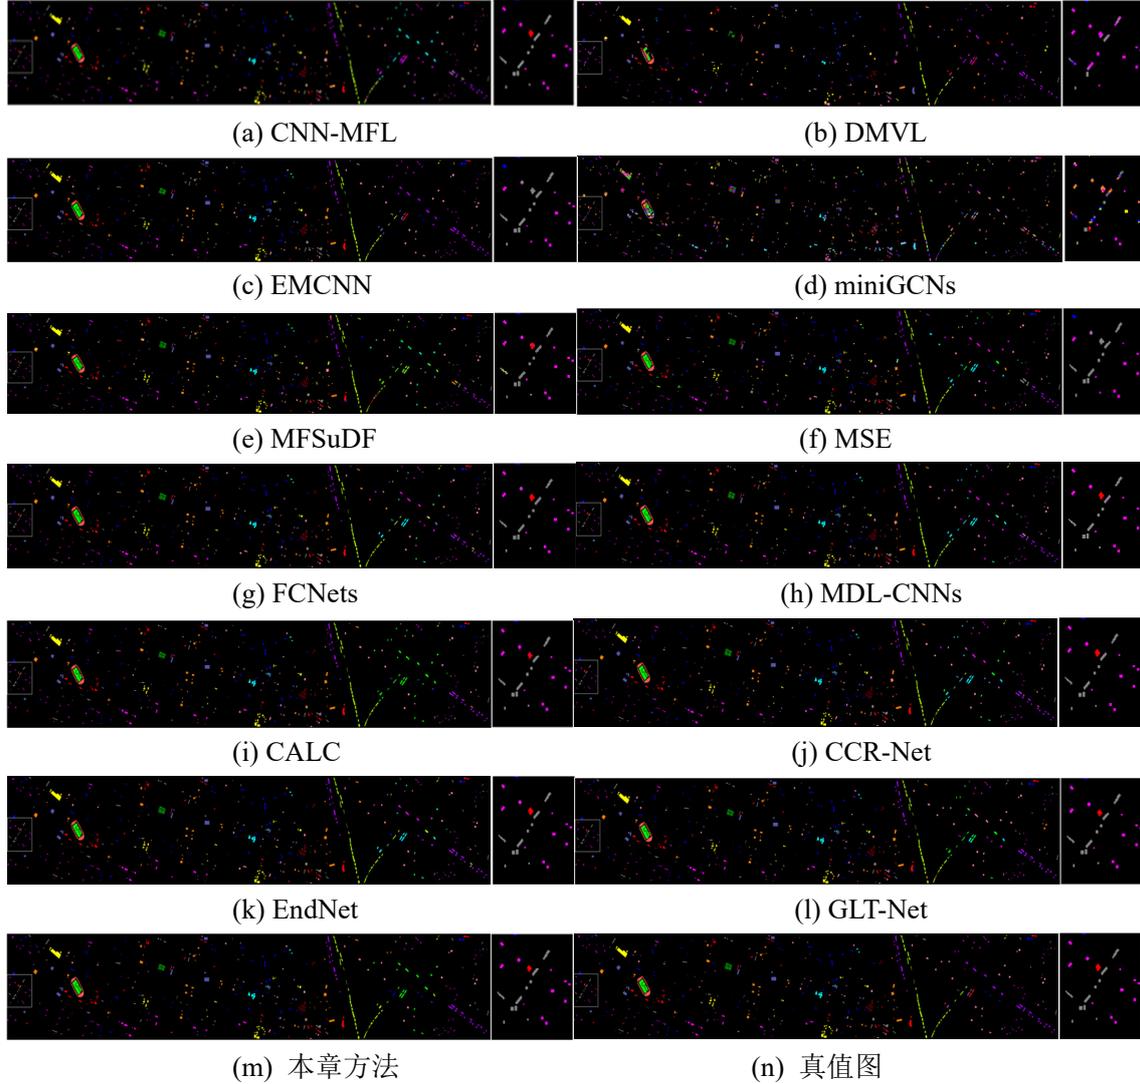


图 5-9 各个方法在休斯顿大学数据集上的分类结果对比图

Fig. 5-9 Classification maps of overall region and local region in the HU dataset obtained by different methods for visual comparison

第二组实验在 Trento 多源数据集上进行各方法分类性能的验证，同样使用了数据集自带的标准训练集和测试集，与高光谱单源分类方法的对比结果如表 5-4 所示，表 5-5 则列出了各多源分类方法获取的量化分类结果。从表中所示结果可以看出，与基于多视特征提取的高光谱分类方法如 CNN-MFL 和 EMCNN 相比，本章所提方法将总体分类精度分别提升了 6.4%和 3.7%，明显高于其他对比方法。此外，与基于深度学习模型的多源分类方法相比，本章所提方法获得了最高的总体分类精度，显现出了极富竞争力的分类性能。图 5-10 则展示了不同方法的地物

分类结果图以及易混淆的异类地物类别 2（建筑物）和类别 6（道路）的局部区域分类放大图，这两类地物的光谱相似度较高，很容易发生错分现象。从图中结果可以看出单源高光谱分类方法分类结果图中存在较为明显的类内错分现象，而多源对比分类方法添加了垂向的高程信息，对地物类别的预测准确度有所提升，在局部放大图中能够看到更为清晰的地物类别边界。此外，大部分多源分类方法在进行地物分类时没有充分地考虑到不同模态数据中包含的地物多属性信息，信息融合的有效性不高，因而在类别 1（苹果树）和类别 6（葡萄园）的地物区分上表现不佳。而本章所提出的方法通过多视图特征提取和多级信息融合实现地物类别的判定，能够有效地减少错分样本，结合整体的地物分类图可以看到不同类别的地物边界更为清晰、空间连续性更加显著，图像解译的效果得到了明显的改善。

表 5-4 特兰托数据集上不同高光谱方法与所提方法对应的分类结果（%）

Table 5-4 Classification results (%) of different HSI classification methods and the proposed method on the Trento dataset

类别编号	训练样本	测试样本	CNN-MFL	DMVL	EMCNN	mini GCNs	本章方法
1	129	3905	80.13	32.42	100	96.35	100
2	125	2778	87.53	44.38	73.30	77.92	100
3	105	374	42.91	7.98	73.62	77.60	87.43
4	154	8969	99.58	100	99.99	98.48	100
5	184	10317	99.33	88.04	98.74	99.69	100
6	122	3525	93.28	70.20	98.91	87.52	96.43
OA	—	—	93.03	60.43	95.76	95.18	99.47
\mathcal{K}	—	—	90.73	51.16	94.32	93.54	99.29

表 5-5 特兰托数据集上各多源分类方法的分类结果（%）

Table 5-5 Classification results (%) obtained by each classification methods for multi-source data on the Trento dataset

类别编号	MFSuDF	MSE	FCNets	MDL-CNNs	CALC	CCR-Net	EndNet	GLT-Net	本章方法
1	89.28	99.49	86.05	91.3	99.74	88.51	85.01	99.69	100
2	95.16	96.9	95.82	90.20	91.15	91.93	95.62	95.73	100
3	85.20	100	65.13	60.83	87.41	70.49	67.65	95.24	87.43
4	99.98	100	99.91	100	100	100	99.92	99.98	100
5	98.67	99.49	97.54	100	99.69	99.92	97.44	100	100
6	96.81	98.00	97.93	99.68	95.28	98.41	97.93	98.49	96.43
OA	97.04	99.25	95.85	97.04	98.35	96.81	95.68	99.32	99.47
\mathcal{K}	96.05	99.00	94.46	96.05	97.79	95.75	94.23	99.09	99.29

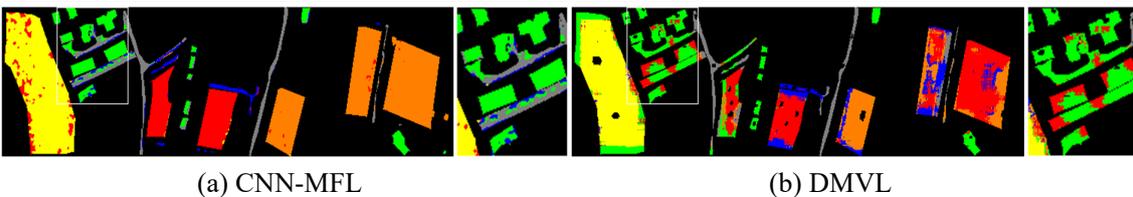


图 5-10 各个方法在特兰托数据集的分类结果对比图

Fig. 5-10 Classification maps of overall region and local region in the Trento dataset obtained by different methods for visual comparison

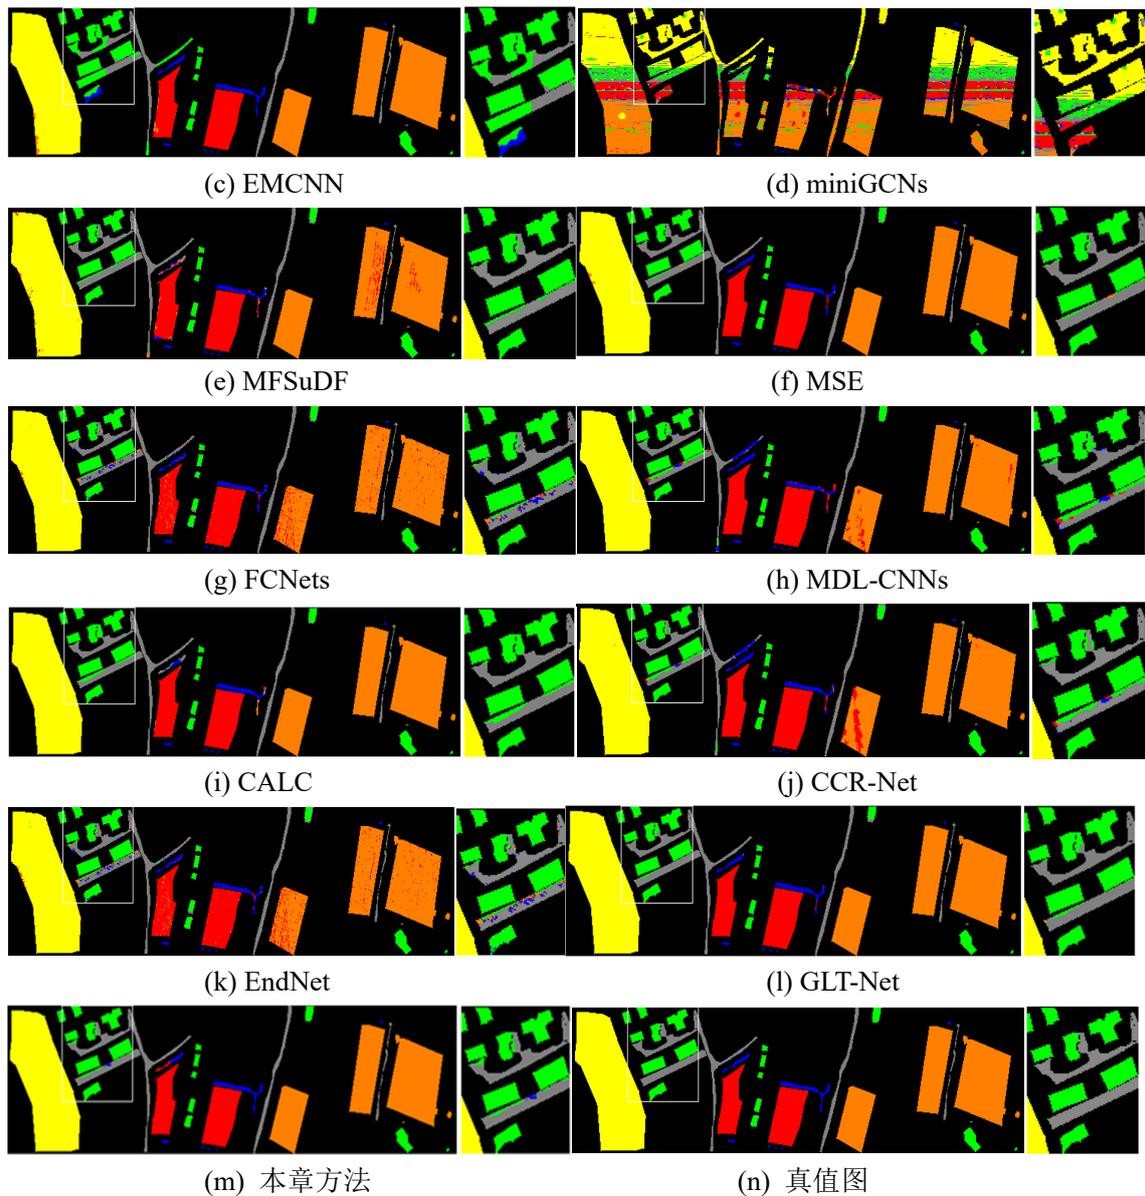


图 5-10 (续图)

5.5 基于高光谱图像的地物分类与分析软件设计

根据中央引导地方科技发展专项—寒地水稻生产智能化技术示范项目的技术内容需求，项目组利用 Visual C++ (Java) 及 Python 等进行了算法设计与软件集成。为了满足不同应用背景下地物类别自动化和智能化区分的需求，论文根据第 3 章、第 4 章和第 5 章面向不同条件的高光谱分类方法研究，设计并搭建了基于 Windows 平台的高光谱地物分类与分析软件，拓展论文所提高光谱分类方法在实际应用中的便携性和可操作性，并为地物类型的区分和分析提供技术支撑。此外，所设计的软件系统便于调整、易于集成，能够协同其他子系统构建更为灵活、功

能更加完善的软件应用系统，以满足整体项目的技术要求。

5.5.1 软件整体框架

本节采用自顶向下、逐级细化的结构化软件设计思想，设计基于高光谱分类技术的地物识别软件，扩展论文所提高光谱分类方法的实用性和便捷性，软件整体系统主要包括用户管理、文件操作、基础工具和地物分类识别四个主要模块，各模块操作界面和软件的整体结构分别如图 5-11 和图 5-12 所示。其中用户管理主要用于账户注册、管理和登录等；文件操作模块是高光谱地物分类与分析软件的基础，通过高光谱图像数据、异源遥感数据和标记样本数据等辅助数据的读取，供后续其他功能模块调用，并内置了输出显示单元和数据文件存储单元；基础工具模块包括高光谱数据特点分析、典型特征提取方法和相关数据的存储单元；地物分类识别模块主要包含半监督分类、小样本分类和多源融合分类等三个子模块，每个子模块包含着可供选择的具体的地物分类方法，用于按照指定的条件实现地物分类，并内置了结果可视化和存储单元。



图 5-11 软件主功能模块界面

Fig. 5-11 The interface of main functional module

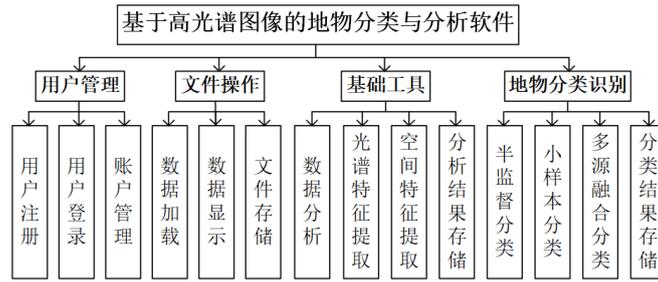
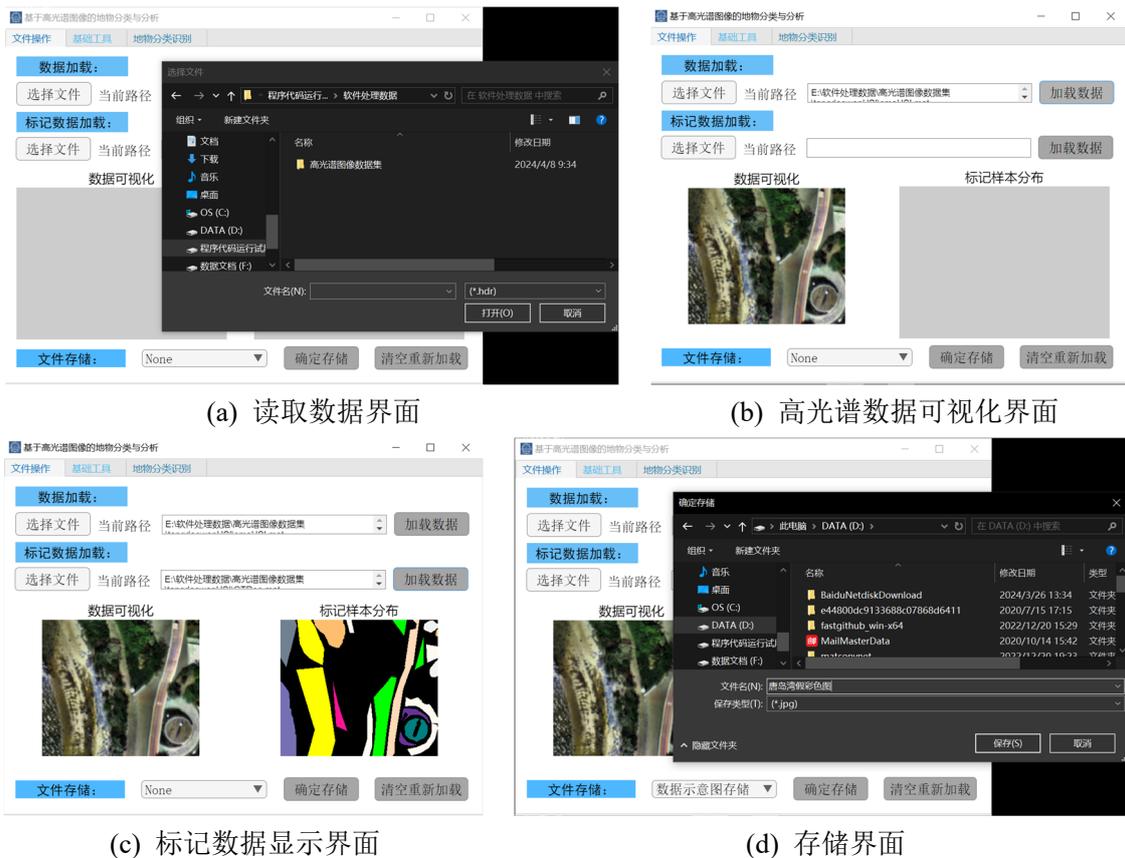


图 5-12 所设计软件中的主要功能模块示意图

Fig. 5-12 The schematic diagram of main function modules in the designed software

5.5.2 文件操作功能模块

文件操作模块用于从选择的文件路径中读取待处理的高光谱图像数据和其他辅助数据，点击“加载数据”可对读取数据进行显示，并支持不同格式(*.hdr, *.tif, *.jpg, *.png 等)和不同精度(int, uint, float, double 等)的数据读取、显示和存储等操作。例如，读取唐岛湾高光谱图像和标记样本数据的操作界面如图 5-13 所示，利用“文件存储”功能可以按照指定的格式和路径存储数据及其可视化显示图。



(a) 读取数据界面

(b) 高光谱数据可视化界面

(c) 标记数据显示界面

(d) 存储界面

图 5-13 文件操作功能界面

Fig. 5-13 Interface display of the document operation module

5.5.3 基础工具功能模块

基础工具模块可以用于对文件操作模块读取到的高光谱图像数据进行预先分析，结合已经加载的地物类型信息，能够计算不同类型地物的光谱响应曲线和分析当前数据地物的特点，并通过可视化的形式进行结果展示。此外，该模块还内置了典型的特征提取方法如 PCA、NPE、EMAP、Gabor 和 GLCM 等，用于数据的光谱特征或空间特征提取，通过存储单元可实现数据特征和数据特点可视化分析结果的存储。具体的操作界面如图 5-14 所示，对于文件操作模块加载的唐岛湾高光谱数据，选择“光谱曲线”，点击“地物信息分析”，显示不同类型地物的光谱响应曲线，选择“地物类别信息”，能够以文本形式显示当前数据集标注的地物类别信息；选择“EMAP”空间特征提取方法，点击“执行特征提取方法”，界面显示所提特征可视化示意图，结合“文件存储”单元，能够实现特征数据或可视化示意图的存储功能。

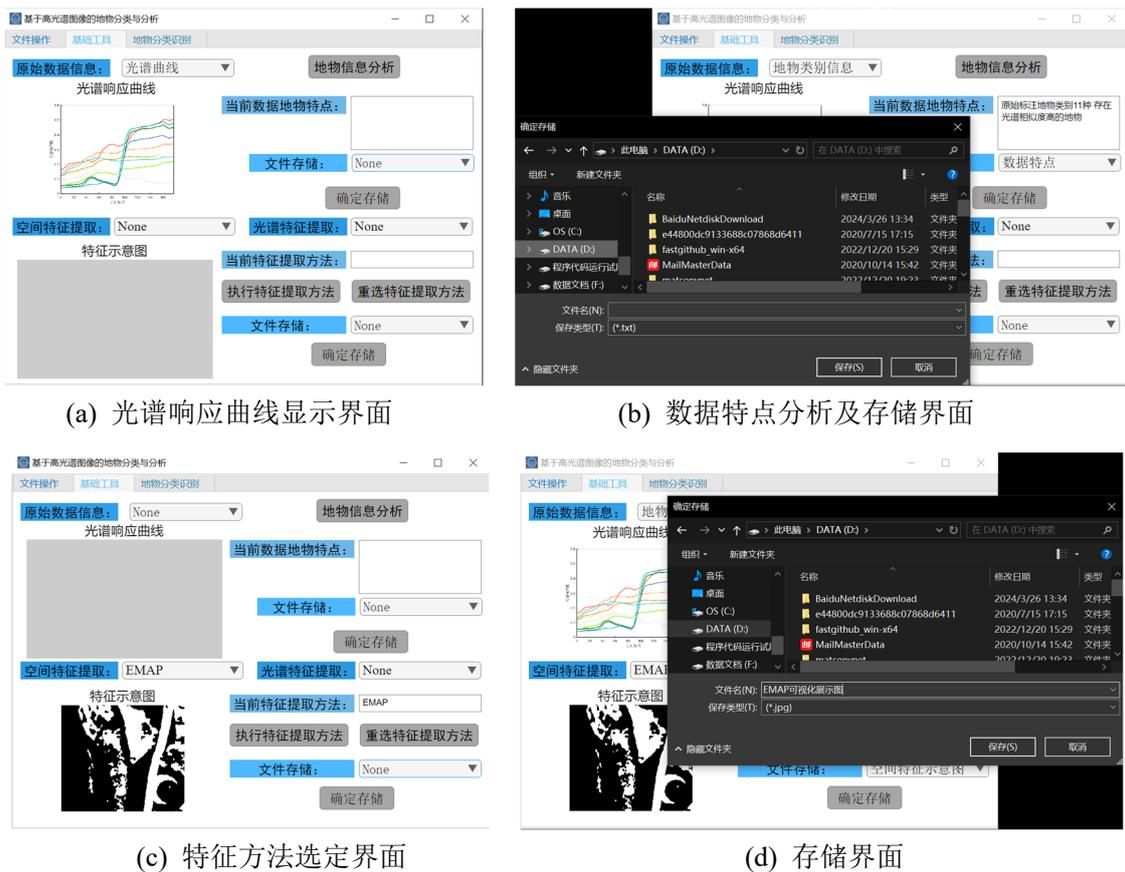


图 5-14 基础工具功能界面

Fig. 5-14 Interface display of the fundamental tool module

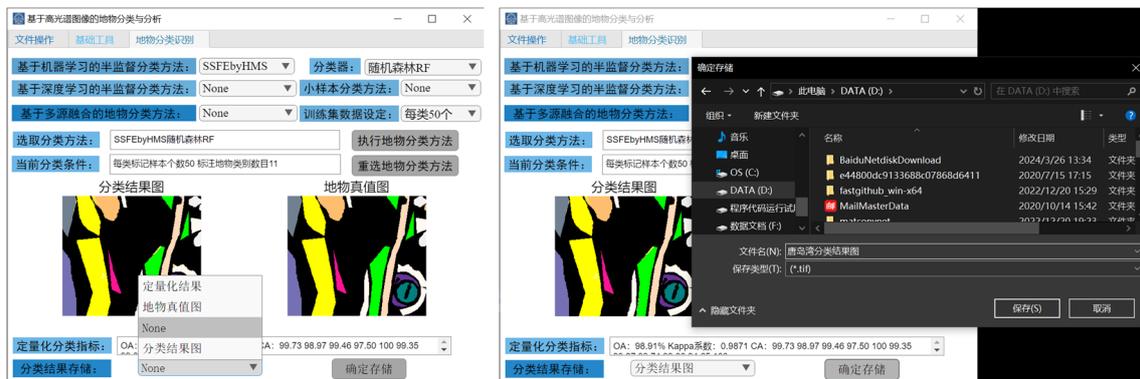
5.5.4 地物分类识别功能模块

地物分类识别模块用于按照指定的分类方法和已加载的地物类别信息实现高光谱图像的地物类型区分和识别,其中半监督分类方法包括 RMLR、SPaCR、IAPs、3D CNN 和论文第 3 章所提方法等选项,小样本分类方法包括 SGTSE、SSAD 和第 4 章所提方法等选项,多源融合地物分类方法包括 MFSuDF、MSE 和第 5 章所提方法等选项,分类器可从 NN、RF 和 SVM 中进行选择,按照不同的起始条件选择加载标准训练集或是对已有标注地物进行随机抽取构建训练集,点击“执行地物分类方法”后,地物分类运算后的结果将以可视化的定量化分类结果和分类结果图进行显示,根据存储单元的选取模式可以对相应的分类结果进行存储。例如,选用论文第 3 章所提的高光谱特征提取方法和随机森林 RF 分类器,选定每类 50 个标记样本作为训练集的条件下,对文件操作模块读取到的高光谱数据进行地物分类,根据具体的需求可将可视化的分类结果图和定量化的分类指标按照指定的路径进行存储,具体的操作界面如图 5-15 所示,所设计的功能模块满足项目的技术要求,并在实际的工程应用中展现出了一定的可操作性和适用性。



(a) 分类条件选定界面

(b) 地物分类结果显示界面



(c) 存储信息选择界面

(d) 结果存储界面

图 5-15 地物分类识别模块界面

Fig. 5-15 Interface display of land cover classification and identification

5.6 本章小结

本章面向单一信源高光谱图像分类任务中地物信息表示的局限性，以第 3 章和第 4 章的研究内容为基础提出了一种基于高程信息辅助的高光谱分类方法，通过多视特征学习和多级信息融合框架实现高光谱与 LiDAR 数据协同下的地物高精度分类。在所提的方法中，首先对第 3 章中地物空谱信息的重要概念进行了扩展，考虑到不同类型的空间特征提取方法能够表征地物几何结构、形状和纹理特征等不同属性的空间信息，利用具有多样性和差异性的多属性空间信息以及多源遥感数据中的光谱和高程信息，能够构建出地物更为完备、更加全面的多视图信息表达。随后，设计了基于特征级多源信息融合的多分支双通道图卷积模型，有效地剔除多源多视图数据表达中的冗余信息，提取出地物具有互补性和多样性的多视图特征表示。然后，在第 4 章类别修正方案的基础上，提出了一种渐进式高置信度的地物分类方案，通过决策级的多源信息融合对地物多视图特征对应的多分支分类结果进行整合，挖掘同类地物在跨视图表示中的语义表达一致性，并利用局部空间中同质样本间的属性关联，实现目标样本类别标签的有效预测。实验结果表明，本章所提的方法能够综合利用不同层次信息融合的各自优势，有效地融合高光谱和 LiDAR 数据中的多源异构信息，挖掘同类地物在不同信息层面上的耦合关联性，改善地物的分类精度和高光谱图像的解译效果。最后，论文将所提的高光谱分类方法进行封装集成，设计了基于高光谱图像的地物类型区分和识别软件，并对该软件的整体结构和主要功能进行了阐述，进一步拓展了论文研究内容在实际应用中的可行性。

结 论

近年来,随着成像光谱技术和航空航天技术的日新月异,高光谱图像分类技术在智慧农业、城市规划、食品医疗和伪装识别等诸多应用领域都展现出了不可替代的重要作用。本文针对高光谱图像分类过程中光谱信息的不确定性对地物类别有效判定的不利影响,首先研究了基于空谱信息联合和可靠邻域结构挖掘的高光谱图像特征提取方法;在此基础上,针对标记样本稀缺情况下地物识别困难、解译效果差等问题,本文研究了小样本条件下的高光谱分类方法,通过高质量的样本扩充和有效的类别修正,提升地物类间区分的能力;最后,为克服高光谱图像地物信息表征不完善和异构高程信息融合困难等问题,本文从地物跨模态信息表示的关联性着手,研究并实现了基于多视特征提取和多层次信息融合框架的高光谱与 LiDAR 数据协同地物分类。论文的主要工作和所取得的创新性研究成果总结如下:

1. 提出了一种基于可靠邻域结构的空谱多维特征提取方法。该方法以高光谱图像空谱信息的联合形式度量样本间距离,克服了现有方法样本相似度的衡量偏差,构建地物样本间可靠的邻域结构,从而揭示高维数据隐含的本质流形特性;然后结合已知的语义类别信息,提取出不同类型地物的鉴别性特征,从而在低维的特征空间中使同类地物样本更加聚集、异类地物间区分更加显著。实验结果表明,所提方法能够更有效地去除高光谱数据中的冗余信息,挖掘出同类地物的本质流形结构,为地物类别的准确判定提供鉴别性的空谱特征,对于农业场景中同一科目下的不同类型作物和复杂城市区域中光谱相似度高的异类地物,都展现出了更强的区分能力。

2. 提出了一种基于半监督学习和多类型信息融合的高光谱小样本分类方法。论文通过原始有限语义信息和高光谱图像中地物多类型信息的有机联合,从不同角度揭示类内地物样本间的密切关系,实现基于可靠邻域结构语义信息一致性的高质量样本扩充和局部同质区域地物关联引导的类别自适应修正,解决地物类别获取困难导致的标记样本数目不充足和地物区分准确度低等问题。实验结果表明,无论是地物种类丰富的农业种植区还是成像背景复杂的城镇区域,所提小样本分类方法中的各部分能够以逐步递进的方式提升地物分类精度,从而缓解标记样本稀缺对高光谱图像解译应用的限制。

3. 提出了一种基于高程信息辅助的高光谱分类方法。论文在前面研究内容的基础上,引入 LiDAR 数据的高程信息辅助,克服高光谱图像地物信息表示的不完

善，通过构建多源地物的多视图特征提取模型，解决了现有方法地物特征表示单一、区分度弱等问题；并规避了单一层次多源数据融合的限制性，结合不同层次上多源信息融合的优势，实现地物类别渐进式的高置信度预测。实验结果表明，对于不同采集条件下的农村场景和城市街区，所提方法能够有效地融合多源数据中地物的多模态异构信息，提取出更具类间区分度的地物特征，并获得更加精确的地物分类结果。

此外，基于本文的研究内容还存在可进一步拓展的研究工作：其中，本文提出的高光谱分类方法，今后可通过联合多光谱或可见光数据，探索类间地物语义和空谱信息间的相关性，增强地物特征的一致性表达，补充高光谱图像缺失的空间细节信息，提升空间分辨率，增强地物类别的区分能力，并将基于高程信息辅助的高光谱分类方法扩展到小样本条件下，拓展其可应用的实际场景；另外，考虑进一步完善基于高光谱分类技术的智能化软件开发，依据目标场景不同时期采集到的高光谱图像，构建典型地物的光谱信息库，拓展其在农业精细化生产和城市智慧化管理中的可持续性应用。

参考文献

- [1] GEO 的宗旨及主要任务[EB/OL](2021-10-24). <http://nrsec.most.cn/p1/gk.html>.
- [2] 童庆禧. 中国遥感技术和产业化发展现状与提升思路 [J]. 发展研究, 2023, 40(6): 1-5.
- [3] 杜培军, 夏俊士, 薛朝辉等. 高光谱遥感影像分类研究进展 [J]. 遥感学报, 2016, 20(2): 236-256.
- [4] 余旭初, 刘冰, 薛志祥. 高光谱地物要素识别潜力分析与前景展望 [J]. 测绘学报, 2023, 52(7): 1115-1125.
- [5] 史飞飞, 高小红, 杨灵玉等. 基于 HJ-1A 高光谱遥感数据的湟水流域典型农作物分类研究 [J]. 遥感技术与应用, 2017, 32(2): 206-217.
- [6] 郝悦竹, 张加龙. 高光谱遥感在林业应用中的主要技术和应用现状 [J]. 绿色科技, 2022, 24(3): 148-153.
- [7] 黄梦鸽, 王新鸿, 马灵玲等. 草地草种遥感判别技术研究进展 [J]. 草业学报, 2023, 32(6):167-185.
- [8] 冯天时, 庞治国, 江威. 基于珠海一号高光谱卫星的巢湖叶绿素 a 浓度反演 [J]. 光谱学与光谱分析, 2022, 42(8): 2642-2648.
- [9] 张启忠, 郑恩迪, 王叶剑等. 高光谱图像深度模糊核聚类的洋底锰结核识别 [J]. 中国图象图形学报, 2021, 26(8): 1886-1895.
- [10] 杜培军. 城市遥感的研究动态与发展趋势—“城市遥感”专栏导读 [J]. 地理与地理信息科学, 2018, 34(3): 1-4.
- [11] Shahshahani B, Landgrebe D. The Effect of Unlabeled Samples in Reducing the Small Sample Size Problem and Mitigating the Hughes Phenomenon [J]. IEEE Transactions on Geoscience and Remote Sensing, 1994, 32(5): 1087-1095.
- [12] 中华人民共和国国务院. 中华人民共和国国民经济和社会发展第十四个五年规划和 2035 年远景目标纲要 [M]. 北京: 人民出版社, 2021.
- [13] Green R O, Chrien T G, Enmark H T. First Results from the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) [J]. Remote Sensing of the Environment, 1993, 44(93): 127-143.
- [14] Mcfee J E, Ripley H T, Dubey A C, et al. Detection of Buried Land Mines Using a CASI Hyperspectral Imager [J]. International Society for Optics and Photonics, 1997, 3079:738-749.
- [15] Kunkel B, Blechinger F, Viehmann D, et al. ROSIS Imaging Spectrometer and Its Potential for Ocean Parameter Measurements (Airborne and Spaceborne) [J]. In-

- ternational Journal of Remote Sensing, 1991, 12(4): 753-761.
- [16] Jan H, Zbyněk M, Lucie H, et al. Potentials of the VNIR Airborne Hyperspectral System AISA Eagle [J]. Aisa Eagle Vnir System, 2008, 27: 1-6.
- [17] Lucas R, Bunting P, Paterson M and Chisholm L. Classification of Australian Forest Communities Using Aerial Photography, CASI and HyMap data [J]. Remote Sensing of Environment, 2008, 112(5): 2088-2103.
- [18] 刘银年. 高光谱成像遥感载荷技术的现状与发展 [J]. 遥感学报, 2021, 25(1): 439-459.
- [19] 刘思田, 卢慧, 王栋等. 星载高光谱成像系统发展综述 [J]. 航天返回与遥感, 2023, 44(6): 12-26.
- [20] 刘银年, 孙德新, 胡晓宁等. 高分五号可见短波红外高光谱相机设计与研制 [J]. 遥感学报, 2020, 24(4): 333-344.
- [21] 赖积保, 康旭东, 鲁续坤等. 新一代人工智能驱动的陆地观测卫星遥感应用技术综述 [J]. 遥感学报, 2022, 26(8): 1530-1546.
- [22] 李盛阳, 刘志文, 刘康等. 航天高光谱遥感应用研究进展(特邀) [J]. 红外与激光工程, 2019, 48(3): 9-23.
- [23] 中华人民共和国自然资源部. 自然资源部卫星遥感应用报告(2020年) [R/OL]. (2021-07-16) [000019174/2021-00013].
- [24] 本刊编辑部. 里程碑与风向标—第一届中国测绘地理信息大会的创新与融合 [J]. 中国测绘, 2023, (11):1.
- [25] 晏磊, 廖小罕, 周成虎等. 中国无人机遥感技术突破与产业发展综述 [J]. 地球信息科学学报, 2019, 21(4): 476-495.
- [26] Rasti B, Hong D, Hang R, Ghamisi P, et al. Feature Extraction for Hyperspectral Imagery: The Evolution from Shallow to Deep (Overview and Toolbox) [J]. IEEE Geoscience and Remote Sensing Magazine, 2020, 8(4): 60-88.
- [27] 苏红军. 高光谱遥感影像降维:进展、挑战与展望 [J].遥感学报, 2022, 26(8): 1504-1529.
- [28] Grewal R, Kasana S S, Kasana G. Machine Learning and Deep Learning Techniques for Spectral Spatial Classification of Hyperspectral Images: A Comprehensive Survey [J]. Electronics, 2023, 12(3): 488-521.
- [29] Zhang X, Jiang X, Jiang J, Zhang Y, et al. Spectral-Spatial and Superpixelwise PCA for Unsupervised Feature Extraction of Hyperspectral Imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-10.
- [30] Luo G, Chen G, Tian L, et al. Minimum Noise Fraction Versus Principal Component Analysis as a Preprocessing Step for Hyperspectral Imagery Denoising [J].

- Canadian Journal of Remote Sensing, 2016, 42(2): 106-116.
- [31] He X, Cai D, Yan S, et al. Neighborhood Preserving Embedding [C]. IEEE International Conference on Computer Vision, 2005, 2: 1208-1213.
- [32] Sugiyama M. Dimensionality Reduction of Multimodal Labeled Data by Local Fisher Discriminant Analysis [J]. Journal of Machine Learning Research, 2007, 8: 1027-1061.
- [33] Melgani F and Bruzzone L. Classification of Hyperspectral Remote Sensing Images with Support Vector Machines [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(8): 1778-1790.
- [34] Ham J, Chen Y, Crawford M M, et al. Investigation of the Random Forest Framework for Classification of Hyperspectral Data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3): 492-501.
- [35] Ghamisi P, Plaza J, Chen Y, et al. Advanced Spectral Classifiers for Hyperspectral Images: A review [J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(1): 8-32.
- [36] Hmimina G, Dufrêne E, Pontailier J, Delpierre N, et al. Evaluation of the Potential of MODIS Satellite Data to Predict Vegetation Phenology in Different Biomes: An Investigation Using Ground-Based NDVI Measurements [J]. Remote Sensing of Environment, 2013, 132: 145-158.
- [37] Cao B. NDWI-A Normalized Difference Water Index for Remotesensing of Vegetatin Liquid Water from Space [J]. Remote Sensing of Environment, 1996, 58: 257-266.
- [38] Candiago S, Remondino F, De Giglio M, Dubbini M, Gattelli M. Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images [J]. Remote Sensing, 2015, 7(4): 4026-4047.
- [39] Imani M, Ghassemian H. Attribute Profile Based Feature Space Discriminant Analysis for Spectral-Spatial Classification of Hyperspectral Images [J]. Computers and Electrical Engineering, 2017, 62:555-569.
- [40] Huang X, Liu X, Zhang L. A Multichannel Gray Level Co-occurrence Matrix for Multi/Hyperspectral Image Texture Representation [J]. Remote Sensing, 2014, 6(9): 8424-8445.
- [41] Bhatti U, Yu Z, Chanussot J, Zeeshan Z, et al. Local Similarity-Based Spatial-Spectral Fusion Hyperspectral Image Classification with Deep CNN and Gabor Filtering [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-15.
- [42] Huang L, Chen C, Li W, Du Q. Remote Sensing Image Scene Classification Using Multi-scale Completed Local Binary Patterns and Fisher Vectors [J]. Remote

- Sensing, 2016, 8(6): 483-499.
- [43] Hong D, Wu X, Ghamisi P, Chanussot J, et al. Invariant Attribute Profiles: A Spatial-Frequency Joint Feature Extractor for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(6): 3791-3808.
- [44] Imani M, Ghassemian H. An overview on Spectral and Spatial Information Fusion for Hyperspectral Image Classification: Current Trends and Challenges [J]. Information Fusion, 2020, 59: 59-83.
- [45] 叶珍, 白璘, 何明一. 高光谱图像空谱特征提取综述 [J]. 中国图象图形学报, 2021, 26(8): 1737-1763.
- [46] Gu Y, Chanussot J, Jia X, Benediktsson J A. Multiple Kernel Learning for Hyperspectral Image Classification: A Review [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(11): 6547-6565.
- [47] Lunga D, Prasad S, Crawford M M, Ersoy O. Manifold-Learning-Based Feature Extraction for Classification of Hyperspectral Data: A Review of Advances in Manifold Learning [J]. IEEE Signal Processing Magazine, 2014, 31(1): 55-66.
- [48] Peng J, Sun W, Li H, Li W, et al. Low-Rank and Sparse Representation for Hyperspectral Image Processing: A review [J]. IEEE Geoscience and Remote Sensing Magazine, 2022, 10(1): 10-43.
- [49] Gao F, Wang Q, Dong J, et al. Spectral and Spatial Classification of Hyperspectral Images Based on Random Multi-Graphs [J]. Remote Sensing, 2018, 10(8): 1271-1290.
- [50] Hong D, Yokoya N, Zhu X. Learning a Robust Local Manifold Representation for Hyperspectral Dimensionality Reduction [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(6): 2960-2975.
- [51] Jiang X, Xiong L, Yan Q, Zhang Y, et al. Unsupervised Dimensionality Reduction for Hyperspectral Imagery via Laplacian Regularized Collaborative Representation Projection [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [52] Zhou C, Tu B, Ren Q, Chen S. Spatial Peak-Aware Collaborative Representation for Hyperspectral Imagery Classification [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [53] Audebert N, Saux B, Lefevre S. Deep Learning for Classification of Hyperspectral Data: A Comparative Review [J]. IEEE Geoscience and Remote Sensing Magazine, 2019, 7(2): 159-173.
- [54] He M, Li B, Chen H. Multi-scale 3D Deep Convolutional Neural Network for Hyperspectral Image Classification [C]. IEEE International Conference on Image Processing, 2017: 3904-3908.
- [55] Hamida B, Benoit A, Lambert P, Amar C. 3-D Deep Learning Approach for Re-

- ote Sensing Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(8): 4420-4434.
- [56] Gao Q, Lim S, Jia X. Hyperspectral Image Classification Using Convolutional Neural Networks and Multiple Feature Learning [J]. Remote Sensing, 2018, 10(2): 299-316.
- [57] Sikakollu P, Dash R. Ensemble of Multiple CNN Classifiers for HSI Classification with Superpixel Smoothing [J]. Computers & Geosciences, 2021,154: 1-12.
- [58] Hong D, Gao L, Yao J, Zhang B, et al. Graph Convolutional Networks for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(7): 5966-5978.
- [59] Zhong Z, Li Y, Ma L, et al. Spectral-Spatial Transformer Network for Hyperspectral Image Classification: A Factorized Architecture Search Framework [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-15.
- [60] 郝乔波. 小样本下高光谱图像分类与性能评估问题研究 [D]. 湖南大学, 2023.
- [61] Wang X, Liu J, Chi W, Wang W, Ni Y. Advances in Hyperspectral Image Classification Methods with Small Samples: A Review [J]. Remote Sensing. 2023, 15(15): 3795-3822.
- [62] Aydemir M, Bilgin G. Semisupervised Hyperspectral Image Classification Using Small Sample Sizes [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 621-625.
- [63] Thoreau R, Achard V, Risser L, Berthelot B, et al. Active Learning for Hyperspectral Image Classification: A Comparative Review [J]. IEEE Geoscience and Remote Sensing Magazine, 2022, 10(3): 256-278.
- [64] Yang J, Zhao Y, Chan J. Learning and Transferring Deep Joint Spectral-Spatial Features for Hyperspectral Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(8): 4729-4742.
- [65] Gao K, Liu B, Yu X, et al Deep Relation Network for Hyperspectral Image Few-Shot Classification [J]. Remote Sensing, 2020; 12(6): 923-946.
- [66] Li X, Li Z, Qiu H, Hou G, Fan P. An Overview of Hyperspectral Image Feature Extraction, Classification Methods and the Methods Based on Small Samples [J]. Applied Spectroscopy Reviews, 2021, 58(6): 367-400.
- [67] Richards J A, Jia X. Using Suitable Neighbors to Augment the Training Set in Hyperspectral Maximum Likelihood Classification [J]. IEEE Geoscience and Remote Sensing Letters, 2008, 5 (4): 774-777.
- [68] Subudhi S, Patro R N, Biswal P K, et al. A Survey on Superpixel Segmentation as a Preprocessing Step in Hyperspectral Image Analysis [J]. IEEE Journal of Se-

- lected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 5015-5035.
- [69] Shang X, Han S, Song M. Iterative Spatial-Spectral Training Sample Augmentation for Effective Hyperspectral Image Classification [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [70] Su H, Shao F, Gao Y, Zhang H, et al. Probabilistic Collaborative Representation Based Ensemble Learning for Classification of Wetland Hyperspectral Imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-17.
- [71] Liu C, Li J, He L. Superpixel-Based Semisupervised Active Learning for Hyperspectral Image Classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(1): 357-370.
- [72] Zheng C, Wang N, Cui J. Hyperspectral Image Classification with Small Training Sample Size Using Superpixel-guided Training Sample Enlargement [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(10): 7307-7316.
- [73] Jia S, Jiang S, et al. A Survey: Deep Learning for Hyperspectral Image Classification with Few Labeled Samples [J]. Neurocomputing, 2021, 448: 179-204.
- [74] Haut J M, Paoletti M E, Plaza J, Plaza A, Li J. Hyperspectral Image Classification Using Random Occlusion Data Augmentation [J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(11): 1751-1755.
- [75] 吴鸿昊, 王立国, 石瑶. 高光谱图像小样本分类的卷积神经网络方法 [J]. 中国图象图形学报, 2021, 26(8): 2009-2020.
- [76] Fang L, Zhao W, He N, Zhu J. Multiscale CNNs Ensemble Based Self-learning for Hyperspectral Image Classification [J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(9): 1593-1597.
- [77] Niu B, Lan J, Shao Y, Zhang H. A Dual-Branch Extraction and Classification Method Under Limited Samples of Hyperspectral Images Based on Deep Learning [J]. Remote Sensing, 2020, 12(3): 536-558.
- [78] Yao J, Cao X Y, Hong D, Wu X, et al. Semi-Active Convolutional Neural Networks for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-15.
- [79] Yue J, Fang L, Rahmani H, Ghamisi P. Self-Supervised Learning with Adaptive Distillation for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-13.
- [80] 谭琨, 王雪, 杜培军. 结合深度学习和半监督学习的遥感影像分类进展 [J]. 中国图象图形学报, 2019, 24(11): 1823-1841.
- [81] Zhang H, Li Y, Jiang Y, Wang P, et al. Hyperspectral Classification Based on Lightweight 3-D-CNN With Transfer Learning [J]. IEEE Transactions on Geosci-

- ence and Remote Sensing, 2019, 57(8): 5813-5828.
- [82] Ahmad M, Ghous U, Hong D, Khan A, et al. A Disjoint Samples-Based 3D-CNN With Active Transfer Learning for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-16.
- [83] 仲崇潇. 基于空谱特征域适应的高光谱图像分类方法研究 [D]. 哈尔滨工业大学, 2022.
- [84] Deng B, Jia S, Shi D. Deep Metric Learning-Based Feature Embedding for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(2): 1422-1435.
- [85] Liu B, Yu X, Yu A, Zhang P, et al. Deep Few-Shot Learning for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(4): 2290-2304.
- [86] Liu B, Yu A, Yu X, Wang R, et al. Deep Multiview Learning for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(9): 7758-7772.
- [87] Li Z, Liu M, Chen Y, Xu Y, et al. Deep Cross-Domain Few-Shot Learning for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-18.
- [88] Ghassemian, H. A Review of Remote Sensing Image Fusion Methods [J]. Information fusion, 2016, 32: 75-89.
- [89] 张良培, 沈焕锋. 遥感数据融合的进展与前瞻 [J]. 遥感学报, 2016, 20(5): 1050-1061.
- [90] 张兵, 高连如, 李嘉鑫等. 高/多光谱遥感图像超分辨率融合研究进展与展望 [J]. 测绘学报, 2023, 52(7): 1074-1089.
- [91] Kahraman S, Bacher R. A Comprehensive Review of Hyperspectral Data Fusion with LiDAR and SAR Data [J]. Annual Reviews in Control, 2021, 51: 236-253.
- [92] Kuras A, Brell M, Rizzi J, Burud I. Hyperspectral and LiDAR Data Applied to the Urban Land Cover Machine Learning and Neural-Network-based Classification: A Review [J]. Remote Sensing, 2021, 13(17): 3393-3431.
- [93] 张蒙蒙. 基于深度学习的高光谱图像融合分类技术研究 [D]. 北京化工大学, 2021.
- [94] Sun X, Tian Y, Lu W, et al. From Single- to Multi-modal Remote Sensing Imagery Interpretation: A Survey and Taxonomy [J]. Science China Information Sciences, 2023, 66, 140301.
- [95] 李树涛, 李聪好, 康旭东. 多源遥感图像融合发展现状与未来展望 [J]. 遥感学报, 2021, 25(1): 148-166.

- [96] Khodadadzadeh M, Li J, Prasad S, Plaza A. Fusion of Hyperspectral and LiDAR Remote Sensing Data Using Multiple Feature Learning [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2971–2983.
- [97] 张高腾, 王浩宇, 王成等. 融合机载LiDAR和高光谱影像的土地利用分类 [J]. *激光杂志*, 2023, 44(3): 133-136.
- [98] Xia J, Liao W, Du P. Hyperspectral and LiDAR Classification with Semisupervised Graph Fusion [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(4): 666-670.
- [99] Ghamisi P, Rasti B, Benediktsson J A. Multisensor Composite Kernels Based on Extreme Learning Machines [J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(2): 196-200.
- [100] Zhang Y, Prasad S. Multisource Geospatial Data Fusion via Local Joint Sparse Representation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(6): 3265-3276.
- [101] 杜星乾. 基于图神经网络的高光谱与激光雷达融合研究 [D]. 中国科学院大学(中国科学院西安光学精密机械研究所), 2023.
- [102] Gu Y, Wang Q. Discriminative Graph-based Fusion of HSI and LiDAR Data for Urban Area Classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(6): 906–910.
- [103] Zhang Y, Prasad S. Locality Preserving Composite Kernel Feature Extraction for Multi-Source Geospatial Image Analysis [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(3): 1385-1392.
- [104] Rasti B, Ghamisi P, Gloaguen R. Hyperspectral and LiDAR Fusion Using Extinction Profiles and Total Variation Component Analysis [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(7): 3997-4007.
- [105] Duan P, Kang X, Ghamisi P, Liu Y. Multilevel Structure Extraction-based Multi-sensor Data Fusion [J]. *Remote Sensing*, 2020, 12(24): 3276–4034.
- [106] 王金哲. 融合可见光/高光谱和LiDAR数据的城市地物分类算法研究 [D]. 哈尔滨工业大学, 2019.
- [107] Roy S, Deria A, Hong D, Ahmad M, et al. Hyperspectral and LiDAR Data Classification Using Joint CNNs and Morphological Feature Learning [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-16.
- [108] Hong D, et al. More Diverse Means Better: Multimodal Deep Learning Meets Remote-Sensing Imagery Classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(5): 4340-4354.
- [109] Hong D, Gao L, Hang R, Zhang B, et al. Deep Encoder-Decoder Networks for

- Classification of Hyperspectral and LiDAR data [J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [110] Ding K, Lu T, Fu W, Li S, et al. Global-Local Transformer Network for HSI and LiDAR Data Joint Classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-13.
- [111] Wu X, Hong D, Chanussot J. Convolutional Neural Networks for Multimodal Remote Sensing Data Classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-10.
- [112] Liao W, Bellens R, Pižurica A, Gautama S, et al. Combining Feature Fusion and Decision Fusion for Classification of Hyperspectral and LiDAR Data [C]. *IEEE International Geoscience and Remote Sensing Symposium*, 2014: 1241-1244.
- [113] Ge C, Du Q, Li W, Li Y, Sun W. Hyperspectral and LiDAR Data Classification Using Kernel Collaborative Representation Based Residual Fusion [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(6): 1963-1973.
- [114] 曹琼, 马爱龙, 钟燕飞等. 高光谱-LiDAR 多级融合城区地表覆盖分类 [J]. *遥感学报*, 2019, 23(5): 892-903.
- [115] Zhong Y, Cao Q, Zhao J, Ma A, et al. Optimal Decision Fusion for Urban Land-Use/Land-Cover Classification Based on Adaptive Differential Evolution Using Hyperspectral and LiDAR Data [J]. *Remote Sensing*, 2017, 9(8): 868-887.
- [116] Jia S, Zhan Z, Zhang M, et al. Multiple Feature-based Superpixel-Level Decision Fusion for Hyperspectral and LiDAR Data Classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(2): 1437-1452.
- [117] Hang R, Li Z, Ghamisi P, Hong D, et al. Classification of Hyperspectral and LiDAR Data Using Coupled CNNs [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(7): 4939-4950.
- [118] Lu T, Ding K, Fu W, Li S, et al. Coupled Adversarial Learning for Fusion Classification of Hyperspectral and LiDAR Data [J]. *Information Fusion*, 2023, 93: 118-131.
- [119] Zhang S, Meng X, Liu Q, Yang G, Sun W. Feature-Decision Level Collaborative Fusion Network for Hyperspectral and LiDAR Classification [J]. *Remote Sensing*, 2023, 15(17): 4148-4167.
- [120] 张兵, 李山山, 张浩等. 高光谱卫星图像协同处理理论与方法 [M]. 北京: 人民邮电出版社, 2020.
- [121] 袁艳, 刘安琪, 苏丽娟. 快照式光谱成像技术发展趋势分析与展望(特邀) [J]. *光子学报*, 2022, 51(7): 96-112.

- [122] 韩艳雪. 低温长波红外高光谱成像仪关键技术研究 [D]. 中国科学院大学(中国科学院长春光学精密机械与物理研究所), 2023.
- [123] 张淳民著. 成像光谱偏振技术 [M]. 北京: 科学出版社, 2020.
- [124] Fu H, Sun G, Zhang L, et al. Three-dimensional Singular Spectrum Analysis for Precise Land Cover Classification from UAV-Borne Hyperspectral Benchmark Datasets [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 202: 115-134.
- [125] 岑奕, 张立福, 张霞等. 雄安新区马蹄湾村航空高光谱遥感影像分类数据集 [J]. *遥感学报*, 2020, 24(11): 1299-1306.
- [126] 刘天竹. 高光谱遥感图像多核学习分类方法研究 [D]. 哈尔滨工业大学, 2019.
- [127] Bachmann C M, Ainsworth T L, Fusina R A. Exploiting Manifold Geometry in Hyperspectral Imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(3): 441-454.
- [128] 张乐飞. 遥感影像的张量表达与流形学习方法研究 [D]. 武汉大学, 2013.
- [129] 李政英. 基于深度流形学习的高光谱图像分类研究 [D]. 重庆大学, 2021.
- [130] Bregler C, Omohundro S M. Nonlinear Manifold Learning for Visual Speech Recognition [C]. *Fifth International Conference on Computer Vision*, Cambridge MA, 1995: 494-499.
- [131] 石光耀. 高光谱遥感影像空-谱流形学习降维方法研究 [D]. 重庆大学, 2022.
- [132] Der Maaten L V, Hinton G E. Visualizing Data Using t-SNE [J]. *Journal of Machine Learning Research*, 2008: 2579-2605.
- [133] Liao W, Pizurica A, Scheunders P, Philips W, et al. Semisupervised Local Discriminant Analysis for Feature Extraction in Hyperspectral Images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(1): 184-198.
- [134] Lu X, Zhang J, Li T, et al. Hyperspectral Image Classification Based on Semisupervised Rotation Forest [J]. *Remote Sensing*, 2017, 9(9): 924-937.
- [135] Duan P, Ghamisi P, Kang X, Rasti B, et al. Fusion of Dual Spatial Information for Hyperspectral Image Classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(9): 7726-7738.
- [136] Yan X, Hu S, Mao Y, et al. Deep Multi-view Learning Methods: A Review [J]. *Neurocomputing*, 2021, 448(11): 106-129.
- [137] Scarselli F, Gori M, Tsoi A, Hagenbuchner M, et al. The Graph Neural Network Model [J]. *IEEE Transactions on Neural Networks*, 2009, 20(1): 61-80.
- [138] Wu Z, Pan S, Chen F, Long G, et al. A Comprehensive Survey on Graph Neural Networks [J]. *IEEE Transactions on Neural Networks and Learning Systems*,

- 2021, 32(1): 4-24.
- [139] Bruna J, Zaremba W, Szlam A, LeCun Y. Spectral Networks and Deep Locally Connected Networks on Graphs [C]. International Conference on Learning Representations, 2014.
- [140] Kipf T N, Welling M. Semi-supervised Classification with Graph Convolutional Networks [C]. International Conference on Learning Representations, 2017.
- [141] Khlifi M, Boulila W, Farah I. Graph-based Deep Learning Techniques for Remote sensing Applications: Techniques, Taxonomy, and Applications-A Comprehensive Review [J]. Computer Science Review, 2023, 50: 1-27.

附录

附表 1 缩略词及释义

Supplementary Table 1 Abbreviations and the corresponding interpretations

缩写	英文全称	中文全称
HSI	Hyperspectral Image	高光谱图像
LiDAR	Light Detection and Ranging	激光雷达
AVIRIS	Airborne Visible/Infrared Imaging Spectrometer	机载可见光/红外成像光谱仪
CASI	Compact Airborne Spectrographic Imager	小型机载成像光谱仪
ROSIS	Reflective Optics System Imaging Spectrometer	反射光学系统成像光谱仪
AISA	Airborne Imaging Spectrometer for Applications	应用型机载成像光谱仪
OMIS	Operational Modular Imaging Spectrometer	实用型模块化成像光谱仪
PHI	Pushbroom Hyperspectral Imager	推扫式高光谱成像仪
ATHIS	Airborne Thermal-Infrared Hyperspectral Imaging System	机载热红外高光谱成像系统
AMMIS	Airborne Multi-modality Imaging Spectrometer	机载多模态成像光谱仪
FTHSI	Fourier Transform Hyperspectral Imager	傅里叶变换高光谱成像光谱仪
CHRIS	Compact High Resolution Imaging Spectrometer	紧凑式高分辨率成像光谱仪
AHSI	Advanced Hyperspectral Imager	可见短波红外高光谱相机
PCA	Principal Component Analysis	主成分分析
NPE	Neighborhood Preserving Embedding	邻域保持嵌入
LFDA	Local Fisher's Discriminant Analysis	局部线性判别分析
SVM	Support Vector Machines	支持向量机
RF	Random Forest	随机森林
kNN	k -Nearest Neighbor	k -近邻分类器
EMAP	Extended Multi-attribute Profiles	扩展的多属性剖面特征
GLCM	Gray Level Co-occurrence Matrix	灰度共生矩阵
LBP	Local Binary Pattern	局部二值化
IAPs	Invariant Attribute Profiles	不变属性剖面特征
RMGs	Random Multi-Graphs	随机多图
RLMR	Robust Local Manifold Representation	鲁棒性的局部流形表示
LRCRP	Laplacian Regularized Collaborative Representation Projection	Laplacian 正则化协同表示
SPaCR	Spatial Peak-Aware Collaborative Representation	基于空间峰值感知的协同表示
M3D-DCNN	Multiscale 3D Deep Convolutional Neural Network	多尺度三维深度卷积神经网络
CNN-MFL	CNN-based Multiple Feature Learning	基于 CNN 的多类型特征学习
EMCNN	Ensemble of Multiple CNN Classifiers	集成多类型 CNN 分类器
GCN	Graph Convolutional Network	图卷积网络

附表 1 (续表)

缩写	英文全称	中文全称
SSTN	Spectral-spatial Transformer Network	空谱 Transformer 网络
SGTSE	Supapixel-Guided Training Sample Enlargement	超像素引导的样本扩充
SSAD	Self-supervised Learning with Adaptive Distillation	结合自适应蒸馏的自监督学习
DFSL	Deep Few-shot Learning	深度少样本学习
DMVL	Deep Multi-view Learning	深度多视图学习
DCFSL	Deep Cross-domain Few-show Learning	深度跨域少样本学习
SAR	Synthetic Aperture Radar	合成孔径雷达
OTVCA	Orthogonal Total Variation Component Analysis	正交全变分成分分析
MSE	Multi-level Structure Extraction	多级结构特征提取
FCNets	Fully Connected Networks	全连接网络
MDL	Multimodal Deep Learning	多模态深度学习
EndNet	Encoder-decoder Network	编码器-解码器结构网络
GLT-Net	Global-Local Transformer Network	全局-局部 Transformer 网络
CCR	Cross-Channel Reconstruction	跨通道重建
MFSuDF	Multiple Feature-Based Supapixel-Level Decision Fusion	基于多类型特征的超像素级决策融合
CALC	Coupled Adversarial Learning-based Classification	基于耦合对抗学习的分类
IP	Indian Pines	印第安纳
PU	Pavia University	帕维亚大学
HU	Houston University	休斯顿大学
OA	Overall Accuracy	总体分类精度
CA	Class-specific Accuracy	类内分类精度
κ	Kappa Coefficients	Kappa 系数
t -SNE	t -Distributed Stochastic Neighbor Embedding	t 分布随机邻域嵌入
SELD	Semi-supervised Local Discriminant Analysis	半监督局部判别分析
WSLDA	Weighted Semi-supervised Local Discriminant Analysis	加权的半监督局部线性判别分析
FE	Feature Extraction	特征提取
MVDR	Multi-view Data Representation	多视图数据表示
MB-DCGCNs	Multi-branch Dual-channel Graph Convolutional Networks	多分支双通道图卷积网络
PHCLA	Progressively High-confidence Label Assignment	渐进式高置信度的地物分类
MVFL-MLIF	Multi-view Feature Learning and Multi-level Information Fusion	多视特征学习和多级信息融合
DCGCNs	Dual-channel Graph Convolutional Networks	双通道图卷积网络

攻读博士学位期间取得创新性成果

（一）发表的学术论文

- [1] **Jia Feng**, Junping Zhang and Ye Zhang. Multi-view Feature Learning and Multi-level Information Fusion for Joint Classification of Hyperspectral and LiDAR Data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-13. (SCI 收录, IDS 号为 001097583200016, IF=8.1. 对应论文第 5 章)
- [2] **Jia Feng**, Junping Zhang and Ye Zhang. A Multiview Spectral-Spatial Feature Extraction and Fusion Framework for Hyperspectral Image Classification [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5. (SCI 收录, IDS 号为 000732201900001, IF=5.3. 对应论文第 5 章)
- [3] **Jia Feng**, Junping Zhang and Ye Zhang. Hyperspectral Image Classification Based on Semisupervised Self-Learning and Multiview Information Fusion [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5. (SCI 收录, IDS 号为 000838362300004, IF=5.3. 对应论文第 4 章)
- [4] **Jia Feng**, Junping Zhang, Tong Li and Ye Zhang. Spectral-Spatial Joint Feature Extraction for Hyperspectral Image Based on High-Reliable Neighborhood Structure [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 9609-9623. (SCI 收录, IDS 号为 000704110600009, IF=4.7. 对应论文第 3 章)
- [5] **Jia Feng**, Junping Zhang. Unsupervised Feature Extraction in Hyperspectral Image Based on Improved Neighborhood Preserving Embedding [C]. IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Waikoloa, HI, USA, 2020: 1291-1294. (EI 收录号: 20211010035602. 对应论文第 3 章)

（二）其他成果

- [1] Qingyu Yan, Junping Zhang, **Jia Feng**. Spectral-Spatial Classification of Hyperspectral Image Using PCA and Gabor Filtering [C]. IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Waikoloa, HI, USA, 2020: 513-516. (EI 收录号: 20211010036208)
- [2] Zhenyuan Feng, Junping Zhang, **Jia Feng**. Spectral-Spatial Joint Target Detection of Hyperspectral Image Based on Transfer Learning [C]. IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Waikoloa, HI, USA, 2020: 1770-1773. (EI 收录号: 20211010035733)

（三）参与的科研项目

- [1] 宽波段多维度高光谱遥感图像分析及解译新方法, 国家自然科学基金. 课题编号: 61871150.
- [2] 基于多源数据的寒地水稻遥感监测技术应用与示范, 中央引导地方科技发展专项 (“百城百园” 专项).

哈尔滨工业大学学位论文原创性声明和使用权限

学位论文原创性声明

本人郑重声明：此处所提交的学位论文《基于空谱多维特征提取的高光谱图像分类方法研究》，是本人在导师指导下，在哈尔滨工业大学攻读学位期间独立进行研究工作所取得的成果，且学位论文中除已标注引用文献的部分外不包含他人完成或已发表的研究成果。对本学位论文的研究工作做出重要贡献的个人和集体，均已在文中以明确方式注明。

作者签名：

日期：2024年5月27日

学位论文使用权限

学位论文是研究生在哈尔滨工业大学攻读学位期间完成的成果，知识产权归属哈尔滨工业大学。学位论文的使用权限如下：

(1) 学校可以采用影印、缩印或其他复制手段保存研究生上交的学位论文，并向国家图书馆报送学位论文；(2) 学校可以将学位论文部分或全部内容编入有关数据库进行检索和提供相应阅览服务；(3) 研究生毕业后发表与此学位论文研究成果相关的学术论文和其他成果时，应征得导师同意，且第一署名单位为哈尔滨工业大学。

保密论文在保密期内遵守有关保密规定，解密后适用于此使用权限规定。

本人知悉学位论文的使用权限，并将遵守有关规定。

作者签名：

日期：2024年5月27日

导师签名：

日期：2024年5月27日

致 谢

执笔至此，而立有二，回顾十几载的求学路，有过迷茫困惑、颓废消沉，也有过奋发进取、拼搏向上，兜兜转转，行进至今。一路走来承蒙师长同学、家人朋友的关照，在论文即将完成之际，谨在此向大家敬以我由衷的谢意。

首先，感谢我的博士生导师张钧萍教授，感谢您在博士阶段给予我学术上的悉心指导和生活中的暖心关怀，我才得以前行至今，收获全新的自己。回想起初入课题组时，内心极度的焦虑不安，感谢您多次与我沟通，帮助我进行情绪疏导、缓解压力，从第一次撰写论文的多轮修改，到最后毕业论文的反复校对，我的每次进步都离不开您的悉心指导和专业引领，“桃李不言,下自成蹊”，老师待人做事的谦逊和蔼、科研教学的严谨细致，是对师者形象的最好诠释，这些都深深地影响着我，是我日后工作的榜样。感谢院系各位老师在各期审核中对我研究方向的专业指导和中肯建议。感谢每篇论文审稿人、评审专家们的专业建议和领域内同行们撰写的优秀科学技术文献，让我得以跳出自己局限的思维，重新审视自己的研究思路，提升了我看待事物的认知水平。

其次，感谢 801 实验室的所有小伙伴们对我学业科研和日常生活中各方面疑惑的耐心解答，尤其感谢陆小辰师兄、彤师姐、仲、郭、琳琳师妹和小冯师弟。此外，还要感谢我的好友王娜在特殊时期给予我的无私帮助，感谢大哥张阳伟一直以来对我的认可和鼓励。借此机会还要感谢硕士阶段遇到的师长和同学们，感谢大家在日常学习生活中给予我的帮助。感谢我的高中班主任于颖，感谢老师一直以来的认可和惦念，感谢高中好友成琳、大学的室友和好友云飞、雪聪、聪聪和晓亮，你们坚毅果敢、自律自强，在我三观确立成型之际，与你们相遇，是我莫大的幸运。

最后，感谢我的父亲和母亲几十年来不求任何回报的默默付出，用自己的臂膀托起了我，让我能够看到更广阔的世界，无论是少年时的叛逆还是青春期的执拗，都一直支持着我、陪伴着我，给我最大的自由度去体验人生。感谢我的公公婆婆，感谢你们这几年来不辞劳苦地替我们分担养育子女的重任，给予我们无私的物质支持和生活关照，让我们能够安心地在异地完成学业。感谢我的先生给予我的关心和包容，我们携手已共度了八个春秋，感谢有你的陪伴，我能够更加勇敢、执着地不断前行。感谢我的女儿，让我深切体会到我的父母亲在养育子女过

程中的艰辛和不易，感谢你的到来，我能够更加高效地工作、平和地生活。还要感谢读博这几年来在“自我怀疑-自我否定-自我激励”的迭代循环中坚持至今的自己，我始终相信每个人的成长历程都不尽相同，不必艳羡别人的繁花似锦、芳香四溢，你自有清幽绿草、笔直生长，“道阻且长，行则将至”，别忘了踏上这条征途启程时的初心和勇气，**Just hold on tight, it can be alright!** 感谢繁荣昌盛的祖国，才有如今和平安定的生活环境，何其有幸，生于华夏，愿你我都能不负韶华，以己之力，尽己所能。

个人简历

1992年01月16日出生于黑龙江省绥化市。

2008年09月——2012年06月，在吉林大学电子科学与工程学院电子科学与技术专业学习并获得工学学士学位。

2013年09月——2016年01月，在哈尔滨工业大学（深圳）电子与信息工程学院集成电路工程专业学习并获得工程硕士学位。

2019年08月——今，在哈尔滨工业大学电子与信息工程学院先进制造工程专业攻读博士学位。

工作经历：

2016年04月——2016年06月，就职于中电第四十七研究所。

2016年09月——2019年07月，就职于绥化学院电气工程学院。