

分类号 TP753
U D C 004

学校代码 10590
密 级 公开

深圳大学硕士学位论文

基于超像素分割的高光谱图像特征变换 和分类算法研究

学位申请人姓名 邓彬

专 业 名 称 模式识别与智能系统

学院（系、所） 计算机与软件学院

指导教师姓名 贾森

深圳大学学位论文原创性声明和使用授权说明

原创性声明

本人郑重声明：所呈交的学位论文 基于超像素分割的高光谱图像特征变换和分类算法研究 是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已经注明引用的内容外，本论文不含任何其他个人或集体已经发表或撰写的作品或成果。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本声明的法律后果由本人承担。

论文作者签名：

邓彬

日期：2018年5月15日

学位论文使用授权说明

本学位论文作者完全了解深圳大学关于收集、保存、使用学位论文的规定，即：研究生在校攻读学位期间论文工作的知识产权单位属深圳大学。学校有权保留学位论文并向国家主管部门或其他机构送交论文的电子版和纸质版，允许论文被查阅和借阅。本人授权深圳大学可以将学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文。

论文作者签名：

邓彬

导师签名：

曾志

日期：2018年5月15日

日期：2018年5月15日

摘要

高光谱图像是由成像光谱仪获取的包含几十乃至上百个连续谱段信息的数据立方体。这种三维图像具备丰富的地表空间信息和光谱信息，已被广泛应用于地表分类、目标探测、环境管理、农业监测和军事目标识别等诸多领域，为我国国民经济和国防建设等方面发挥了重要的作用。然而，分类作为高光谱图像处理和应用的一项重要技术，仍然面临着诸多问题和挑战。一方面，高光谱图像数据所呈现的高度非线性使得直接对其原始数据进行分类难以达到可观的效果；另一方面，极其有限的先验样本使得分类模型的参数难以估计准确。为了更好的解决这些问题，在基于高光谱图像特性和分析研究现状的基础上，本文重点在两个方面上研究了如何利用超像素来实现有效的小样本地物分类。

首先，在提取高光谱图像特征上，为了能够得到更加空谱一体化的特征以及充分利用这些特征信息，本文提出了一个由超像素引导的基于支持向量机的多任务学习框架。该框架在原有的薛定谔特征映射的基础上，将多组 Gabor 特征作用其中，并采用基于超像素水平的特征降维方法，从而充分挖掘了高光谱图像的空间-光谱信息，并降低了时间复杂度。在得到多组空谱一体特征之后，为了更好地利用这些特征来进行分类，本文首次采用了基于支持向量机的多任务学习方法，该方法对比于传统的基于稀疏表示的多任务学习方法，大大减少了时间复杂度。实验结果表明，对比于当前一些先进的特征提取方法，该分类框架能够提取出表征性更强的特征并能得到更高的分类精度。

另一方面，在高光谱图像分类结果决策融合上，为了能够得到更加符合地表实际情况的分类结果，本文提出了由超像素引导的基于局部二值模式 (Local Binary Pattern, LBP) 的分类方法。首先，该方法最核心部分就是能够分割出更加基于地物分布的超像素，这通过对高光谱图像的过分割以及区域合并操作完成。接着，该方法使用了统一模式的局部二值模式 (Uniform Local Binary Pattern, ULBP) 来提取纹理特征，并利用支持向量机对该特征进行预分类，得到每个像素属于每一类的概率。最后，一个基于超像素的软决策融合方法将被提出并得到最终的分类标签。实验结果表明，该方法能够在小样本的情况下得到非常好的分类效果，尤其是对于地物分布更均匀的图像。

关键词： 高光谱图像分类；小样本分类；超像素；维数降解；多任务学习；支持向量机

Abstract

Hyperspectral imagery (HSI) is a three-dimensional imagery containing tens or even hundreds of consecutive spectral bands acquired by an imaging spectrometer. This three-dimensional imagery has wealth information both in spatial and spectral, and has been widely used in many fields such as surface classification, target detection, environmental management, agricultural monitoring and military target identification. Therefore, it has played an important role in China's national economy and national defense construction. However, classification, as an important technology for hyperspectral imagery processing and application, still faces many problems and challenges. On the one hand, the high nonlinearity presented by hyperspectral imagery data makes it difficult to directly classify its raw data to achieve considerable results. On the other hand, extremely limited labeled samples make it difficult to estimate the accuracy of the parameters of the classification model. In order to tackle these problems with much better solution, based on the characteristics of hyperspectral imagery and the analysis of existing researches, this paper focuses on how to use superpixels to achieve effective small-sample classification of surface materials from two aspects.

Firstly, in order to extract features containing much richer spectral-spatial information from the hyperspectral imagery and to make full use of these features, a multi-task learning framework based on support vector machine (SVM) is proposed. On the basis of the original Schrodinger feature mapping, this framework replaces raw features with multiple sets of Gabor features and adopts a feature-based dimensionality reduction method based on the superpixel level, which fully exploits the spatial-spectral information of hyperspectral imagery and reduces the time complexity. After obtaining multiple sets of spectral-spatial features, in order to make better use of these features for classification, a multi-task learning method based on support vector machine is adopted for the first time in this paper. Compared with traditional multi-task learning methods based on sparse representation, the method proposed in this paper reduces the time complexity significantly. Experimental results show that the multi-task learning framework proposed in this paper can extract much better features and can obtain much higher classification accuracy than some current advanced feature extraction methods.

For another, in the process of decision fusion of hyperspectral imagery classification results, in order to obtain a classification result that is more consistent with the ground truth, this paper proposes a novel method based on local binary pattern (LBP) with superpixel guidance. First and foremost, the core part of this method is to be able to generate the superpixels which are consistent with the distribution of the ground truth. This can be achieved by over segmentation and region merging, which are proposed in this paper. Then, the uniform local binary pattern (ULBP) is used to extract the texture features of hyperspectral imagery and each

pixel can be pre-predicted to the probability of each class by using support vector machine. Finally, a probability-oriented classification strategy is applied to classify each pixel based on superpixel-level guidance. Experimental results have demonstrated that the proposed method is more effective and powerful than several state-of-the-art methods in the small-sample situation, especially for hyperspectral images with more evenly distributed surfaces.

Key word: Hyperspectral Imagery Classification; Small-Sample Classification; Superpixel; Dimension Reduction; Multi-Task Learning; Support Vector Machine

目录

摘要	I
Abstract	II
第 1 章 绪论	1
1.1 研究背景及意义	1
1.2 国内外研究现状	4
1.2.1 高光谱图像分类的研究现状	4
1.2.2 超像素分割的研究现状	7
1.2.3 存在的问题与挑战	9
1.3 高光谱图像分类概述	10
1.3.1 高光谱图像特性	10
1.3.2 高光谱图像分类精度评价	12
1.3.3 高光谱图像实验数据描述	12
1.4 研究内容与章节安排	15
1.4.1 研究内容	15
1.4.2 章节安排	16
第 2 章 现有的超像素分割方法及其在高光谱图像上的应用	17
2.1 超像素分割算法	17
2.1.1 SLIC 超像素分割算法	17
2.1.2 ERS 超像素分割算法	19
2.2 基于特征提取的超像素应用技术	21
2.2.1 空间-光谱薛定谔特征映射	21
2.2.2 超像素在薛定谔特征映射中的应用	22
2.3 基于超像素水平的分类方法	23
2.3.1 基于超像素均值特征的分类	23
2.3.2 基于超像素的多任务联合稀疏表示	23
2.3.3 简单的超像素融合分类方法	24
2.4 本章小结	25
第 3 章 超像素引导的特征变换及其多任务学习方法	26
3.1 Gabor 特征提取	26
3.2 超像素引导的 Gabor 特征薛定谔变换	27

3.3	基于支持向量机的多任务学习框架	28
3.4	实验结果及分析	29
3.4.1	实验设置	29
3.4.2	参数敏感度分析	30
3.4.3	实验结果	31
3.5	本章小结	38
第 4 章	超像素引导的分类决策融合方法	40
4.1	ULBP 特征提取	40
4.1.1	LBP 算子	40
4.1.2	ULBP 算子	41
4.1.3	ULBP 高光谱图像特征	42
4.2	超像素合并方法	43
4.3	基于超像素的软决策融合	45
4.4	实验结果及分析	45
4.4.1	实验设置	45
4.4.2	参数敏感度分析	46
4.4.3	实验结果	47
4.5	本章小结	52
第 5 章	总结与展望	54
5.1	本文的主要工作和创新点	54
5.2	未来的工作展望	55
参考文献	56
致谢	62
攻读硕士学位期间研究成果	63

图目录

图 1-1	高光谱遥感图像结构示意图 ^[9]	1
图 1-2	HJ-1 号卫星高光谱遥感图像成像图	3
图 1-3	高光谱图像分类技术研究现状概览	5
图 1-4	自然图像超像素分割示意图	8
图 1-5	高光谱图像地物光谱性状示例	11
图 1-6	Hughes 现象 ^[67]	11
图 1-7	Indian Pines 地面真实数据图	13
图 1-8	Salinas scene 地面真实数据图	14
图 1-9	Pavia University 地面真实数据图	14
图 2-1	k -means 和 SLIC 算法在像素聚类过程中搜索区域的实现方式	17
图 2-2	SLIC 算法聚类中心初始化示意图	18
图 2-3	ERS 算法实现示例图	20
图 2-4	S ⁴ E 特征提取流程图	22
图 2-5	基于多数表决的超像素融合方法示例图	24
图 3-1	GS ⁴ E-MTL _{SVM} 多任务学习框架系统流程示意图	29
图 3-2	GS ⁴ E-MTL _{SVM} 的分类精度随参数 m 和 K 的变化趋势	31
图 3-3	Indian Pines 数据集: 每类 5 个训练样本的分类结果图	32
图 3-4	Indian Pines 数据集: 每类训练样本数对分类结果的影响	34
图 3-5	Salinas 数据集: 每类 5 个训练样本的分类结果图	35
图 3-6	Salinas 数据集: 每类训练样本数对分类结果的影响	37
图 3-7	PaviaU 数据集: 每类训练样本数对分类结果的影响	37
图 3-8	PaviaU 数据集: 每类 5 个训练样本的分类结果图	38
图 4-1	原始 LBP 值的定义	40
图 4-2	几种不同 P, R 值对应的圆环形领域	41
图 4-3	ULBP 在高光谱图像单波段上的特征提取过程示例	42
图 4-4	ULBP-SPG 框架示意图	44
图 4-5	直方图统计块大小对总分类精度的影响	46
图 4-6	ULBP-SPG 的分类精度随参数 K 和 M 的变换趋势	47
图 4-7	Salinas 数据集: 每类 10 个训练样本的全像素分类结果图	48
图 4-8	Salinas 数据集: 每类训练样本数对分类结果的影响	50

图 4-9	Indian Pines 数据集：每类训练样本数对分类结果的影响	50
图 4-10	Indian Pines 数据集：每类 10 个训练样本全像素分类结果图	51

表目录

表 1-1	几种广泛使用的高光谱成像仪的主要技术参数 ^[15]	4
表 1-2	Indian Pines 数据地物类别情况	13
表 1-3	Salinas scene 数据地物类别情况	13
表 1-4	Pavia University 数据地物类别情况	14
表 3-1	实验中的一些参数设置值	30
表 3-2	Indian Pines 数据集：每类 5 个训练样本的分类精度表 (%)	33
表 3-3	Salinas 数据集：每类 5 个训练样本的分类精度表 (%)	36
表 3-4	PaviaU 数据集：每类 5 个训练样本的分类精度表 (%)	39
表 3-5	7 个方法的平均运行时间 (秒)	39
表 4-1	Salinas 数据集：每类 10 个训练样本的分类精度表 (%)	49
表 4-2	Indian Pines 数据集：每类 10 个训练样本的分类精度表 (%)	52

第 1 章 绪论

1.1 研究背景及意义

遥感是 20 世纪 60 年代发展起来的对地观测综合性技术^[1]，随后成为一门新兴的交叉科学技术并得到了迅速的发展。到了 20 世纪 80 年代，成像光谱技术 (Imaging Spectroscopy) 取得了重大突破^[2]，从此光学遥感开始进入高光谱遥感 (Hyperspectral Remote Sensing) 阶段。自从进入高光谱遥感阶段之后，人们对地观测与认识事物的能力发生了跨越式的进步。过去几十年间，遥感对地观测系统上所搭载的成像光谱仪 (Imaging Spectrometer) 采集的遥感图像 (Remote Sensing Images) 的光谱分辨率得到极大提高。高光谱遥感图像的光谱分辨率极高，其光谱成像可精确到纳米级别，因此其成像光谱通道通常高达几十乃至上百个。高光谱遥感图像极高的光谱分辨率使得其可以提供包含丰富的反映地物特有物理性质的光谱信息，同时还可以反映出地表物质的空间结构分布。由此，蕴含丰富的空间 - 光谱信息的高光谱图像在对地表物质进行精准检测和分析的一系列应用得到了广泛的推广。在这个信息化的时代，作为一种认知世界的有效手段，高光谱遥感技术已经与人类的工作和生活紧密联系起来，在气候预测^[3]、城市分类^[4]、林业检测^[5]、矿物勘探^[6]、农业^[7] 以及军事现代化建设^[8] 等诸多领域中发挥着举足轻重的作用。




图 1-1 高光谱遥感图像结构示意图^[9]

高光谱遥感图像之所以具备如此高的光谱分辨率，是因为其在波长方向上的记录宽度之多 (波长宽度也称为波段宽度)，记录的波段数越多，其光谱分辨率就越高。因为能够成像的波段数量多，而且其往往是连续的，因此，成像光谱仪在采集高光谱图像的时候，能够以相同的空间分辨率对每个波段形成一个平面图像，从而蕴含了丰富的空

谱信息，这些平面图像按波段顺序叠合在一起便构成了高光谱图像立方体，也即是高光谱遥感图像。对高光谱图像的每一个像元而言，其在每一个波段都有一个光谱辐射值，因此每一个像元都能按波段顺序形成一条光滑的曲线。理论上，不同的物质对光谱反射的程度不一样，因此将会得到完全不一样的光谱曲线^[10]。如图 1-1 所示展现了高光谱图像的结构信息，从图中可以看出，不同的物质对应不同的光谱特征。正是高光谱图像所具备的这种特性，使得其为地物分类和检测奠定了基础。

高光谱图像的广泛应用与成像光谱仪的快速发展密切相关。早在 1983 年，全球第一台成像光谱仪 AIS-1 (Aero Imaging Spectrometer-1, 航空成像光谱仪) 就在美国宇航局某实验室研制成功，并在许多应用领域如矿物填图、植物分类等方面中取得了成效。随后在 1987 年，该实验室在此基础上又研制出了第二台成像光谱仪 AVIRIS (Airborne Visible/Infrared Imaging Spectrometer, 航空可见光、红外光成像光谱仪)，其成像光谱范围为 0.4-2.5 μm ，共有 224 个光谱波段，光谱分辨率为 10nm。AIS-1 和 AVIRIS 的成像技术与当初雷达技术一起被称为是自遥感技术问世以来最重大的两项技术突破，并为高光谱遥感技术的发展和推广起到了极大的推动作用^[10]。

自 AVIRIS 问世之后，为了提高成像光谱仪收集技术水平，在美国海军空间与作战系统指挥部的发起下，又成功研制了一种新一代的、定标完好的高光谱成像光谱仪 HYDICE (Hyperspectral Digital Imagery Collection Experiment, 高光谱数字影像采集实验仪)。HYDICE 的诞生大大增强了空间信息的采集，其光谱测量范围与 AVIRIS 相同，但采用 CCD 推扫式技术成像，空间分辨率最高可达仅为 0.75m，拥有 210 个光谱波段。在 2000 年，高光谱成像卫星 Hypersion 在美国发射成功，成为世界上第一颗实用的星载高光谱卫星，其光谱成像范围与光谱分辨率都与 AVIRIS 成像光谱仪相同。

除了美国之外，还有很多发达国家也相继投入资金研制高光谱成像仪。其中具有代表性的有加拿大的荧光成像光谱仪 FLI 和小型机载成像光谱仪 AIS，及其 ITRES 公司推出的 CASI、SASI、TABI 系列产品；还有德国研制的反射式成像光谱仪 ROSIS；澳大利亚 Integrated Spectronics 公司研制生产的高光谱制图仪 (Hyperspectral Mapper, HyMap) 以及荷兰的 CAESAR 等。表 1-1 列出了 5 种比较广泛采用的高光谱成像仪的主要规格参数。到目前为止，全球大约有 60 多种成像光谱仪被成功研制并分布在 10 多个不同的国家之中。

我国在高光谱成像光谱技术上的研究也紧跟世界的步伐，在诸多方面上取得了稳步的进展^[11]。我国的成像光谱发展始于 20 世纪 80 年代中期的黄金找矿热潮^[12]，并开辟了国际上地矿遥感的研究领域。随后于 1986 年和 1987 年相继自主研发的红外细

分多光谱扫描仪 (FIMS-1) 和 12 波段短波红外多光谱扫描仪 (FIMS-2) 并成功应用于对新疆西准噶尔地区的遥感飞行, 意味着我国在机载准成像光谱技术和应用上得到了显著突破^[11]。于此同时, 成像光谱仪的研制和应用也被列为国家的第 7 个五年计划科技攻关的主要内容之一。经过随后 3 年多的努力, 第一台具有先进水平的 64 波段可见光/近红外光模块化机载成像光谱仪 (Modular Aero Imaging Spectrometer, MAIS) 在薛永祺院士团队的努力下研制成功, 并在与日本和澳大利亚的合作中取得了一系列令人信服的成果, 使我国在国际上成像光谱领域中占有重要的一席。随后, 我国又研制成功了推扫式成像光谱仪 (Pushbroom Hyperspectral Imaging, PHI), 该光谱仪包括 244 个波段, 光谱成像范围为 $0.40\text{-}0.85\mu\text{m}$ 。在 MAIS 的基础上, 1999 年, 实用型模块化机载成像光谱仪 (Operational Modular Imaging Spectrometer, OMIS) 在中科院研制成功, 它包括有 128 波段的 OMIS1 和 68 波段的 OMIS2 两个型号。OMIS 和 PHI 是我国极具代表的两个成像光谱仪, 代表了当初的亚洲水平, 在国际上也占据了一席之地。




图 1-2 HJ-1 号卫星高光谱遥感图像成像图

在航空遥感技术取得显著进步的同时, 我国在航天高光谱遥感方面也取得了蓬勃的发展。在 2002 年 3 月, 我国发射的神舟 3 号无人飞船中就搭载了一个中分辨率的成像光谱仪 (China Moderate Resolution Imaging Spectroradiometer, CMODIS), 它有 34 个波段, 波长范围在 $0.4\text{-}12.5\mu\text{m}$ 。CMODIS 的成功升空标志着我国成为世界上第二个掌握并拥有航天成像光谱仪技术的国家^[13]。此外, 在 2007 年发射的嫦娥一号探月卫星以及 2008 年发射升空的环境与减灾小卫星 (HJ-1) 中也分别搭载了高光谱成像光谱仪, 如图 1-2 显示了其高光谱成像图之一。另外, “风云 -3” 卫星也投入气象预测观察中, 在气象预报上发挥显著作用。我国成像光谱仪在各个领域上的广泛以及成功的应用, 标

表 1-1 几种广泛使用的高光谱成像仪的主要技术参数^[15]

	AVIRIS	HYDICE	HyMap	Probe-1	Hyperion
完成时间	1987	1995	1996	1997	2000
平台	机载	机载	机载	机载	星载
拍摄高度 (km)	20	6	5	2.5	705
空间分辨率 (m)	20	3	10	5	30
光谱分辨率 (nm)	10	3~20	17	11~18	10
光谱范围 (μm)	0.4~2.5	0.4~2.5	0.4~2.5	0.4~2.5	0.4~2.5
波段数	224	210	128	128	220
扫描带宽 (km)	12	0.9	6	3	7.7

志我国在高光谱遥感领域上已经跻身于世界前列^[13]。

高光谱图像的应用研究和成像光谱仪的发展总是相辅相成，因为对高质量高分辨率的高光谱图像的渴求激发了越来越先进的成像光谱仪的诞生，而这些先进的成像光谱仪也带了丰富的高光谱数据，从而高光谱遥感技术的理论和应用研究也逐渐的活跃起来。由于高光谱遥感图像的高光谱分辨率以及图谱合一的独特优势，因此受到很多来自国内外科学学者的关注。目前，高光谱遥感图像的应用领域已经涵盖了地球科学的各个方面，成为地质制图、植被调查、农业遥感、海洋遥感、大气研究、环境监测等领域的有效技术手段^[11]。高光谱图像分类作为高光谱遥感图像处理和应用技术的主要内容之一，发挥着巨大的意义^[14]。

1.2 国内外研究现状

1.2.1 高光谱图像分类的研究现状

高光谱图像分类是高光谱遥感影像应用的主要实现技术之一。不同于自然图像的分类，高光谱图像分类的对象是对图像中的每一个像元进行的，目的是给所有像元都预测为一个指定的标签。研究和实践表明，高光谱图像分类实际上跟当前机器学习、计算机视觉和模式识别理论与方法具有紧密连接，图 1-3 粗略地显示了高光谱图像分类技术的研究现状。在传统的高光谱图像分类中，其研究内容主要集中在两个方面：特征提取以及分类器的设计。

在特征提取方面上，经历了从光谱特征提取到空间-光谱特征提取的阶段。光谱特征提取又根据是否改变原始光谱空间，分为特征提取^[16]和波段选择^[17]。此外，特征挖掘 (Feature mining) 的概念^[18]也被提出，作为一种新型的重构特征的提取方式，但并没有得到广泛应用。特征提取大多是基于统计的方法，关键是如何构建合适的变换矩阵，以将光谱特征映射到另一个更具表征性的空间上。根据是否使用先验样本信息，特征

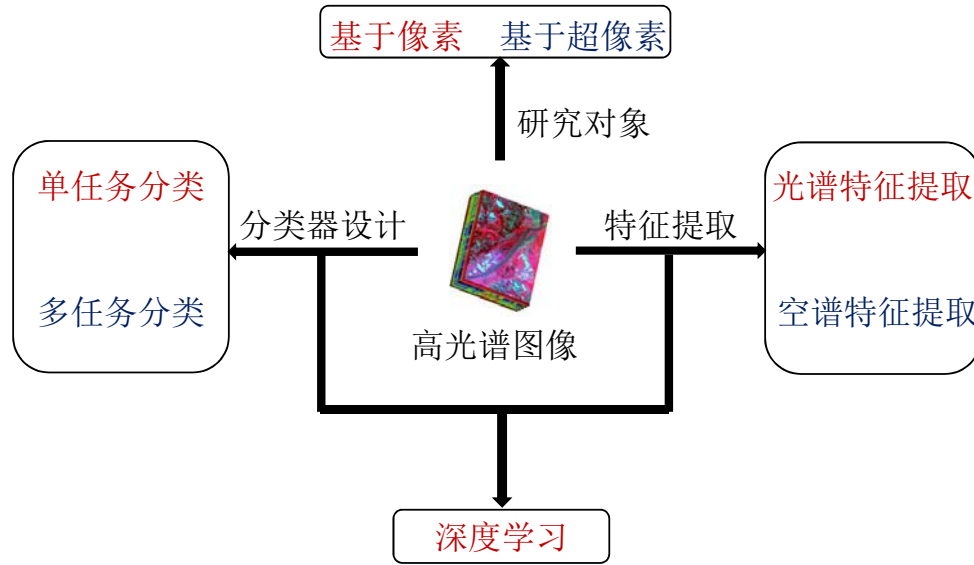


图 1-3 高光谱图像分类技术研究现状概览

提取又可分为监督特征提取、非监督特征提取和半监督特征提取。

经典的监督特征提取有基于构建类别可分性函数的线性判别分析 (LDA)^[19] 和典型相关分析 (CA)^[20] 等；基于核函数的泛化判别分析 (GDA)^[21] 和核局部 Fisher 判别分析 (KLFDA)^[22] 等；基于正则化技术的非参数特征提取 (NWFE)^[23] 等。

在非监督特征提取中，使用最为广泛的有主成分分析 (PCA)^[24] 和独立成分分析 (ICA)^[25] 等。PCA 是一个典型的特征降维方法，它是一个线性变换，通过保留数据中对方差贡献最大的特征来实现数据降维。ICA 要求分离结果彼此相互独立，实际上可以看成是 PCA 方法的扩展，它们已经被广泛的用于高光谱图像分类中^[9]。最近，流行学习的特征提取方法也受到了广泛的关注。杜培军等^[26] 把光谱角和光谱信息散度与测地距离结合起来，有效的利用了基于稀疏图的流行学习方法进行了特征提取。拉普拉斯特征映射 (Laplacian Eigenmap)^[27] 是流行学习方法中特征变换的典范，也被成功的应用于高光谱图像的特征提取当中^[28]，并得到了研究者的极大兴趣。但因为流行学习主要是基于构建图的方法，其计算复杂度往往很高。

一些半监督的特征提取方法也被提出，其目的是为了充分利用有限的训练样本以及非训练样本的信息来提取出有用的特征以改善学习性能。这些方法主要有成对约束法^[29]、对偶几何子空间^[30] 以及半监督局部判别分析^[31] 等。

波段选择是光谱特征提取中通过选择一些子波段的方法来实现的特征选择方法，这种方法的优点在于保留了各个波段的物理特性，通过波段选择可以削弱波段之间的相关性，使得提取出来的波段子集更容易分类。波段选择主要有基于滤波器型的波段

选择方法以及基于封装型的波段选择方法, 分别取决于是否根据分类性能作为测度来进行选择。基于滤波器型的波段选择方法更流行, 其波段选择的过程跟分类的过程是独立的, 如 Jia 等^[32]提出的基于排序聚类的波段选择方法采用了聚类的思想, 其完全是非监督的。还有一些利用了训练样本来构建目标函数的波段选择方法, 最为典型的就是基于 JM (Jeffreys Matusita Distance) 距离的方法^[19,33]。

由于高光谱图像所具备的空域特性, 仅仅采用基于光谱特征的提取方法未能考虑空间信息, 使得其分类结果往往存在椒盐现象, 这与实际的地表分布不相符, 为更好的解决这个问题, 很多基于空间-光谱特征提取的方法被提出, 并迅速成为当今高光谱图像特征提取的主要趋势^[14]。采用灰度共生矩阵 (Gray Level Co-occurrence Matrix, GLCM) 纹理特征提取的方法是最早应用于高光谱图像空谱特征提取的算法之一。GLCM 算法首先被应用在多光谱图像中用于云层分类^[34], 后面 Tsai 等人^[35]将其用于高光谱图像特征提取中, 并取得了良好的分类效果。另一种纹理特征提取: 局部二值模式 (Local Binary Patterns, LBP) 也在高光谱图像空谱特征提取中得到了广泛的应用^[36,37]。除了纹理特征提取之外, 理论成熟的小波变换以及 Gabor 变换也在高光谱图像空谱特征提取中占据一席之地。早在 2002 年, Bruce 等人^[38]就利用了小波变换的思想在高光谱图像中提取空谱特征, 并成功地应用于农业植被分类中。Shen 等人^[39]将小波变换扩展到 3D, 利用三维的 Gabor 变换得到了一系列不同频率和方向的 Gabor 滤波器, 并利用这些滤波器对高光谱图像提取了多组特征并得到了显著的分类性能。在高光谱空间-光谱特征提取里面, 基于形态学特征 (Morphological Profile, MP) 提取的方法曾受到研究学者的广泛关注。该方法首先在 2001 年由 Plaza 等人^[40]应用于高光谱图像特征提取中, 后面该方法被扩展和改善为 EMP (Extended Morphological Profiles)^[41] 和后来的 EAP (Extended Attribute Profile) 以及 EMAP (Extended Multi-Attribute Profile)^[42]。

最近, 利用超像素辅助来进行特征提取的方法也成为高光谱图像空谱特征提取的重要手段。在高光谱遥感图像中, 由于地物的分布往往是成块存在的, 这意味着相邻的像素属于同一类的概率很大。因此, 考虑先将图像聚成若干个超像素, 使得每个超像素尽可能同质, 然后充分利用这种空间局部信息来建立特征提取的方式得到了广泛的应用。最简单的直接求取每个超像素内所有像素的均值作为该超像素内所有像素的特征^[43], 然后通过极限学习机 (Extreme Learning Machine, ELM) 分类器后也能得到很好的分类效果。Li 等人^[44]基于超像素构建的多任务联合稀疏表示方法虽然没有直接提取特征, 但却间接的利用了超像素信息, 使得其隐含特征具备更丰富的空间局域性。Fang 等人^[45]提出了利用超像素均值特征并通过赋予其不同的权值从而提取出多组特征

并构建多核的方法。此外, Zhang 等人^[46]使用基于超像素水平的特征降维方法, 大大的降低了基于像素级特征提取方法的时间复杂度。

在分类器的设计方面上, 经历了从典型的光谱角匹配 (Spectral Angle Mapper, SAM)^[47] 和光谱信息散度 (Spectral Information Divergence, SID)^[48] 到基于统计的分类方法的过渡。目前, 大部分研究方法主要是基于统计的理论, 在这些方法中, 除了单任务地使用一些传统的分类器如 k 最近邻 (k -Nearest Neighbors, KNN)、支持向量机 (Support Vector Machine, SVM) 和基于稀疏表示的分类 (Sparse Representation-Based Classification, SRC) 等外, 最近, 多任务学习 (Multi-Task Learning, MTL) 分类也在高光谱遥感图像中得到了广泛的应用^[49]。多任务学习通过组成或复合多个单任务分类结果来进行最终的决策, 主要表现在三种策略上: 基于不同样本构建的如 AdaBoost-CART 算法^[50]; 基于不同数量分类器构建的如 Su 等^[51] 提出的集成空间 - 光谱的动态分类器算法; 基于不同特征集构建的如多任务联合稀疏表示分类算法^[44]。

除了传统的将特征提取和分类器分离的方法之外, 最近, 将特征提取与分类集成一体的端到端的深度学习 (Deep Learning) 也在高光谱图像分类中火热起来。深度学习首先在计算机视觉领域取得了前所未有的巨大成效, 引发了所有研究识别算法的科研人员的极大关注, 并相继将其应用于各自领域, 使得深度学习现在已经成为机器学习、计算机视觉乃至人工智能领域的主流^[52]。首先应用在高光谱图像分类中使用自编码器 (Autoencoder) 来提取特征^[53], 后面 1D CNN (Convolutional Neural Network)^[54]、2D CNN^[55]、3D CNN^[56] 乃至 RNN (Recurrent Neural Network)^[57] 的研究也相继出现。但由于高光谱图像极其有限的先验样本以及深度学习对样本规模的要求极高的矛盾使得深度学习在高光谱图像小样本分类中受到阻碍。

1.2.2 超像素分割的研究现状

超像素就是许多相邻的能够反应同一物质特性的像素凝聚在一起构成的像素块。如图 1-4 显示了超像素分割在彩色图像中的示意过程。因为超像素所具备的这种同质特性, 使得其受到高光谱图像分类的研究者们的极大兴趣。因为高光谱图像的分类是对每一个像元进行分类的, 如果能够借助超像素的这种局部性质, 则可以为其提供丰富的空域结构信息。目前, 几乎所有超像素分割的算法都是在自然图像上进行的, 而针对高光谱图像的超像素分割算法大都是这些算法直接或间接的应用。所以, 在这里本文对目前自然图像的超像素分割算法的研究现状进行一个简单的回顾。现有的超像素分割算法可以大概的分为两类: 基于图的分割算法以及基于梯度下降的分割算法。

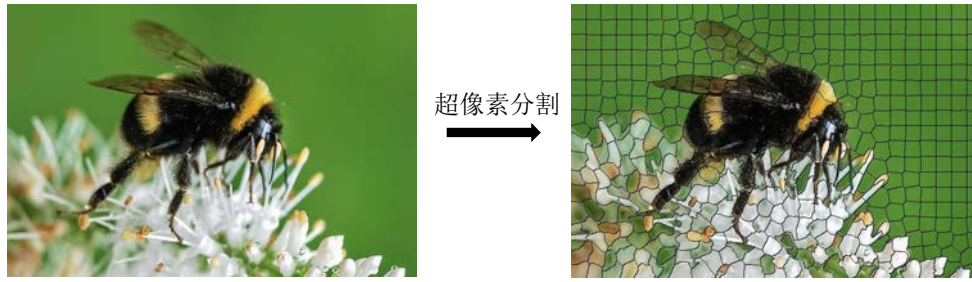


图 1-4 自然图像超像素分割示意图

(1) 基于图的分割算法

在基于图的分割算法中，每个像素将被看成图的一个顶点，而图的边的权值则代表了连接这两个顶点之间的相似度。其核心要素是通过构建一个目标函数，并优化这个目标函数使得这个图最终被切割成多个子图，而每一个子图就代表了一个超像素。

最早的经典的图割算法是由 Shi 等人^[58]提出的 Ncut (Normalized Cuts) 方法。该方法在轮廓和纹理上对图像构建优化函数，通过优化该函数达到切割的目的。Ncut 算法的优点是可以控制生成超像素的数量，形状也比较规则和紧凑，缺点是边缘贴合度 (Boundary Adherence) 不高，而且其复杂度很高，随着图像的增大，其计算速度变得很慢，因此不适合用于大尺寸图像分割。

Felzenszwalb 等人^[59]提出的 Graph-based 算法采用了最小生成树的思想，通过将图上的顶点进行聚类来实现，使得同一区域的像素尽可能相似，不同区域的像素尽可能相异，最后每一个超像素对应于每一个区域的最小生成树。该算法的优点是运算速度较快，缺点是不能控制超像素的个数以及紧凑度。

Moore 等人^[60]提出的 Superpixel Lattices 算法增加了图像拓扑信息的约束，通过寻找最优路径的方式，该算法分别在垂直和水平两个方向上将图像进行分割，优点是能够控制超像素的个数，但该算法的输入是图像的边缘图，因此分割结果对其质量的依赖性较强。

Liu 等人^[61]提出的基于熵率的超像素分割算法 ERS (Entropy Rate Superpixel Segmentation) 采用了一种由随机游走的熵率函数和平衡项函数两部分组成的目标代价函数。优化熵率函数的目的是使得分割的超像素形状结构较为紧凑、均匀而且边缘贴合度较强，而优化平衡项函数则使得获得的超像素具有相似的大小。该算法最后通过贪心算法进行优化，能够生成确定数量的大小相似、紧凑以及边缘贴合度较强的超像素。

(2) 基于梯度下降的分割算法

基于梯度下降的算法在生成超像素时通过采用梯度下降的方法进行优化，通过不

断地迭代更新聚类，直到最后收敛。

最早被广泛应用的基于梯度下降的图像分割算法是 Vincent 等人^[62]于 1991 年提出的分水岭 (Water Shed) 算法，其基本思想是把图像看作是地表的真实分布，灰度值代表着海拔高度，而分水岭就如同那些不同盆地之间的山脉。分水岭算法计算速度快，但生成的超像素边缘贴合度和紧凑度都很低，而且容易出现严重的过分割现象。

Comaniciu 等人^[63]基于早期 Mean-shift 算法的思想，提出了一种无参数的、基于核密度梯度估计的快速统计迭代算法。该算法基于密度函数将密度相似的点聚合在一起构成超像素，其优点是抗噪性能和边缘贴合度较好，缺点是超像素不紧凑和规则。

Levinshtein 等人^[64]提出的 Turbopixel 算法是一种基于网格思想的算法，通过将图像划为网格形并基于水平流划分成超像素。该算法生成的超像素能够保持图像的局部边界，运算速度也很快，但生成的超像素规则性欠佳。

最近，较为流行的超像素分割算法是由 Achanta 等人^[65]提出的简单线性迭代聚类 (Simple Linear Iterative Clustering, SLIC) 算法。SLIC 算法思想简单，容易实现，而且极其快速，它的实现可以看作是带窗的 k -means 聚类过程。实验表明，对比于其它基于梯度下降的方法，这种方法能够生成更为紧凑和边缘附着性更好的超像素。

Chen 等人^[66]将 Ncut 算法的基本原理同 SLIC 结合起来，提出了一种新的 LSC (Linear Spectral Clustering Superpixel) 超像素分割算法。实际上，LSC 可以看成是换了一种距离测度的 SLIC 算法的变形，在某些条件下也能得到与之类似的效果。

1.2.3 存在的问题与挑战

尽管当前对高光谱图像的研究已经紧跟机器学习、计算机视觉和人工智能领域的步伐，但由于高光谱图像所具备的独特特性，使得其存在的问题依然突出，具体表现在以下三个方面上：

(1) 高光谱图像先验样本的不足与当前大多数研究需要使用大量训练样本之间的矛盾。在高光谱图像中，获取先验样本的代价及高，使得其无法得到充足的训练样本，但是通过对上述高光谱图像分类的研究现状中发现，大多数方法 (特别是深度学习) 都使用的大量的训练样本，这与实际问题是互相矛盾的。能够提出在小样本场景下的有效分类具有其必要性和实用性。

(2) 时间复杂度过高的问题。高光谱图像数据所具备的高维非线性结构以及像元混合的特性，使得很多分类算法无法达到有效的分类精度，为了解决这个问题，一些新的算法如流行学习的方法等被提出，对这个问题得到了比较好的改善，但是也带来了

时间复杂度过高的问题。时间复杂度过高严重限制了对大规模图像的实时处理，因此，更多时间上有效的分类算法需要得到补充。

(3) 空间信息没有得到充分的挖掘。高光谱遥感图像实际上是对地表物质的成像，而地表的分布往往具有局部规则性的，比如下面有一片建筑，那么这片建筑所对应的像元应该都属于同一类，因此，能够充分挖掘其地表分布的空域信息具备很高的潜在价值，如果只针对其像元进行分类，则没有充分的利用其地表空间分布的信息。目前很多超像素分割方法的提出对其空间分布信息的挖掘具有很大帮助，但是这些超像素方法都是针对自然图像所提出的，而针对高光谱图像的超像素分割算法则寥寥无几。

1.3 高光谱图像分类概述

不同于自然图像的分类，高光谱图像的分类是针对每一个像元的。这意味着高光谱图像的分类只在一张图像上进行，其最终结果是给图像中的每一个像元都赋予一个唯一的标签。能够对每个像元进行分类是因为每个像元在高光谱图像中都富含着丰富的光谱信息(通常包含上百个波段光谱信息)，但除此之外，高光谱图像还具备很多其他特性，了解这些特性是对其进行分类研究的基础。下面简单介绍了高光谱图像的一些显著特性，并给出了分类结果优良的评价指标，最后描述了本文实验所用到的基准图像。

1.3.1 高光谱图像特性

近几十年来，随着成像光谱仪的不断发展，其采集的高光谱遥感图像包含了越来越丰富的空间、辐射和光谱信息。这使得高光谱图像的特性显得越发明显，主要分别体现在以下几个方面上：

(1) 高光谱分辨率且高度非线性。高光谱图像是由成像光谱仪获取的具有数十乃至上百个光谱通道的三维数据，其成像光谱范围覆盖了整个可见光、以及人眼不可见的近红外、短波红外和热红外等区域。由于光谱维度连续且成像范围广，因此对其具备很高的光谱分辨率。同时，由于成像时受到很多因素的干扰，比如受光照、气候变化、云层厚度等的影响，使得采集的图像数据往往具有高度非线性的特点。这种高度非线性也会引发“同物异谱”和“异物同谱”的特点，如图 1-5 所示，大豆和建筑、树木之间有时会出现几乎一样的光谱曲线，而同样的干草，在不同环境下的成像也具有很大差异。这些特性都为其分类任务增加了难度。

(2) 图谱合一。成像光谱仪在对地成像时，同时采集了地物的空间信息和光谱信息。在图像空间上，提供了地物类别的位置信息及其上下文信息；在光谱空间上，成

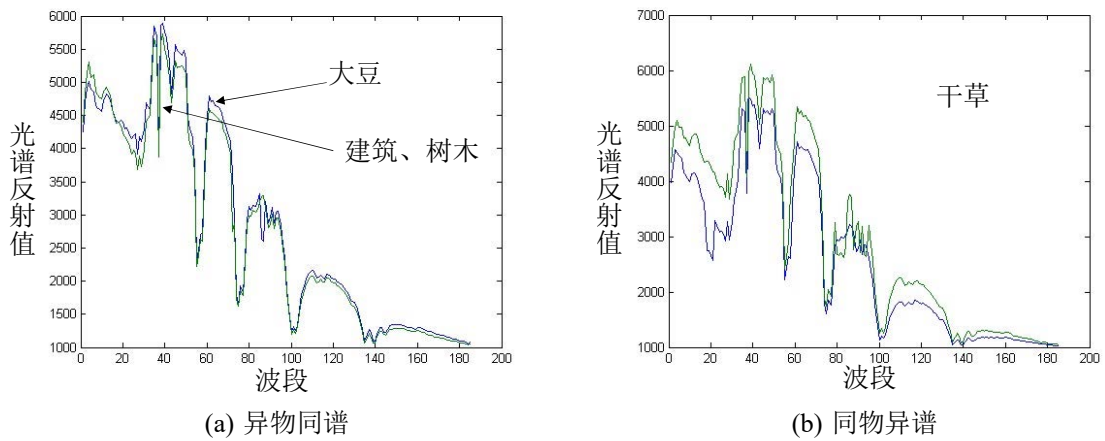


图 1-5 高光谱图像地物光谱性状示例

十上百的光谱波段数据使得每个图像像素在光谱维度上都呈现出一条连续的光谱曲线。高光谱图像的这种特性为识别地表物质提供了丰富的空间-光谱信息，是实现其有效分类的有力工具。




图 1-6 Hughes 现象^[67]

(3) 标记样本稀缺。由于采集标记的训练样本代的价极其昂贵而且困难，因此要获取足够多的标记样本往往不可行。高光谱图像稀缺的标记样本，加上其高维非线性特性，使得其在分类任务中容易引发 Hughes 现象^[67]。如图 1-6 显示了 Hughes 现象在分类精度、维度以及样本数量上所表现出来的关系，可以看到，在稀缺样本数量的情况下，其分类精度随着维度的增加先提高后逐渐下降。这使得高光谱图像在小样本分类中存在性能瓶颈。

1.3.2 高光谱图像分类精度评价

在进行高光谱图像分类后，需要对其分类结果的优良进行评价，因此，需要一个客观的评价指标来反映其分类性能。通常的分类结果评价指标有：总体分类精度 (Overall Accuracy, OA)，平均分类精度 (Average Accuracy, AA)，具体类别的分类精度 (Class-Specific Accuracy, CA) 以及 Kappa 系数 (κ)。在计算这些评价指标时，通常借助混淆矩阵 (Confusion Matrix)^[68] 来完成。假设混淆矩阵 \mathbf{M} 是一个 $C \times C$ 的矩阵， C 是类别数量，其中 \mathbf{M}_{ij} 表示类别为 i 的测试样本被分类到类别 j 的个数，则总测试样本个数 $N = \sum_i^C \sum_j^C \mathbf{M}_{ij}$ ，从而有：

(1) 总体分类精度 OA:

$$OA = \frac{\sum_i^C \mathbf{M}_{ii}}{N} \times 100\% \quad (1.1)$$

(2) 具体类别的分类精度 CA:

$$CA_i = \frac{\mathbf{M}_{ii}}{\sum_j^C \mathbf{M}_{ij}} \times 100\% \quad (1.2)$$

(3) 平均分类精度 AA:

$$AA = \frac{\sum_i^C CA_i}{C} \times 100\% \quad (1.3)$$

(4) Kappa 系数 κ :

$$\kappa = \frac{N \times \sum_i^C \mathbf{M}_{ii} - \sum_i^C (\sum_j^C \mathbf{M}_{ij} \times \sum_j^C \mathbf{M}_{ji})}{N^2 - \sum_i^C (\sum_j^C \mathbf{M}_{ij} \times \sum_j^C \mathbf{M}_{ji})} \quad (1.4)$$

1.3.3 高光谱图像实验数据描述

在这一节中，我们描述了在本文实验中所使用的三个高光谱图像分类基准图像，分别是 Indian Pines, Salinas scene 以及 Pavia University 数据，他们在高光谱图像分类中被广泛使用，因此有利于重复实验和不同的算法比较。

(1) Indian Pines 数据集

Indian Pines 数据集是由 AVIRIS 高光谱传感器在 1992 年印第安纳的西北部所采集的高光谱图像数据。该高光谱图像是公开的基准高光谱图像数据，其空间分辨率为 20m，空间维度为 145×145 以及总共 224 个波段。除去 4 个零波段和 35 个被大气

表 1-2 Indian Pines 数据地物类别情况

类别	地物类型	样本数
C1	石/钢塔	95
C2	干草/料堆	489
C3	玉米幼苗	834
C4	未耕大豆地	968
C5	苜蓿草	54
C6	整过的大豆地	614
C7	草地/牧场	497
C8	木柴	1294
C9	建筑/草地/机器	380
C10	修建过的草地/牧场	26
C11	玉米	234
C12	燕麦	20
C13	未耕玉米地	1434
C14	大豆幼苗	2468
C15	草/树	747
C16	小麦	212
	样本总数	10366

表 1-3 Salinas scene 数据地物类别情况

类别	地物类型	样本数
C1	椰菜绿色杂草 1	2009
C2	椰菜绿色杂草 2	3726
C3	休耕地	1976
C4	粗犁休耕地	1394
C5	平整休耕地	2678
C6	残株	3959
C7	芹菜	3579
C8	野生葡萄	11271
C9	葡萄园培植土壤	6203
C10	老玉米绿色杂草	3278
C11	四星期罗马生菜	1068
C12	五星期罗马生菜	1927
C13	六星期罗马生菜	916
C14	七星期罗马生菜	1070
C15	野生葡萄园	7268
C16	葡萄架	1807
	样本总数	54129

层或水吸收的波段，最终得到 185 个波段。该图像包含 10366 个有标签的样本和 16 类地物类别。该数据的所有样本标记图如图 1-7 所示，表 1-2 显示了各个类别样本数量的分布。




图 1-7 Indian Pines 地面真实数据图

(2) Salinas scene 数据集

第二个高光谱图像数据集也是由 AVIRIS 传感器所采集的，其地点位于美国加利福尼亚州的萨利纳斯山谷。Salinas scene 图像具有很高的空间分辨率，每个像素只有 3.7m 宽，其原始大小为 $512 \times 217 \times 224$ ，其中 224 是光谱波段数。在实验中，去除了 20 个被水吸收的波段，余下的 204 个波段的图像将用于分类。该图像包含 54129 个样本像素和 16 类地物种类，如图 1-8 显示了其地物种类的分布，表 1-3 描

表 1-4 Pavia University 数据地物类别情况

类别	地物类型	样本数
C1	沥青路	6631
C2	草甸	18649
C3	碎石	2099
C4	树木	3064
C5	金属板	1345
C6	裸土	5029
C7	沥青	1330
C8	砖块	3682
C9	阴影	947
	样本总数	42776

述了其各类地物的样本个数。



图 1-8 Salinas scene 地面真实数据图




图 1-9 Pavia University 地面真实数据图

(3) Pavia University 数据集

第三个高光谱图像数据集是 Pavia University，它是由 ROSIS-3 传感器在 Pavia 大学采集的，图像空间大小为 610×340 。与 Indian Pines 和 Salinas scene 数据类似，去除 12 个噪声波段后，余下的 115 个光谱波段图像将用于本文的实验中。在这三个数据中，Pavia University 的空间分辨率最高，达到 1.3m。该图像共包含 9 类地物类别和 42776 个标签样本，它们的细节信息如图 1-9 和表 1-4 所示。

1.4 研究内容与章节安排

1.4.1 研究内容

(1) 超像素引导的高光谱遥感图像特征提取方法研究

考虑到高光谱遥感图像空谱信息的丰富性，为了充分利用高光谱遥感图像的空谱信息，本文将超像素信息引进来辅助提取具备空谱一体化的特征。本文研究重点借助于超像素信息来对高光谱遥感图像进行特征提取。一方面，本文利用目前存在的基于超像素提取特征来进一步扩展到每一个像素上的方法，从而明显降低原特征提取算法的时间复杂度。另一方面，由于这样提取的特征使得光谱特征弱化，本文提出了采用多组 Gabor 特征多任务学习框架最终综合决策的方法来弥补这一不足。该算法框架的相关工作已经被遥感信息处理的国际权威期刊 *IEEE Transactions on Geoscience and Remote Sensing* 发表。

(2) 基于高光谱遥感图像的超像素分割方法研究

针对目前高光谱遥感图像的超像素分割大都基于自然图像的超像素分割方法而不能充分利用高光谱图像的丰富信息，从而无法保证超像素的基于对象性这一不足，本文将自然图像的超像素分割扩展到高光谱图像的情况。重点研究在高光谱图像下基于对象性的超像素分割方法。在本文中，我们使用两步来构建高光谱图像超像素分割，第一步使用自然图像的超像素分割方法对其进行初始化的超像素分割，第二步结合高光谱遥感图像定义超像素之间的相似度量，最后通过区域合并得到最终的超像素分割结果图。

(3) 超像素引导的高光谱遥感图像决策融合的分类方法研究

考虑到在高光谱图像中的领域像素之间的高度同质性，将超像素信息引进以帮助分类决策。当把高光谱遥感图像分割成若干个超像素的时候，已经能够保证在同一个超像素内的像素具有很强的同质性了，这就意味着处于同一个超像素的像素属于同一类的概率很大。同时，现有的高光谱遥感图像特征提取方法多种多样，包括 Gabor 特征提取，LBP 特征提取，形态学特征提取等等，这些方法都充分利用了高光谱遥感图像的空间或纹理信息，最终提取的特征都具备空间-光谱特性。但是这些方法对每一个像素的处理都是采用同样的领域大小，对每一个像素构造的特征都采用的是同一种方式进行，这就导致了处于类别边缘的像素特征提取结果不够理想，可以看到，通过这些方法构造的特征得到的最终分类结果的类别边缘都是非常不规则的。恰恰相反的是，超像素分割结果对类别边缘非常的敏感，往往能够在不同类别界限处分割开来，如果能

够加入超像素的信息来辅助决策融合，必定能够改善类别边缘的像素的分类结果，使得其最终边缘显著而规则。基于这个考虑，本文打算对分类结果进行决策融合。决策融合方法目前存在的是硬决策融合，它简单的把预分类结果中处于同一个超像素的类别数最多像素的那个类指定为该超像素的类别。这种基于多数表决的方法具有一定的局限性，因为它对超像素的同质性要求很高，当超像素分割结果很理想的时候，这种方法能够对分类结果得到显著的改善，但当超像素分割结果不够理想的时候，它所起到的作用就小了甚至是副作用。基于上述考虑，本文提出了一种软分类的决策融合方式，该方式通过概率的表现来决定融合该超像素的分类结果，从而能够比较起到比较鲁棒的效果。决策融合的一个关键在于超像素分割的好坏，因此，该融合效果跟基于高光谱图像的超像素分割方法紧密相关。高光谱图像超像素分割和决策融合的相关工作已经被遥感信息处理的国际权威期刊 *IEEE Transactions on Geoscience and Remote Sensing* 发表。

1.4.2 章节安排

本文章节的安排如下：

第一章，绪论。主要介绍了目前高光谱遥感发展的背景及对高光谱遥感图像分类研究的意义，并总结了当前高光谱图像分类的国内外研究现状以及超像素分割的研究现状，分析了其仍存在的问题。该部分还介绍了高光谱图像的特点、分类评价的指标以及本文使用的一些基准图像。最后简单地介绍了本文的主要研究内容和章节安排。

第二章，现有的超像素分割方法及其在高光谱图像上的应用。主要详细地给出了本文使用的当前流行的超像素分割算法包括 SLIC 和 ERS，并对跟本文相关的一些基于超像素应用于高光谱图像分类的算法进行详细描述。最后系统的回顾了目前基于超像素应用于高光谱图像分类的算法。

第三章，超像素引导的特征提取及其多任务学习方法。主要介绍了本文提出的由超像素引导的高光谱图像特征提取及多任务学习框架。首先，引入了 Gabor 特征的提取方法，然后详细的给出了基于支持向量机构建的多任务学习方法，最后是实验结果的展示和对比。

第四章，超像素引导的分类决策融合。主要介绍了本文提出的由超像素引导的高光谱图像分类决策融合框架。首先详细描述了 ULBP 特征提取算法，分析了其特征分类的结果所存在的问题。在此基础上，引入了超像素决策融合的方法，并给出了基于高光谱图像的超像素分割算法。最后，给出了一系列相关的验证实验和结果分析。

第五章，总结与展望。总结了全文的工作及主要创新点，展望未来的研究方向。

第 2 章 现有的超像素分割方法及其在高光谱图像上的应用

在上一章本文简单地回顾了当前的超像素分割方法，包括基于图论和基于梯度下降的两类算法，在这一章中，本文将分别对在这两类算法中最典型的算法进行详细地介绍。同时，我们总结了现有的超像素在高光谱图像上的应用，并详细地给出了它们当中与本文相关的算法思想。为了对本章后面的算法进行更好的描述，在这里定义了一些符号的含义。在本章中使用 $\mathbf{R} \in \mathbb{R}^{X \times Y \times B}$ 表示高光谱数据，其中 X 和 Y 是空间维度大小， B 是波段数。 \mathbf{R}_{xy} 是空间坐标位于 (x, y) 的像素点，它是一个一维向量， $\mathcal{R} = \{\mathbf{r}_i, i = 1, \dots, XY\} \in \mathbb{R}^{B \times XY}$ 是所有像素的集合，其中每一个 $\mathbf{r}_i = \mathbf{R}_{xy} \in \mathbb{R}^B, i = (x - 1) \cdot Y + y$ 代表一个具体的像素在空间坐标 (x, y) 下的光谱值向量， $\mathbf{r}_i^p = \{x; y\} \in \mathbb{R}^2$ 是空间值向量。

2.1 超像素分割算法

目前的超像素分割算法几乎是全部针对自然图像所提出的，在基于图论的算法中，熵率超像素分割算法 (ERS) 是极其典型的，而在基于梯度下降的算法中，最为典型的应该是简单线性迭代聚类算法 (SLIC)，下面本文将对这两个算法进行详细地描述。

2.1.1 SLIC 超像素分割算法

SLIC 是一个简单，容易理解的超像素分割算法，其实现可以看做是一个带窗的 k -means 聚类过程^[65]。如图 2-1 展示了 k -means 和 SLIC 聚类算法在聚类过程中像素搜索的不同之处，显而易见 SLIC 在搜索区域时限制在一个带窗的区域上，这不仅体现了超像素所要求的局部性，而且大大提高了算法的时间效率。

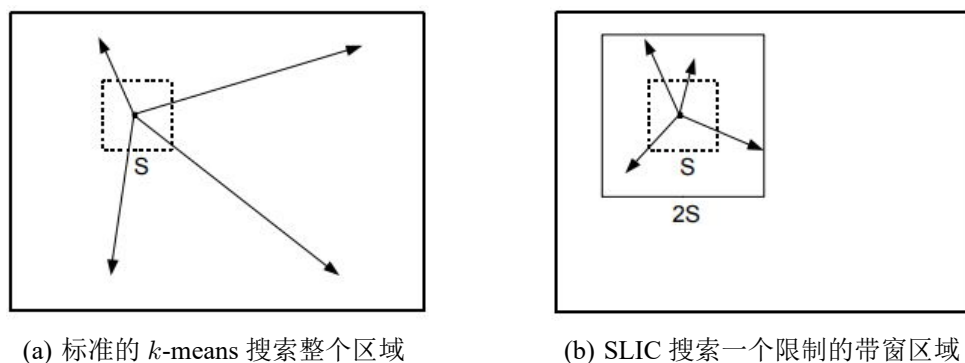


图 2-1 k -means 和 SLIC 算法在像素聚类过程中搜索区域的实现方式

SLIC 算法是针对自然图像而提出的，在实现聚类时先把自然图像的 RGB 值转

化为 LAB 值 (彩色图像到 CIELAB 图像的转化), 为了使得 SLIC 算法能够适用于高光谱遥感图像上, 我们把高光谱图像 \mathbf{R} 的每个像素光谱向量 \mathbf{R}_{xy} 代替其 LAB 值, 其中 x 和 y 是像素 \mathbf{R}_{xy} 的空间坐标, 则 SLIC 算法可以简单的描述如下:

1. 对高光谱图像的每个像素构造一个包含空间信息和光谱信息的向量 $\Phi(x, y) \in \mathbb{R}^{B+2}$ (B 是波段数):

$$\Phi(x, y) = \begin{bmatrix} \eta x \\ \eta y \\ \mathbf{R}_{xy} \end{bmatrix}, \quad (2.1)$$

在这里 η 参数平衡了空间和光谱信息, 假设 $S \times S$ 是一个搜索窗口的大小, 通常将 η 的值设置成 m/S , 从而通过调节 m 的值来控制空间和光谱信息的权重。

2. 根据输入的期望超像素个数 K 来确定聚类中心的数目并确定步长 S , N 是图像的总像素数, 按步长 $S = \sqrt{N/K}$ 初始化一系列的聚类中心 $C_i = \Phi(x_i, y_i)$, 如图 2-2(a) 所示, 并将这些聚类中心移到其所属的 3×3 领域中梯度最小的位置, 如图 2-2(b) 所示, 这样做可以避免聚类中心落在超像素的边缘上, 从而减少了噪声点所带来的影响。




图 2-2 SLIC 算法聚类中心初始化示意图

3. 每一个像素在其领域 $2S \times 2S$ 内根据欧几里得距离 $\|\Phi(x, y) - \Phi(x_i, y_i)\|$ 搜索与其距离最近的的聚类中心, 并将它聚为该类。
4. 更新聚类中心为该类所有像素的均值。
5. 重复上述两个步骤直到聚类中心的位置信息不再发生改变。

6. 最后，采用连通算法合并孤立点，使得每个超像素内部像素之间互相连通并且像素个数均匀。

实验证明基于 k -means 聚类思想的 SLIC 算法简单易实现，时间复杂度低，分割出的超像素个数可控且边缘贴合度好，但分割结果受参数影响较大，如何选择一个合适的空间光谱平衡因子 m 成为算法成败的关键问题。

2.1.2 ERS 超像素分割算法

熵率超像素分割 ERS 是一个基于图论的图像过分割算法^[61]，其过分割的过程也相当于一个逐步聚类的过程，主要通过优化一个目标函数来实现。该优化函数包含两部分，第一部分是随机行走的熵率函数，第二部分是平衡项函数。熵率函数主要优化聚类过程使得每个超像素内部更同质和紧凑，而平衡项函数则控制了各个超像素具有相似的大小。为了使得 ERS 算法能够更好地应用于高光谱图像之中，我们提前对高光谱图像采用了降维，其具体的实现过程如下所示：

1. 对高光谱图像进行维数降解。在这个步骤中，使用主成分分析 PCA 对高光谱图像进行光谱维度上的降维并提取出前三维构成一个彩色图像，之后所有的处理都是对这个三维图像进行。
2. 把图像映射成为一个图 $G = (V, E)$ ，其中 V 是图的顶点，代表的是像素点， E 是图的边，边的权值代表的是像素点之间的相似度。该图采用 8 连通的的网格图来构造，使得每个像素点只跟它相邻的 8 个像素点才有边。接下来，算法的目标就是要选择出子边集 $A \subseteq E$ 使得分割结果图 $G = (V, A)$ 恰好包含 K 个离散子图，而每个子图就代表一个超像素集。图的顶点 v_i 和 v_j 之间的边的权重定义如下：

$$w_{i,j} = \exp\left(-\frac{d(v_i, v_j)^2}{2\sigma^2}\right), e_{i,j} \in E \quad (2.2)$$

其中 $d(v_i, v_j)$ 是彩色图像强度差与空间欧几里得距离的乘积。

3. 构造熵率项函数：

$$\mathcal{H}(A) = - \sum_i u_i \sum_j p_{i,j}(A) \log(p_{i,j}(A)) \quad (2.3)$$




图 2-3 ERS 算法实现示例图

其中传播概率 $p_{i,j}$ 和 u_i 值的定义如下:

$$p_{i,j}(A) = \begin{cases} \frac{w_{i,j}}{w_i} & \text{if } i \neq j \text{ and } e_{i,j} \in A, \\ 0 & \text{if } i \neq j \text{ and } e_{i,j} \notin A, \\ 1 - \frac{\sum_{j:e_{i,j} \in A} w_{i,j}}{w_i} & \text{if } i = j. \end{cases} \quad (2.4)$$

$$w_i = \sum_{k:e_{i,k} \in E} w_{i,k}, w_T = \sum_{i=1}^{|V|} w_i, u_i = \frac{w_i}{w_T}$$

4. 构造平衡项函数:

$$\mathcal{B}(A) = H(Z_A) - N_A = - \sum_i PZ_A(i) \log(PZ_A(i)) - N_A, \quad (2.5)$$

这里假设在聚类过程中边集 A 把图划分为 N_A 个子图, 顶点集为 $S_A = \{S_1, S_2, \dots, S_{N_A}\}$, Z_A 的分布为:

$$PZ_A(i) = \frac{|S_i|}{|V|}, i = \{1, \dots, N_A\}. \quad (2.6)$$

5. 熵率项函数和平衡项函数构造完成之后, 通过最优化目标函数最终分割得到 K 个子图, 每个子图的顶点集代表一个超像素。目标函数如下:

$$\begin{aligned} & \max_A \mathcal{H}(A) + \lambda \mathcal{B}(A) \\ & \text{subject to } A \subseteq E \text{ and } N_A \geq K \end{aligned} \quad (2.7)$$

这里 $\lambda \geq 0$ 是平衡项函数的权值调节参数。

图 2-3 简单的展示了构造图 $G = (V, E)$ 的形式以及通过优化目标函数 2.7 最终产生分割图 $G = (V, A)$ 的一个简单示例, 在这里假设图像有 16 个像素点和期望得到的超像素个数 $K=3$ 。ERS 算法与 SLIC 算法不同, SLIC 算法依靠一个空间和光谱的调节因子来调节空间信息和光谱信息在超像素分割时所占的权重, 而 ERS 算法在构建图的时

候已经确定了空间信息，它只需要调节一个超像素的均匀性 (是否各个超像素间具有相同的大小) 和同质性 (是否同一个超像素内同质) 的平衡参数。所以 SLIC 在高光谱图像中生成的超像素更容易使得其规则性一致 (只要增加空间信息的权重，超像素就会越规则)，而 ERS 能够很好的划分出不同类别地物的边缘。综合这两种不同超像素方法的各自优势，本文在使用超像素引导的特征提取时采用了 SLIC 算法，而在超像素引导的分类决策融合中采用了 ERS 算法。

2.2 基于特征提取的超像素应用技术

2.2.1 空间-光谱薛定谔特征映射

在拉普拉斯特征映射^[27]和薛定谔特征映射^[69]的基础上，Cahill 等人^[70]将其应用于高光谱图像中，并提出了空间-光谱薛定谔特征提取的方法 (S³E)，这种方法可以有效地提取出低维的表征性更强的空谱特征。该特征提取方法主要是在拉普拉斯特征映射的基础上引入了空间信息，假设我们对 B 个波段的高光谱图像 \mathbf{R} 的展开矩阵 \mathcal{R}^T 进行降维得到 P 维数据的话，则 S³E 方法可以简单的描述为如下：

1. 构建一个无向图 $\mathcal{G} = (\mathcal{R}, \mathcal{E})$ ，其中顶点集为 \mathcal{R} ，边集为 \mathcal{E} ，边的构建采用 ϵ -近邻的方法，如果两个点的空间距离满足 $\|\mathbf{r}_i^p - \mathbf{r}_j^p\|_2 < \epsilon$ ，则点 \mathbf{r}_i 和点 \mathbf{r}_j 将连接一条边 (也可以采用 k -近邻的方法选取 k 个离该点最近的点构建边)。
2. 利用热核函数对构建的边集定义权值，并得到点与点之间的权值矩阵 $\mathbf{W} \in \mathbb{R}^{XY \times XY}$ ，如果点点 \mathbf{r}_i 和点 \mathbf{r}_j 存在边，则它们所构成的边的权值为： $\mathbf{W}_{i,j} = \exp(-\|\mathbf{r}_i - \mathbf{r}_j\|^2/\sigma^2)$ ，否则 $\mathbf{W}_{i,j} = 0$ 。
3. 对任何两个点 \mathbf{r}_i 和 \mathbf{r}_j ，定义稀疏矩阵 $\mathbf{S}^{(i,j)} \in \mathbb{R}^{XY \times XY}$ 为：

$$\mathbf{S}_{k,l}^{(i,j)} = \begin{cases} 1, & (k, l) \in \{(i, i), (j, j)\} \\ -1, & (k, l) \in \{(i, j), (j, i)\} \\ 0, & otherwise \end{cases} \quad (2.8)$$

从而得到由空间信息构成的潜在矩阵 $\mathbf{V} \in \mathbb{R}^{XY \times XY}$ ：

$$\mathbf{V} = \sum_{i=1}^{XY} \sum_{\mathbf{r}_j \in \mathcal{N}_\epsilon^p(\mathbf{r}_i)} \mathbf{S}^{(i,j)} \cdot \gamma_{i,j} \cdot \exp\left(-\frac{\|\mathbf{r}_i^p - \mathbf{r}_j^p\|^2}{\sigma^2}\right), \quad (2.9)$$

其中 $\mathcal{N}_\epsilon^p(\mathbf{r}_i)$ 是点 \mathbf{r}_i 在 ϵ -邻域内的点集:

$$\mathcal{N}_\epsilon^p(\mathbf{r}_i) = \{\mathbf{r} | \mathbf{r} \neq \mathbf{r}_i, \|\mathbf{r}_i^p - \mathbf{r}^p\|_2 < \epsilon\}, \quad (2.10)$$

以及系数 $\gamma_{i,j} = \exp\left(-\cos^{-1}\left(\frac{\langle \mathbf{r}_i, \mathbf{r}_j \rangle}{\|\mathbf{r}_i\| \cdot \|\mathbf{r}_j\|}\right)\right)$ 。

4. 构造拉普拉斯矩阵 $\mathbf{L} = \mathbf{D} - \mathbf{W}$, 其中 \mathbf{D} 是对角矩阵, 且 $\mathbf{D}_{i,i} = \sum_j \mathbf{W}_{i,j}$ 。计算 $(\mathbf{L} + \alpha\mathbf{V})\mathbf{f} = \lambda\mathbf{D}\mathbf{f}$ 最小的 $P + 1$ 特征值 $0 = \lambda_0 \leq \lambda_1 \leq \dots \leq \lambda_P$ 和其所对应的特征向量 $\mathbf{f}_0, \mathbf{f}_1, \dots, \mathbf{f}_P$, 最后, 由这些特征向量所组成的矩阵 $\mathbf{F} = [\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_P] \in \mathbb{R}^{XY \times P}$ 便是通过空间-光谱薛定谔特征映射降维后的矩阵。

S^3E 算法通过引入由空间信息构建的潜在矩阵 \mathbf{V} , 并将其与由光谱信息构建的拉普拉斯矩阵组合起来, 从而形成空间-光谱特征映射。从其算法中可以看出, 该算法复杂度很高, 由于高光谱图像往往很大, 意味着每个高光谱图像有成千上万个像素, 在构建图的时候如果将每个像素看成一个点的话将使得构建的矩阵 \mathbf{L} 和 \mathbf{V} 很大, 使得其复杂度高达 $O(BX^2Y^2)$ 。

2.2.2 超像素在薛定谔特征映射中的应用

实验证明空间-光谱薛定谔特征映射方法 S^3E 在高光谱图像中提取的特征分类效果极其好^[70], 但存在的问题是复杂度太高, 为了提高时间效率, Zhang 等人^[46] 引入了超像素来辅助特征提取, 本文命名该方法为 S^4E 。 S^4E 方法的思想极其简单, 主要是将空间-光谱薛定谔特征提取方法的作用对象从基于像素到基于超像素。如图 2-4 显示了 S^4E 方法在利用超像素辅助 S^3E 特征提取时主要过程。

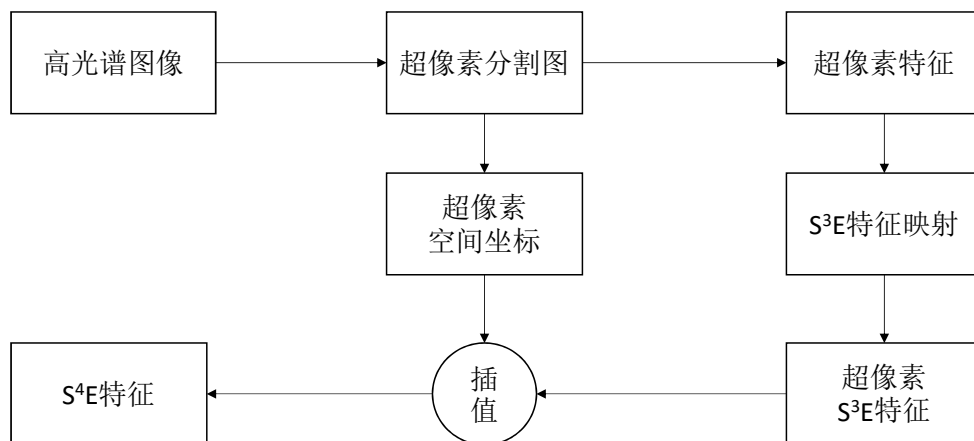


图 2-4 S^4E 特征提取流程图

超像素特征的提取只需要采用超像素内所有像素的光谱均值特征即可，而超像素的空间坐标同样是超像素内所有像素的空间坐标的均值。因为高光谱图像经过超像素分割后，超像素的个数远远小于总像素的个数，因此通过基于超像素特征的维数变换大大减少了时间复杂度。

2.3 基于超像素水平的分类方法

2.3.1 基于超像素均值特征的分类

在利用超像素方法对高光谱图像进行超像素分割之后，会生成 K 个超像素，让 $\{\mathbf{X}_1, \dots, \mathbf{X}_K\}$ 来表示这 K 个超像素，其中 $\mathbf{X}_i = [\mathbf{X}_i(:, 1), \dots, \mathbf{X}_i(:, K_i)] \in \mathbb{R}^{B \times K_i}$ 是第 i 个超像素， K_i 表示该在这个超像素中的像素个数。超像素均值特征提取只需要对该超像素内的所有像素求平均值，其计算公式如下：

$$\mathbf{x}_i = \frac{1}{K_i} \sum_{j=1}^{K_i} \mathbf{X}_i(:, j), \quad i = 1, \dots, K \quad (2.11)$$

在得到第 i 个超像素的均值特征 \mathbf{x}_i 后，只需要把该超像素看作一个整体，也就是该超像素内的所有像素的特征都用该超像素的均值特征表示，因此它们是一样的。采用超像素均值作为分类特征的方法对超像素分割的结果依赖性很强，只有在超像素分割很好的情况下，才能保证该方法提取的特征具有表征性，除此之外，由于高光谱图像所具备的同物异谱和异物同谱的特点，简单的使用求取均值的特征不足以反映该地物的特征表示，因此分类效果的鲁棒性不强，误差很大。

2.3.2 基于超像素的多任务联合稀疏表示

典型的稀疏表示的分类 (SRC) 在计算机视觉领域里面曾受广泛学者的关注，在高光谱图像上也不例外。Li 等人^[44] 将其分类思想与超像素结合起来，提出了基于超像素水平的稀疏表示分类，并作用于多组特征 (光谱特征，Gabor 特征以及 EMAP 特征^[42])，从而构成多任务的学习分类方法。其思想是把整个超像素内的像素看作一个整体，但并不是像求平均值那样给每一个像素都赋予相同的权值，而是对每一个像素都给予一个未知权值参数，并在稀疏优化过程将其参数求解出来。假设在第 l 个特征中，超像素 $\mathbf{X}^l = [\mathbf{X}^l(:, 1), \dots, \mathbf{X}^l(:, m)] \in \mathbb{R}^{B \times m}$ 内各个像素的权值参数为 $\mathbf{a}^l = [\mathbf{a}^l(1); \dots; \mathbf{a}^l(m)] \in \mathbb{R}^m$ ，由训练样本构建的学习字典为 \mathbf{D}^l ，学习系数为 \mathbf{b}^l ，则

基于超像素的多任务联合稀疏表示分类的稀疏优化目标函数为：

$$\begin{aligned} \min_{\{\mathbf{A}, \mathbf{B}\}} & \sum_l^L \|\mathbf{X}^l \mathbf{a}^l - \mathbf{D}^l \mathbf{b}^l\|_2^2 + \lambda \|\mathbf{A}\|_F + \eta \|\mathbf{B}\|_{1,2} \\ \text{s.t. } & \mathbf{A} = [\mathbf{a}^1, \dots, \mathbf{a}^L], \mathbf{B} = [\mathbf{b}^1, \dots, \mathbf{b}^L], \\ & \sum_j \mathbf{a}^l(j) = 1, l = 1, \dots, L \end{aligned} \quad (2.12)$$

在这里， λ 和 η 是规则化参数。经过优化求得权重系数矩阵 \mathbf{A} 和稀疏系数矩阵 \mathbf{B} 后，超像素的类别标签将预测为：

$$\text{Class}(\mathbf{X}) = \arg \min_{i=1, \dots, C} \sum_l^L \|\mathbf{X}^l \mathbf{a}^l - \mathbf{D}_i^l \mathbf{b}_i^l\|_2^2. \quad (2.13)$$

由于该方法采用了基于超像素的联合稀疏表示，在一定程度上减少了比单一使用基于像素的的稀疏表示分类所带来的高时间复杂度，同时面向超像素水平的方法使得分类结果有了很大改善。该方法在引入超像素的同时，也使用了多任务学习的策略，通过组合不同特征共同发挥作用，比单一使用任一组特征都更鲁棒和精确。

2.3.3 简单的超像素融合分类方法

在基于超像素的分类方法中，一个简单有效的方法就是利用超像素的局部同质性去修正已经得到的分类结果。最简单的修正方法就是使用多数表决策策略，把每一个超像素的类别标签预测为该超像素内大多数像素的分类标签，如图 2-5 所示所展现的是使用该方法的一个示例。




图 2-5 基于多数表决的超像素融合方法示例图

从示例图中我们可以看出，简单的使用多数表决的思想在总体上可以大大地提高分类的精度，但其结果受超像素的分割效果和预分类的效果影响很大，一旦某一个超像素分割的结果不够同质，或者在该超像素位置上的像素预分类的结果不够理想，将使得其超像素整体分错，因此，该方法的缺点是不够鲁棒，方差很大。

2.4 本章小结

本章首先由经典的超像素分割算法出发，阐述了目前广泛使用的两种超像素分割算法的基本思想，并详细描述了他们在高光谱图像上的具体分割算法；进而由此引出在高光谱图像分类上超像素所扮演的作用，并将其作用归纳为两大类，分类是基于特征提取的和基于超像素水平分类的方法；最后，对每一类方法，分别详细介绍了目前应用比较成功的一些算法，并给出了他们的算法流程，且分析了它们的优缺点和存在的问题，在后续的研究中，本文将对其相关算法进行改进。

本章内容是本文的基本理论指导，是本文后续研究的基本依据。

第 3 章 超像素引导的特征变换及其多任务学习方法

在高光谱图像分类中，特征提取起到了关键的作用，但是高光谱图像数据量大，在提取其特征的时候往往带来巨大的运算压力。在上一章提到的空间-光谱薛定谔特征映射 (S³E) 方法虽然能够提取出辨别性强的特征，但是其复杂度及其大，为了改善其时间效率，利用超像素辅助其特征提取能够显著降低其时间复杂度，这便是上面提到的 S⁴E 方法，然而，这种牺牲精度换取时间效率的算法并不是最理想的策略。在这一章中，我们将围绕这个问题开展研究，既要充分利用空间-光谱薛定谔特征映射的良好特征变换的特点，使得其分类精度能够有更大的提升，又要保证在时间效率上尽可能的优化。为了解决这个问题，本文提出了采用多组 Gabor 特征代替原光谱特征来作为薛定谔特征变换源，以弥补使用超像素辅助特征提取时所带来的光谱信息缺失，同时提出了新型的基于支持向量机的多任务学习框架，这保证了多组特征能够更大的发挥作用。

3.1 Gabor 特征提取

Gabor 小波变换最早源于傅里叶变换，被称为带窗的傅里叶变换或短时傅里叶变换。最近，Gabor 变换作为一个有效的特征提取工具已经成功并广泛地应用于图像的多项领域，包括纹理分割^[71]，医学图像配准^[72]，人脸识别^[73]等。在这些领域的应用表明 Gabor 特征具备很高的辨别力，因为 Gabor 函数在时域和频率的设计特性与人类视觉系统特征描述具有相似性^[74]。本文利用 Gabor 特征在自然图像上的强表征力转移到高光谱图像的空谱特征提取上来，设计了一系列基于不同频率尺度和方向的 2D Gabor 函数：

$$\begin{aligned} \Psi_{f_u, \theta_v}(x, y) &= \exp(-\pi(a^2 x'^2 + b^2 y'^2)) \cdot \exp(j2\pi f_u x'^2), \\ x' &= x \cos \theta_v + y \sin \theta_v, y' = -x \sin \theta_v + y \cos \theta_v, \\ a &= 0.9589 f_u, b = 1.1866 f_u, \end{aligned} \quad (3.1)$$

其中， f_u 和 θ_v 分别表示 Gabor 函数的中心频率和方向。设 $\{\Psi_t, t = 1, 2, \dots, T\}$ 为在不同频率和方向上获得的 T 个 Gabor 滤波器，则高光谱图像 \mathbf{R} 的 Gabor 特征只需要使用这些滤波器对其图像按波段进行卷积操作后获得：

$$\mathbf{G}_t(x, y, b) = |(\mathbf{R}_b \otimes \Psi_t)(x, y)| \quad (3.2)$$

其中 $\mathbf{R}_b \in \mathbb{R}^{X \times Y}$ 是第 b 波段图像, 且 $1 \leq b \leq B$, \otimes 和 $|\cdot|$ 分别是卷积运算符和取绝对值运算符。经过对每一个波段的卷积操作, 可以得到 T 个在不同频率和方向上提取的 Gabor 特征立方体, 其中 $\mathbf{G}_t \in \mathbb{R}^{X \times Y \times B}$ 是第 t 个 Gabor 特征立方体, 显然, 它的维数与原光谱数据的维数是一致的。在本文中, Gabor 滤波器的频率设置为 4 组, 方向设置为 6 组, 如下:

$$f_u \in [0.03589, 0.09473, 0.25, 0.6577]$$

$$\theta_v \in [0, 40, 80, 120, 160, 180].$$

因此, 在这里共可以得到 $T = 24$ 个不同的 Gabor 特征立方体。

3.2 超像素引导的 Gabor 特征薛定谔变换

在一系列的 Gabor 特征立方体提取之后, 对每一个 Gabor 立方体进行薛定谔特征变换将会消耗大量的时间, 因此采用基于超像素引导的特征提取方法进行。首先, SLIC 超像素分割算法将应用于此, 特别地, 让 $\{\mathbf{X}_1^t, \dots, \mathbf{X}_N^t\}$ 代表在第 t 个 Gabor 特征立方体下的 N 个超像素, 其中 $\mathbf{X}_i^t = [\mathbf{X}_i^t(:, 1), \dots, \mathbf{X}_i^t(:, N_i)] \in \mathbb{R}^{B \times N_i}$ 是第 i 个超像素在第 t 个 Gabor 立方体下的像素集。显然, 对每一个 $j = 1, \dots, N_i$ 的像素 $\mathbf{X}_i^t(:, j)$ 在不同 $t = 1, \dots, T$ 下所对应的空间坐标都是一致的, 使用 $\mathbf{P}_i(:, j) \in \mathbb{R}^2$ 来表示该像素点的坐标, $\mathbf{P}_i = [\mathbf{P}_i(:, 1), \dots, \mathbf{P}_i(:, N_i)] \in \mathbb{R}^{2 \times N_i}$ 表示第 i 个超像素内的所有像素的空间坐标信息。

在得到多个 Gabor 特征立方体和超像素分割图之后, 需要首先提取出每一个超像素的特征, 以及他的空间坐标, 由于每一个超像素内具有若干个像素, 我们对这些若干个像素取均值运算:

$$\begin{aligned} \mathbf{x}_i^t &= \frac{1}{N_i} \sum_{j=1}^{N_i} \mathbf{X}_i^t(:, j), \quad \mathbf{p}_i = \frac{1}{N_i} \sum_{j=1}^{N_i} \mathbf{P}_i(:, j), \\ i &= 1, \dots, N, \quad t = 1, \dots, T \end{aligned} \quad (3.3)$$

从而得到每个超像素在每个 Gabor 特征体下的特征表示和坐标表示, 其中 \mathbf{x}_i^t 是第 t 个 Gabor 特征体下第 i 个超像素的特征表示, \mathbf{p}_i 是其空间坐标, 由于其在每个 Gabor 特征体下的位置坐标都是一样的, 因此与第几个 Gabor 特征体无关。

对于第 t 个 Gabor 特征立方体, 我们都能得到一组特征 $\mathcal{X}^t = \{\mathbf{x}_1^t, \dots, \mathbf{x}_N^t\} \in \mathbb{R}^{B \times N}$, $t = 1, \dots, T$, 它们是在这个 Gabor 体下所有超像素特征的集合, 它们都含有空间坐标信息, 因此这些特征可以直接用于空间-光谱的薛定谔的特征变换上, 最终映射得到 K 维数据特征 $\mathcal{Y}^t = \{\mathbf{y}_1^t, \dots, \mathbf{y}_N^t\} \in \mathbb{R}^{K \times N}$, $t = 1, \dots, T$ 。最后对这些变换后的超

像素特征使用自然邻接插值法对每一个像素进行插值还原，从而得到最终的特征立方体 $\mathbf{M}_t \in \mathbb{R}^{X \times Y \times K}, t = 1, \dots, T$ ，这些特征 (称为 GS⁴E 特征) 将用于下面的多任务学习框架上。

3.3 基于支持向量机的多任务学习框架

为了能充分利用这 T 组特征，本文提出了一种多任务学习的策略，在上一章中我们介绍了基于稀疏表示的多任务学习方法，跟这个方法思想类似，本文提出的多任务学习方法也是通过组合多个特征已达到多任务的目的，但不同的是本文采用的是基分类器是支持向量机，这使得算法具备更加更高效的时间效率，其运行时间远远低于基于稀疏表示的多任务策略。

假设高光谱图像共有 C 个地物类别和 L 个训练样本，对每一个特征体 $\mathbf{M}_t \in \mathbb{R}^{X \times Y \times K}, t = 1, \dots, T$ ， $\mathbf{A}_c^t = [\mathbf{a}_{c,1}^t, \mathbf{a}_{c,2}^t, \dots, \mathbf{a}_{c,L_c}^t] \in \mathbb{R}^{K \times L_c}$ 是其对应的第 c 类训练样本，其中每一个特征向量 $\mathbf{a}_{c,j} (j = 1, 2, \dots, L_c)$ 都是 K 维的。因此第 t 个特征 \mathbf{M}_t 所对应的训练样本可以表示为 $\mathbf{A}^t = [\mathbf{A}_1^t, \mathbf{A}_2^t, \dots, \mathbf{A}_C^t] \in \mathbb{R}^{K \times L}$ ，其中 $L = L_1 + L_2 + \dots + L_C$ 。取 $\mathbf{y} \in \mathbb{R}^K$ 为一个测试像素点，由于其在每一个特征体下的标签都是一样的，让 $\mathbf{y}^t \in \mathbb{R}^K$ 作为其第 t 个特征体下的一个测试样本，我们第一步的目标就是要得到该测试样本属于每一个类别的概率，将其表示为：

$$p_c^t = P(y = c | \mathbf{y}^t), \quad c = 1, \dots, C. \quad (3.4)$$

为了得到这个概率，首先我们采用一对一的支持向量机学习策略针对每两个类别来进行概率判断，假设在第 c 和第 d 类之中，该测试样本所属 c 的概率为：

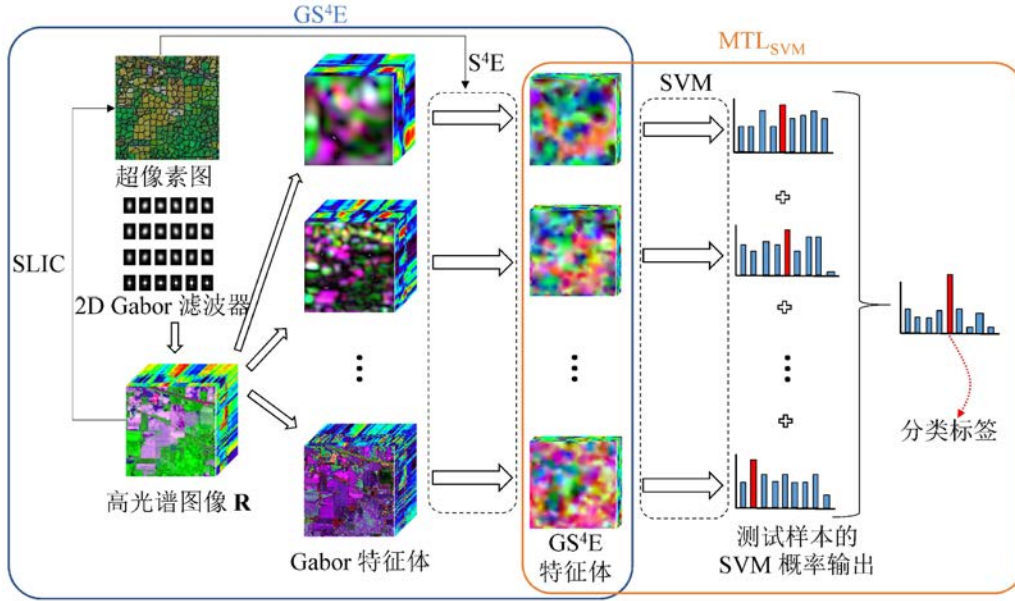
$$r_{cd}^t = P(y = c | y = c \text{ or } d, \mathbf{y}^t) \quad (3.5)$$

如果 f_t 是测试样本 \mathbf{y}^t 在训练数据集 \mathbf{A}^t 下使用支持向量机所得到的决策值，则 r_{cd}^t 定义为：

$$r_{cd}^{(t)} = \frac{1}{1 + e^{af_t + b}}, \quad (3.6)$$

在这里，参数 a 和 b 可以通过极大似然估计得到。

在得到成对的概率 $r_{cd}^{(t)}, c = 1, \dots, C, d = 1, \dots, C$ 之后，为了得到该测试样本在每一


 图 3-1 GS^4E-MTL_{SVM} 多任务学习框架系统流程示意图

个类别的概率，即为了得到 $\mathbf{p}^t = [p_1^t, p_2^t, \dots, p_c^t]$ ，通过优化下列目标函数实现^[75]：

$$\min_{\mathbf{p}^t} \frac{1}{2} \sum_{c=1}^C \sum_{d:d \neq c} (r_{dc}^t p_c^t - r_{cd}^t p_d^t)^2 \quad (3.7)$$

$$\text{subject to } p_c^t \geq 0, \forall c, \sum_{c=1}^C p_c^t = 1$$

通过求解上述优化得到每个特征体下的测试样本的所属概率后，因为原测试样本 \mathbf{y} 共有 T 个特征表示，因此我们简单的组合多个特征的概率预测结果来确定该测试样本的所属类别：

$$\text{Class}(\mathbf{y}) = \arg \max_c \sum_{t=1}^T p_c^t \quad (3.8)$$

如图 3-1 阐述了提出的超像素引导的多任务学习框架系统流程图，我们将该方法命名为 GS^4E-MTL_{SVM} 方法。

3.4 实验结果及分析

3.4.1 实验设置

为了验证提出的 GS^4E-MTL_{SVM} 方法的有效性，本实验选择了三个广泛使用的真实遥感图像进行验证，分别是 Indian Pines, Salinas scene 和 Pavia University 数据集，相关的描述见第一章。在实验中，一些目前先进的特征提取算法和与本方法相关的算法将进行对比分析，其中有基准的原光谱特征 (Raw)，目前流行的扩展形态学特

表 3-1 实验中的一些参数设置值

参数	描述	值
σ	S ⁴ E 中的方差参数	1
α	S ⁴ E 中的权衡参数	$0.1 * tr(\mathbf{L}) / tr(\mathbf{V})$
S	SLIC 中的步长	8
m	SLIC 中的权衡参数	0.01
K	降维维度	50 或 25

征 (Extended Morphological Attribute Profiles, EMAP)^[42], 薛定谔映射特征 (S³E), 基于超像素的薛定谔映射特征 (S⁴E), 和本文提出的 GS⁴E 特征, 这些特征全部采用一致的基于 RBF 核的支持向量机作为分类器, 除此之外, 对 S⁴E 特征还采用了基于稀疏表示的分类器 (SRC) 作为比较 (为了验证使用 SRC 分类器计算复杂度高, 从而表明基于支持向量机的多任务学习的时效性)。

在这些对比方法的参数选择上, 对于 SVM 分类器, 将采用 C 折交叉验证 (C 是类别数), 对于 SRC 分类器, 一个同伦算法将被使用来计算系数信号^[76], 其规则化参数根据经验设置为 10^{-2} , 其他的方法全部采用与原文设置的最优默认参数。

实验时, 每次实验重复 15 次, 每次随机选取不同的训练样本和测试样本, 因为本文的研究是基于小样本的分类, 因此训练样本大小选择为从每类 5 个到每类 15 个样本, 此外对于 Salinas scene 和 Pavia University 数据集, 还试验了每类 20, 30, 40 和 50 个样本的情况 (由于 Indian Pine 样本集比较小, 有些类的样本总数不到 30)。实验结果评价准则将采用总体分类精度 (Overall Accuracy, OA) 以及 Kappa 系数 (κ) 进行评估。

3.4.2 参数敏感度分析

在实验过程中, 有一些重要参数需要调制, 比如特征提取后的维数大小 K 和 SLIC 超像素分割算法中的参数 m , 为了了解他们对实验结果的影响程度, 本实验在进行评估算法之前对这些需要调节的参数进行了敏感度分析。如图 3-2 所示, 分别在三个实验数据上三个不同大小的训练样本的情境下对参数 m 和 K 进行了分析, 在这里, 选取 m 的范围为 $\{0.01, 0.02, \dots, 0.1\}$, K 的选取范围在 Indian Pines 和 Salinas scene 数据集上为 $\{20, 25, \dots, 60\}$, 而对于数据 Pavia University 数据, 由于其波段数较少, K 选取范围为 $\{5, 10, \dots, 35\}$ 。在这些参数范围内, 根据其对算法分类精度的影响, 我们可以看到其分类精度在参数变化的小范围区域内较为稳定, 而在不同的参数之间的变化也比较平滑。对于维度 K 来说, 随着其的增大, 其精度总体是先呈上升趋势而后稳定下来, 而对于参数 m 来说, 几乎没有什么很大的影响。在本后续的实验中, 参数 m 被设置

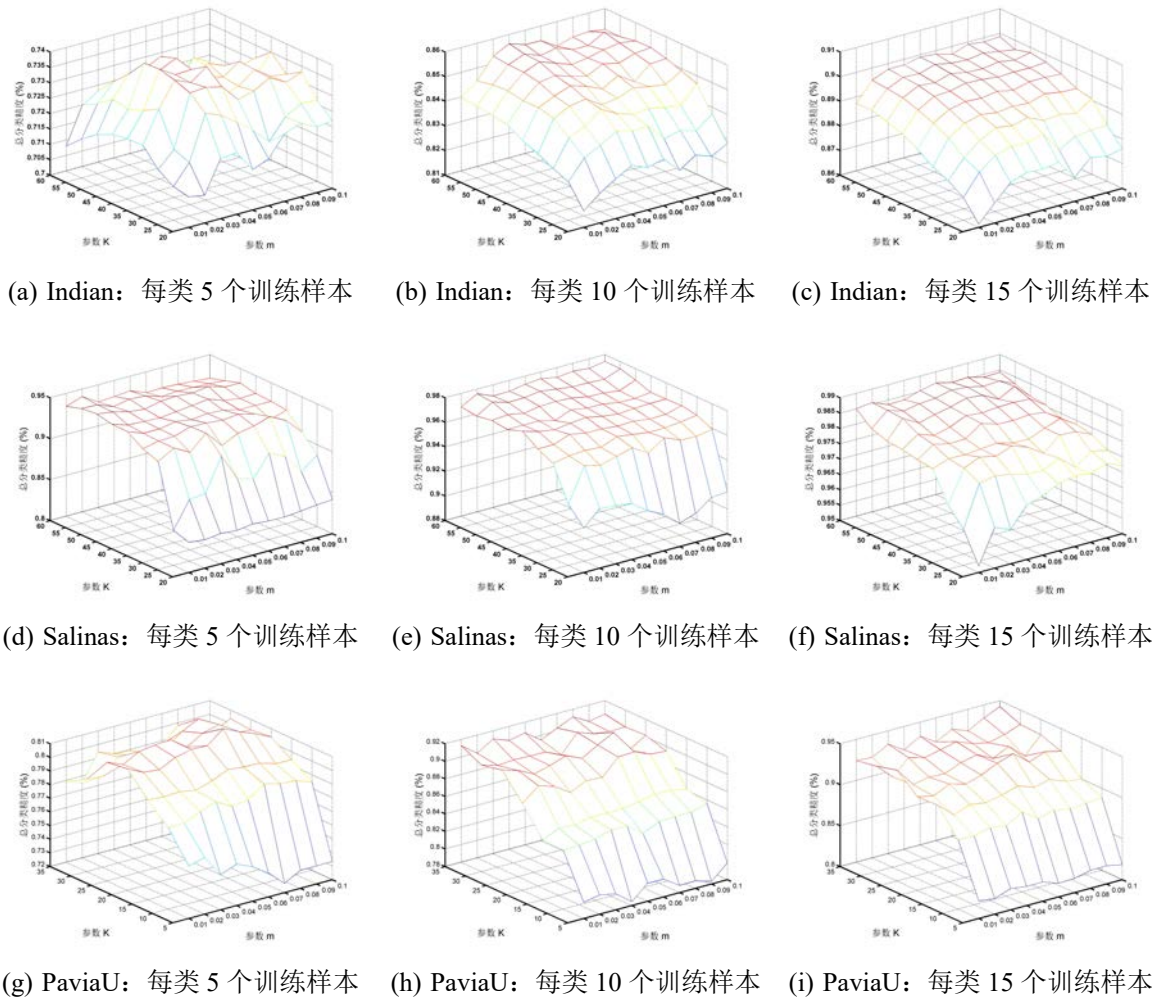


图 3-2 GS^4E-MTL_{SVM} 的分类精度随参数 m 和 K 的变化趋势

为 0.01，在 Indian Pines 和 Salinas scene 数据中， K 选取为 50，而在 Pavia University 数据上为 25。对于其他的参数设置，本文均定为与其相关的文献保持一致，如表 3-1 展示了实验过程中的参数设置值。

3.4.3 实验结果

为了验证本文算法的有效性，本节将在三个广泛使用的高光谱图像上进行实验，并从四个方面来对实验的结果进行分析。首先，在每类训练样本个数为 5 的实验下，分别直观地列出了 6 个相关算法以及本文提出的方法的分类结果图，通过对这些分类结果图和已知的真实标签图的比对，从而得出结论，进而，分别列出了这些算法在每一类当中的具体分类精度以及分类标准差，再者，分析了在不同训练样本个数下的对比实验，最后，给出了平均运行时间。

(1) Indian Pines 实验数据结果

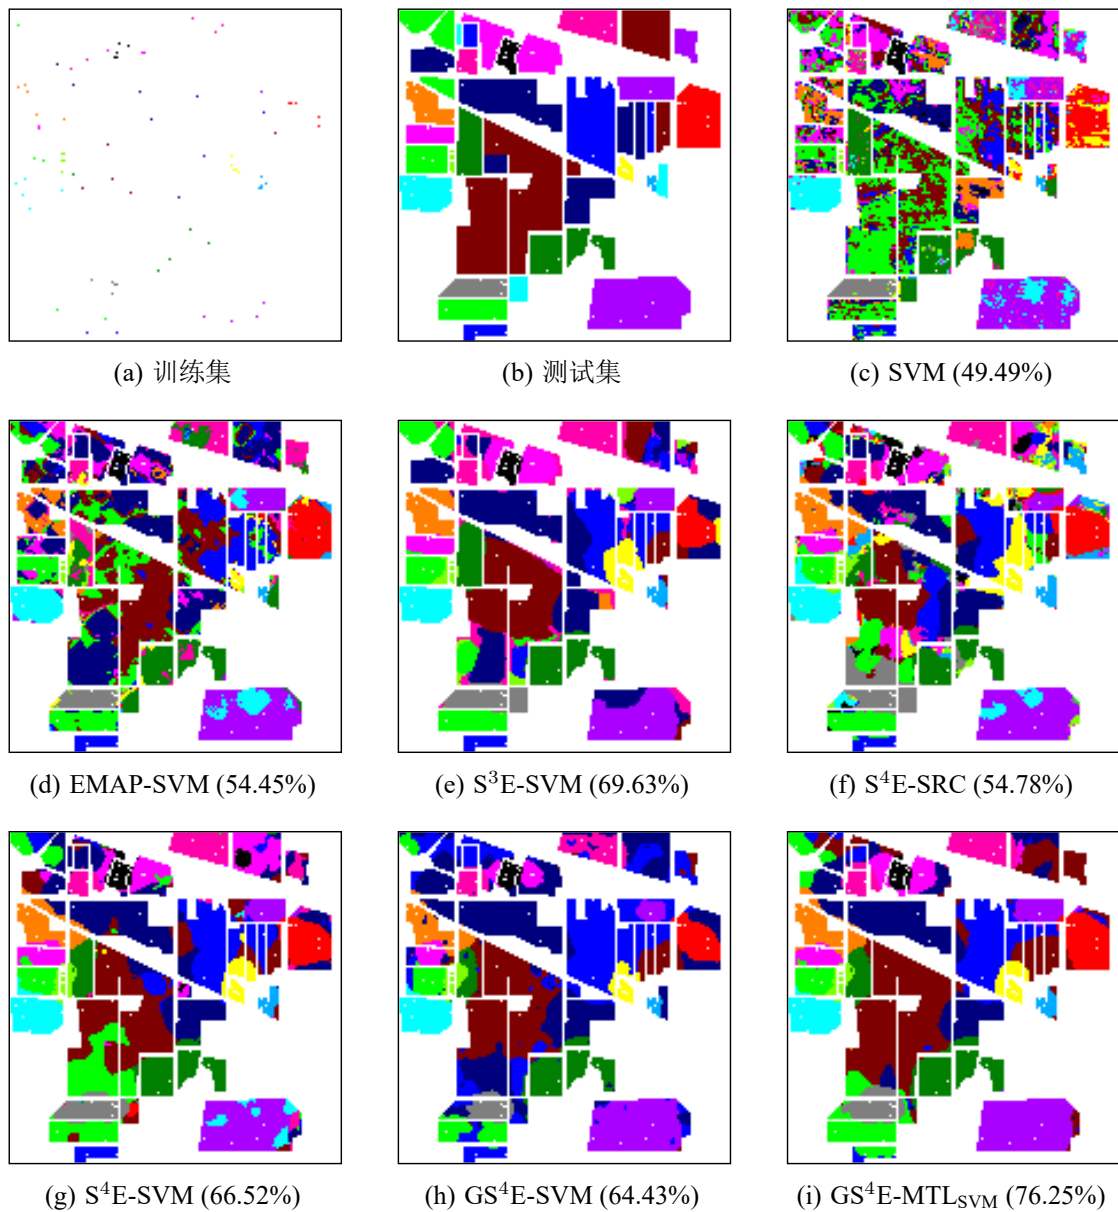


图 3-3 Indian Pines 数据集：每类 5 个训练样本的分类结果图

在每个类只有 5 个训练样本的小样本分类情况下，图 3-3 展示了 6 个相关算法和本文提出的算法在测试集上的对比分类结果图。从图中可以看出，对比于其他方法，本文提出的 GS^4E - MTL_{SVM} 方法的分类结果 (图 3-3(i)) 与真实标签 (图 4-10(b)) 更加接近。作为基准对比的光谱特征的分类结果，如图 4-10(c) 所示，其分类结果显著劣于其他方法，说明单纯使用光谱特征在小样本场景下是行不通的，因此对高光谱图像提取表征性更强的特征及其关键。与本文的算法相比， S^3E -SVM 方法作为对全像素做空间-光谱薛定谔特征映射，其结果显著优于原始光谱特征以及目前流行的形态学特征，而 S^4E -SVM 方法在其基础上使用基于超像素的特征映射，其分类精度稍微略低。通过引入本文提出的 Gabor 特征后， GS^4E -SVM 方法的分类性能并没有得到有效的提升，因

表 3-2 Indian Pines 数据集：每类 5 个训练样本的分类精度表 (%)

类别	SVM		EMAP-SVM		S ³ E-SVM		S ⁴ E-SRC		S ⁴ E-SVM		GS ⁴ E-SVM		GS ⁴ E-MTL _{SVM}	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差
C1	90.00	6.89	91.33	8.57	95.37	1.30	89.63	8.29	89.85	9.55	87.93	8.61	85.93	13.44
C2	61.14	10.98	90.17	11.47	62.81	13.95	90.92	9.59	86.91	10.85	78.93	18.20	90.62	8.50
C3	43.68	8.34	45.80	9.09	59.59	4.97	54.02	9.75	56.19	9.04	54.98	17.72	63.09	12.68
C4	49.27	10.37	40.99	8.70	62.82	6.52	60.01	5.61	67.00	12.38	61.32	17.02	65.75	14.73
C5	65.85	12.42	84.90	8.23	99.16	0.83	99.18	1.69	98.91	1.87	99.05	2.16	99.46	1.21
C6	37.59	7.44	45.91	13.15	63.88	6.29	50.89	7.38	62.22	10.69	53.68	13.46	62.84	9.70
C7	69.34	12.38	67.87	8.28	69.07	4.05	61.83	11.80	66.23	9.97	64.23	9.94	73.33	11.38
C8	64.80	12.41	74.56	8.02	77.33	9.82	56.45	14.88	80.15	8.95	80.49	11.34	87.51	9.14
C9	37.33	10.20	79.31	8.54	79.13	2.88	71.80	17.13	73.53	17.15	70.08	17.00	74.47	19.44
C10	90.48	5.69	97.14	5.91	99.21	1.94	99.37	1.68	100.00	0.00	100.00	0.00	99.05	1.97
C11	49.58	6.61	75.40	12.64	95.29	1.02	89.49	3.47	90.92	6.95	89.26	10.65	95.84	5.71
C12	92.89	10.53	100.00	0.00	100.00	0.00	100.00	0.00	100.00	0.00	100.00	0.00	100.00	0.00
C13	30.53	9.97	36.55	8.91	40.51	5.84	41.89	8.71	48.65	10.30	54.43	23.97	58.67	19.14
C14	37.81	12.13	37.16	11.22	42.73	5.53	38.18	7.37	44.78	9.80	67.18	17.98	67.42	19.83
C15	77.60	6.33	55.07	10.57	84.23	12.63	68.50	11.40	81.33	10.41	71.56	16.41	79.07	13.80
C16	88.82	11.83	93.59	4.44	96.38	1.75	89.79	10.96	95.36	3.53	87.41	12.81	91.47	6.23
OA	49.24	1.88	53.03	2.10	67.02	2.16	55.22	3.11	63.37	3.61	67.16	3.16	71.95	4.09
Kappa	0.44	0.02	0.48	0.02	0.63	0.02	0.51	0.03	0.59	0.04	0.62	0.04	0.68	0.04

为该方法只是简单的把所有 Gabor 特征组合起来，没有充分的利用到各个 Gabor 特征的优势，而通过引入基于支持向量机的多任务学习后，本文提出的 GS⁴E-MTL_{SVM} 方法在分类精度上得到了显著的提升。

表 3-2 展示了在每类 5 个样本时的各个方法的具体分类精度。从实验结果的均值和方差(随机重复 15 次实验)来看，虽然本文方法在方差上略大于其他方法，但其分类精度在大部分类别下都能取得最优的效果，其总体分类精度(OA)和 Kappa 系数远远高于其他对比方法。

通过改变每个类别训练样本的数量，我们对所有方法进行了实验，如图 3-4 所示，展示了总体分类精度(OA)和 kappa 系数随训练样本数的变化趋势。当训练样本数量从每类 5 个增加到每类 15 个的时候，本文提出的方法的分类结果都优于其他算法。特别地，在样本数量更小的情况下，本文提出的方法优势越明显，说明本文提出的多任务学习的策略在小样本分类中越能充分挖掘特征信息。在其鲁棒性上(分类标准差)，我们可以看到，我们提出的方法于其他方法基本相当，并且随着训练样本的数量的增加而减小。尽管通过引入 Gabor 特征后，GS⁴E-SVM 方法在每类只有 5 个训练样本时并

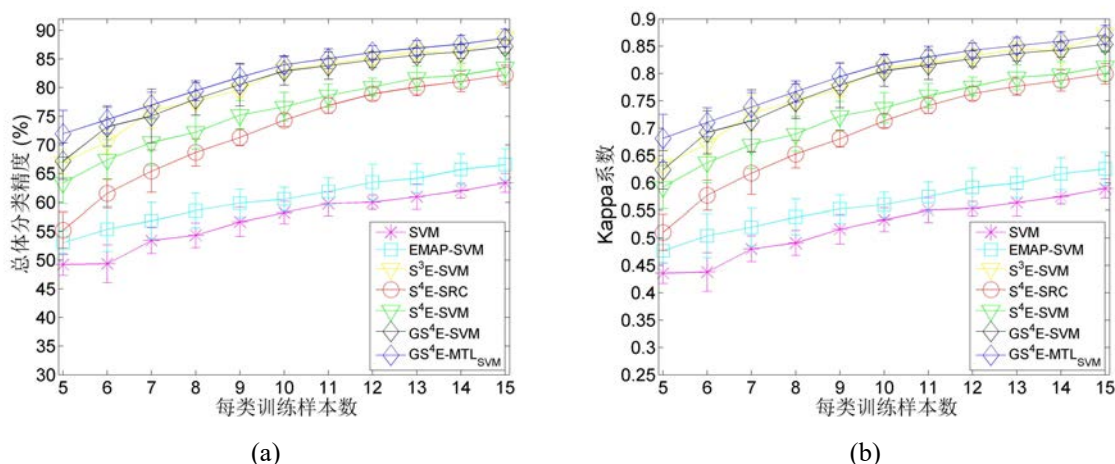


图 3-4 Indian Pines 数据集：每类训练样本数对分类结果的影响

没有有效的提升分类精度，但是当训练样本增加时，其优势越来越明显，从中可以看出 Gabor 特征是及其有效的特征。同样的 S⁴E 特征，使用 SRC 分类器的分类效果远远不如使用 SVM，证明选用 SVM 作为基分类器比使用 SRC 好。从图中可以看出，空间-光谱薛定谔特征 S³E 也能得到很高的分类精度，尤其是在样本数更多的时候，而采用超像素辅助的空间-光谱薛定谔特征 S⁴E 明显不如基于全像素的特征 S³E，但是通过引入本文提出的 Gabor 特征以及多任务学习之后，其分类性能得到显著的提升。

(2) Salinas scene 实验数据结果

同样的，在每个类只有 5 个训练样本的情况下，图 3-5 展示了 6 个相关算法和本文提出的算法在测试集上的对比分类结果图。显然的，本文提出的方法所产生的分类结果图 (图 3-5(i)) 与真实场景的标签图 (图 4-7(b)) 最为一致。与 Indian Pines 数据集一样，在 Salinas scene 数据集上仍然是纯光谱特征表现最差，然而由于 Salinas scene 数据图像地表分布相对平滑，因此采用超像素辅助的特征提取将会有表现更好，其特征更能充分利用空间信息，如图 3-5(g) 所示，其分类性能显著优于图 3-5(e)。

表 3-3 展示了在每类 5 个样本时的各个方法的具体分类精度。由于 Salinas scene 数据地表分布比较集中，从表中可以看出，使用超像素的方法其分类性能将得到显著的提升，而且相对于 Indiana Pines 数据，这些使用超像素的方法的分类标准差也减小了很多，这些数据说明，超像素在应用于高光谱图像的特征提取时，如果高光谱图像的空间信息越丰富，则其效果越明显。尽管使用了 Gabor 特征后总体分类精度得到下降 (88.05%)，但是通过使用本文提供的多任务学习策略后，其总体分类精度 (93.24%) 再次得到显著提高，并超过了 S⁴E 特征的总体分类精度 (91.27%)。

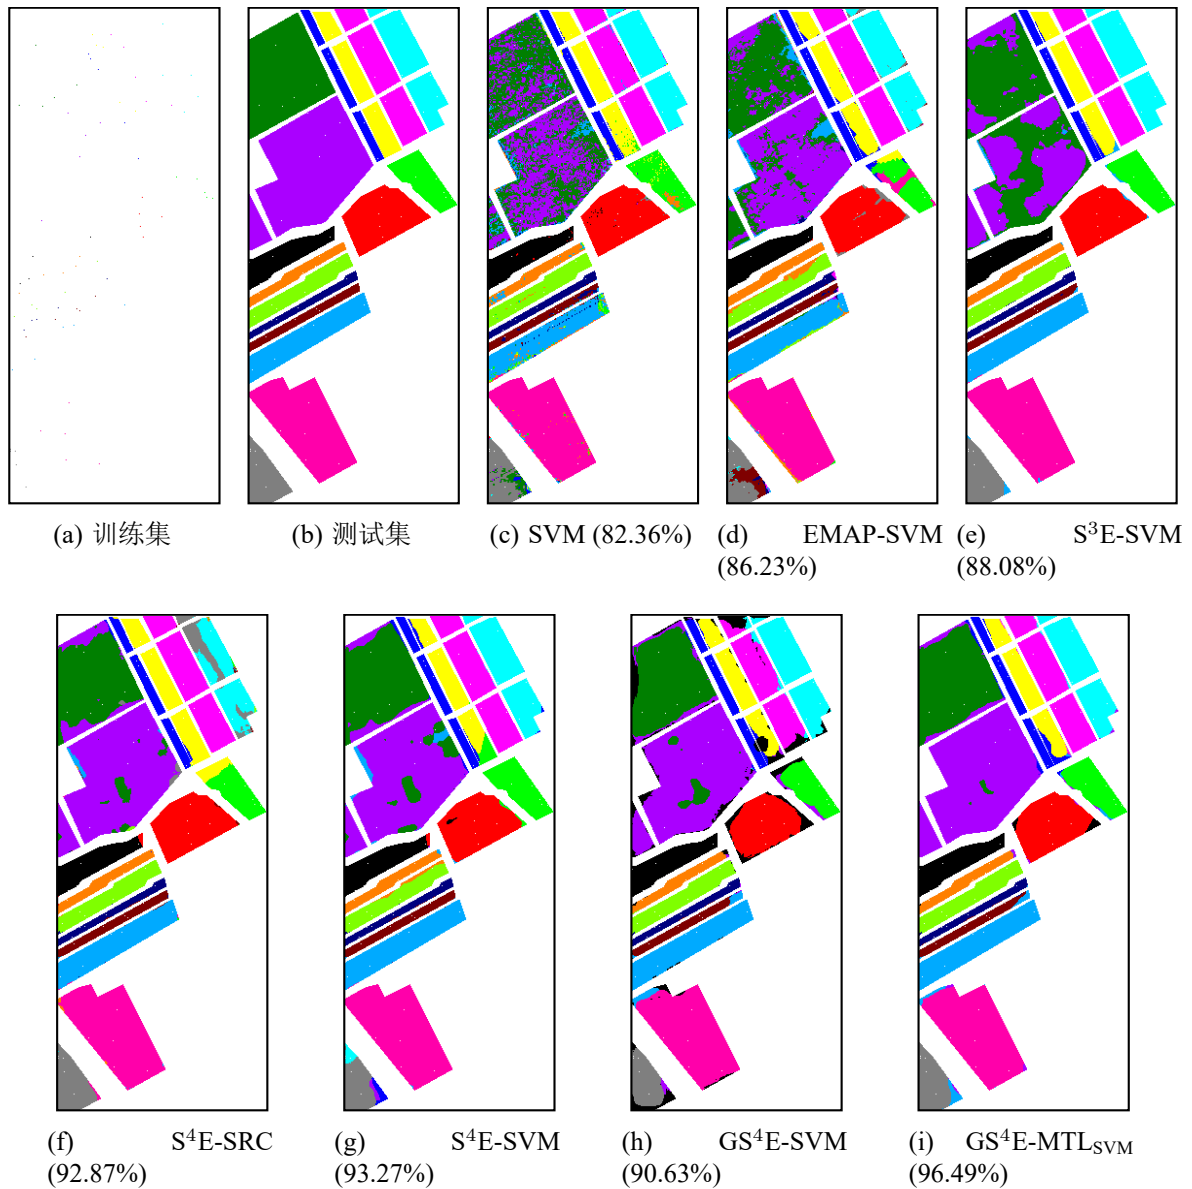


图 3-5 Salinas 数据集：每类 5 个训练样本的分类结果图

在分析训练样本数对分类精度的影响上，如图 3-6 所示，展示了训练样本个数在 5 到 15 以及 20 到 50 上的总体分类精度 (OA) 和 Kappa 系数的变化情况。从图中可以看到，本文提出的 GS⁴E-MTL_{SVM} 方法在所有这些不同大小的训练样本下都能达到最优，尤其是在样本更小的情况下，其优势越明显。从图中我们还可以看到，使用超像素的方法 (S⁴E-SRC, S⁴E-SVM, GS⁴E-SVM, GS⁴E-MTL_{SVM}) 都比单纯使用基于全像素的方法 (SVM, EMAP-SVM, S³E-SVM) 效果好，因为超像素能够充分利用图像的空间信息，特别是在如 Salinas scene 这样地表空间分布集中的图像。

(3) Pavia University 实验数据结果

与前面两个数据一样，图 3-8 展示了在训练样本为每类 5 个的情况下的分类

表 3-3 Salinas 数据集：每类 5 个训练样本的分类精度表 (%)

类别	SVM		EMAP-SVM		S ³ E-SVM		S ⁴ E-SRC		S ⁴ E-SVM		GS ⁴ E-SVM		GS ⁴ E-MTL _{SVM}	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差
C1	97.38	1.94	99.78	0.12	100.00	0.00	96.58	1.11	95.43	1.80	97.98	3.65	100.00	0.00
C2	97.48	1.30	96.71	1.83	90.45	13.50	99.38	0.17	98.99	0.89	92.82	8.50	99.58	1.38
C3	82.36	12.99	63.72	14.61	86.16	15.01	86.77	17.13	95.24	9.37	90.71	11.09	98.90	1.10
C4	97.73	1.70	87.38	11.91	95.30	2.82	87.91	9.67	98.29	1.49	93.43	5.13	98.53	1.72
C5	93.68	4.33	89.18	5.08	86.68	7.78	93.71	5.50	86.13	7.95	85.74	10.46	96.15	3.14
C6	98.30	1.25	95.80	8.63	92.37	16.26	99.70	0.28	99.58	0.59	91.18	9.53	99.38	0.49
C7	99.27	0.37	96.04	4.46	90.62	18.47	92.44	9.56	96.47	3.53	88.77	9.75	97.38	1.76
C8	57.97	9.71	67.22	7.97	42.21	6.85	81.16	14.97	82.44	10.76	81.07	18.57	96.83	5.04
C9	97.33	2.27	90.44	5.58	89.06	6.88	98.34	1.64	98.22	2.90	91.85	9.32	98.36	0.93
C10	77.43	9.60	81.02	8.34	89.51	7.10	95.84	3.87	95.19	4.37	87.87	6.46	96.04	2.64
C11	88.31	4.88	93.35	6.40	99.34	0.17	97.80	1.70	97.62	2.51	93.06	4.55	96.26	2.25
C12	98.88	1.07	88.24	5.38	98.99	0.63	98.19	1.28	94.36	4.03	96.06	6.21	98.53	1.49
C13	97.81	1.56	96.10	0.78	98.54	0.98	99.07	0.88	98.61	1.63	96.82	3.41	99.35	1.08
C14	89.38	3.48	95.47	3.49	96.78	1.12	97.61	2.17	97.11	3.40	93.35	6.06	96.90	3.71
C15	54.62	15.38	68.24	8.12	70.23	16.03	83.50	6.10	82.82	7.70	82.48	13.45	89.02	7.15
C16	86.78	5.89	85.50	12.23	83.09	9.69	94.35	3.97	84.00	5.57	89.61	6.78	96.39	3.19
OA	81.05	1.74	82.48	2.75	80.21	0.98	91.26	2.45	91.27	1.90	88.05	3.74	93.24	1.49
Kappa	0.79	0.02	0.81	0.03	0.78	0.01	0.90	0.03	0.90	0.02	0.87	0.04	0.93	0.01

结果图。从图中可以看出，本文提出的方法的分类结果 3-8(i) 仍能与真实地表分布 3-8(b) 更为一致。不同于其他两个数据的是，在这个数据当中，有些分类方法比如 EMAP-SVM 和 S⁴E-SRC 还不如原始光谱数据的 SVM 方法，这说明，在这个数据当中，这两类方法并不适用于小样本分类。我们知道 Pavia University 数据的空间分辨率特别高 (1.3m)，而且其地表空间分布也比较分散，因此直接使用超像素的方法并不能对其分类结果得到有效的改善，比如使用超像素的图 3-8(g) 不如基于全像素的图 3-8(e)。然而，Pavia University 数据在 Gabor 特征下却能得到有效的改善，如图 3-8(h)，在加上与本文提出的多任务学习策略结合起来，分类性能提升越明显。

同样在每类训练样本为 5 个的情况下，表 3-4 展示了其具体每类的分类精度均值以及标准差。从表中可以看出，尽管本文提出的方法分类精度标准差比较大 (5.68%)，但其分类精度均值 (81.67%) 远远高于其他方法，比如次高的方法 S³E-SVM 的分类精度也只有 75.33%，而且在 9 个类别当中，本文提出的方法有 5 个类别精度达到最优。

当训练样本大小在每类 5 至 15 以及 20 至 50 个时，其总体分类精度 (OA) 以及 Kappa 系数的值如图 3-7 所示。从图中可以看到，本文方法均一致最优，与前两个实

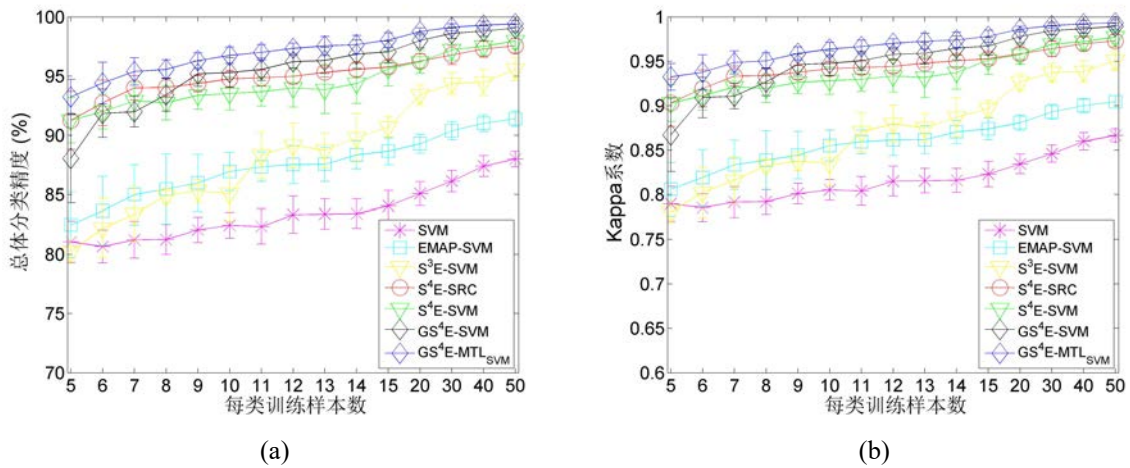


图 3-6 Salinas 数据集：每类训练样本数对分类结果的影响




图 3-7 PaviaU 数据集：每类训练样本数对分类结果的影响

验数据一样，当训练样本越小时，其分类精度就越好于其他的方法，表明由超像素引导的基于 Gabor 特征联合多任务学习的方法在小样本分类上表现良好。

(4) 实验运行时间分析

在最后，给出了所有方法在实验过程中的平均运行时间，如表 3-5 所示 (在计算运行时间的时候，对于需要做特征提取的方法，在重复多次实验的时候只做一次特征提取操作即可)。从表中各方法的运行时间数据可以看出，基于超像素的空谱薛定谔特征映射方法 (S⁴E-SVM) 相对于其基于像素的方法 (S³E-SVM) 在时间效率上得到了显著提升，但是由于单纯地使用光谱特征，其分类性能得到下降。为了解决这个问题，本文提出在 Gabor 特征上进行薛定谔变换，并将其应用于提出的多任务学习框架中进行分类，结果分类精度得到了极大的提升，尽管运行时间上仍然较慢，但相对于原始的 S³E-SVM 方法，已经得到了显著的下降。同时我们也可以从表中看到，随着高光谱

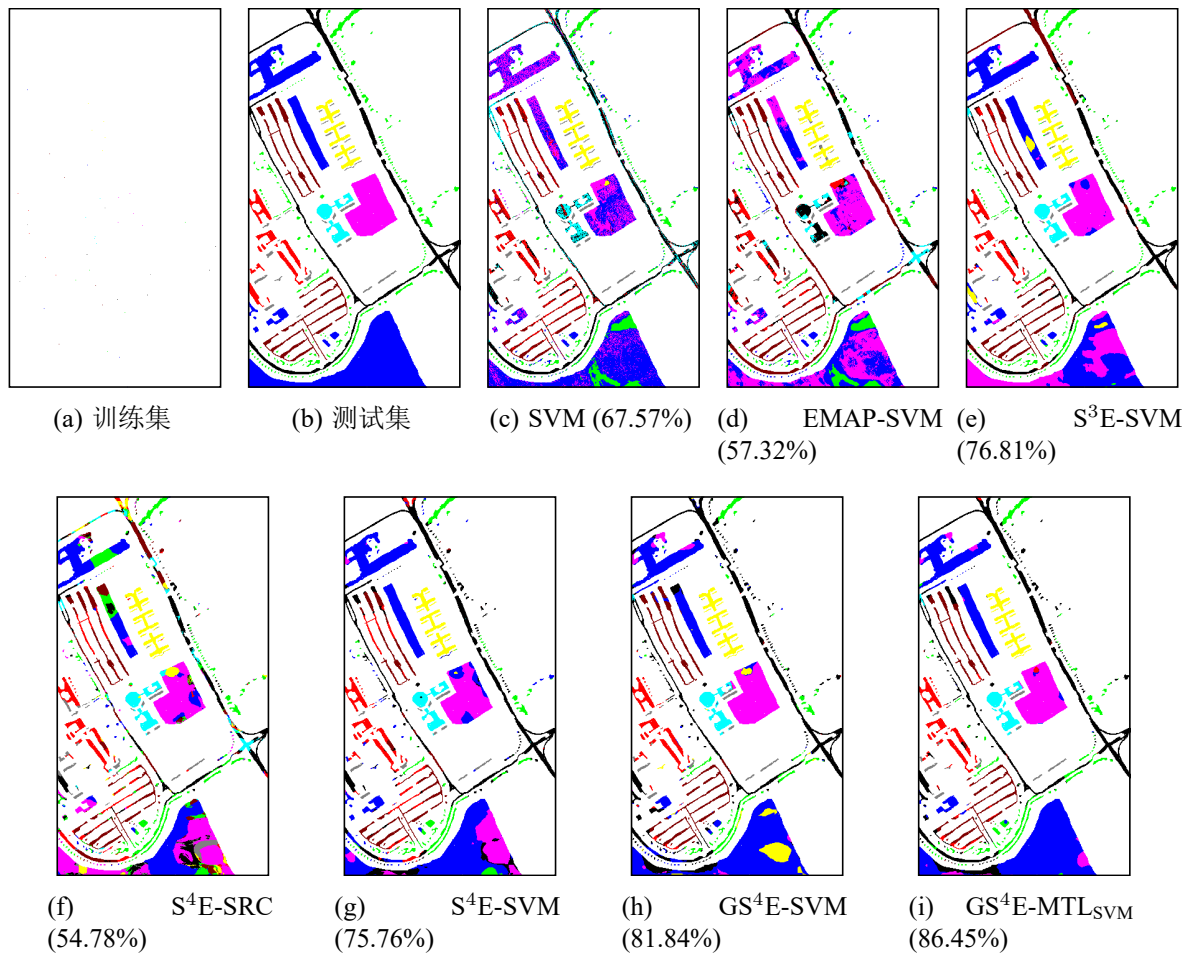


图 3-8 PaviaU 数据集：每类 5 个训练样本的分类结果图

图像尺寸的增大 (Indiana < Salinas < PaviaU), S³E-SVM 方法越发变慢, 本文提出的方法在时间上越突出优势。由于在预测分类结果的时候是对图像所有像素进行预测的, 因此随着图像的增大, 像素点的个数显著提升, 因此基于 SRC 的分类器效率极低, 这也是为什么本文采用基于支持向量机来构建多任务学习的原因之一。

3.5 本章小结

在这一章中, 我们提出了一个超像素引导的高光谱图像特征提取以及多任务学习框架 GS⁴E-MTL_{SVM}。在这个分类框架当中, 一方面, 我们基于空谱薛定谔特征映射的方法所具备的特征表征性强但时间复杂度高的特点, 另一方面, 基于超像素辅助下进行特征提取所具备的快速性但分类精度不优的特点, 从而对这两个方法进行取长补短, 提出了引入 Gabor 特征以及多任务学习的策略。通过本文提出的 Gabor 特征提取, 能够得到更加丰富的空间-光谱特征; 通过构建基于支持向量机的多任务学习框架, 能够把多组特征的代表能力更加充分地发挥。

表 3-4 PaviaU 数据集：每类 5 个训练样本的分类精度表 (%)

类别	SVM		EMAP-SVM		S ³ E-SVM		S ⁴ E-SRC		S ⁴ E-SVM		GS ⁴ E-SVM		GS ⁴ E-MTL _{SVM}	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差
C1	59.20	6.05	55.21	7.20	90.32	7.80	43.12	9.36	60.23	13.53	63.75	19.70	69.76	19.37
C2	48.22	11.78	62.90	14.12	56.14	8.17	52.59	9.92	68.60	11.84	64.96	17.75	85.49	8.41
C3	58.09	16.92	60.96	17.77	57.09	7.96	60.76	18.31	67.34	13.89	73.00	22.54	79.93	12.59
C4	81.88	18.90	91.18	8.28	92.16	1.20	55.24	9.77	72.10	12.70	60.45	15.08	77.45	12.26
C5	94.22	13.06	95.48	4.02	96.22	4.15	94.84	6.84	90.52	6.68	82.64	22.98	97.00	3.98
C6	56.81	8.75	66.28	13.30	83.41	3.67	71.40	14.47	82.46	8.78	85.50	15.28	92.50	9.81
C7	87.38	8.41	81.63	14.77	99.61	0.47	92.02	6.84	96.61	3.63	92.39	4.55	95.39	5.85
C8	60.01	11.02	75.62	16.15	81.12	5.53	78.44	6.05	80.51	10.92	72.64	20.30	84.44	13.63
C9	99.46	0.28	88.23	6.93	89.35	4.97	70.42	16.19	72.94	7.85	60.77	21.66	73.86	13.38
OA	58.63	6.08	67.29	5.18	75.33	2.98	59.09	4.03	71.80	5.64	69.23	6.22	81.67	5.68
Kappa	0.50	0.06	0.59	0.06	0.70	0.03	0.51	0.04	0.65	0.06	0.62	0.07	0.77	0.07

表 3-5 7 个方法的平均运行时间 (秒)

	SVM	EMAP-SVM	S ³ E-SVM	S ⁴ E-SRC	S ⁴ E-SVM	GS ⁴ E-SVM	GS ⁴ E-MTL _{SVM}
Indian Pines	65.74	47.19	250.21	2027.90	39.26	2817.50	120.95
Salinas scene	201.82	41.41	5618.60	2673.30	64.13	3162.50	801.85
Pavia University	41.42	16.72	7917.50	4878.60	56.17	1922.00	967.49

本章最后在三个广泛使用的高光谱图像数据上的实验证明，对比于相关算法，本章算法在对高光谱图像分类上是非常有效的，不仅在时间复杂度上得到了一定的改善，而且其分类性能更是得到了极大的提升。

第 4 章 超像素引导的分类决策融合方法

在高光谱图像分类当中，为了提高分类精度，除了通过提取丰富表征性强的特征以及设计优良的分类器外，另一个可以用来改善分类结果的策略就是使用决策融合的方法，该方法主要是基于高光谱图像丰富的空间信息对其预分类的结果进行改良，以期能够达到更符合真实地面分布的预测图，从而提高分类性能。在这一章中，本文提出了一种基于超像素的软决策融合方法，该方法首先根据高光谱图像的特性进行超像素分割及其合并操作，从而得到符合地表分布的超像素区域；这些得到的超像素区域具备极其高的同质性以及基于对象性，利用这些信息，我们进而提出了一种软决策融合的策略，最终把每一个超像素预测为一个指定类别；在进行软决策融合之前，我们引入了统一模式的局部二值模式 (Uniform Local Binary Patterns, ULBP) 特征作为预分类的特征以及使用支持向量机 (Support Vector Machine, SVM) 分类器作为的基分类器。至于为什么这么融合以及如何融合，本章接下来将对其进行详细的阐述。

4.1 ULBP 特征提取

最近几年来，局部二值模式 (LBP) 作为提取图像纹理特征的一个重要工具^[77]，已经在计算机视觉、图像处理等领域里生根扎底，成为了特征提取领域里面人尽皆知的方法。然而，这些应用主要集中在自然图像的特征提取之中，在高光谱图像上的应用还不够显著。不同于自然图像，高光谱图像的特征是基于像素的，因此，要想使用 LBP 来进行特征提取，必须对其进行针对性的改良。




图 4-1 原始 LBP 值的定义

4.1.1 LBP 算子

LBP 算子是一个局部运算算子，其运算对象是灰度图像。最原始的 LBP 算子定义在一个像素的 8 领域中，通过比对该像素的灰度值大小与其领域像素的灰度值大小来进




图 4-2 几种不同 P, R 值对应的圆环形领域

行编码，分别对其赋予 0 (如果中心像素灰度值大于其领域像素灰度值)，否则为 1。在编码完成后，按照指定顺序对其编码赋予一个编码值，如图 4-1 展示了原始 LBP 编码值的定义。

后面，为了改善其特征提取方式以适应旋转不变等视觉特性，基于旋转半径 R 和模式个数 P 的 LBP 编码得到了广泛地应用。假设，需要进行的编码的中心像素为点 (x, y) ，则其基于 P 和 R 的 LBP 值的定义如下：

$$LBP_{P,R}(x, y) = \sum_{p=0}^{P-1} s(g_p - g_c)2^p, \quad (4.1)$$

$$s(z) = \begin{cases} 1, & z \geq 0 \\ 0, & z < 0 \end{cases}$$

其中， g_c 是中心点 (x, y) 像素的灰度值， g_0, \dots, g_{P-1} 是其圆形领域上的点的灰度值。如图 4-2 所示，显示了在几个在不同 P 和 R 值下的领域点构建形式，其中不落在像素中心的领域点的灰度值将通过双线性插值得到。

4.1.2 ULBP 算子

在实验的过程中，由于 LBP 算子产生的模式编码值很大，共 2^P 个编码，如果把每一个编码值都当作是一个模式的话，则其提取的特征将会特别的大，这对纹理特征提取及其分类过程是极其不利的。为了能够节省时间以及空间上的巨大消耗，同时保证提取的模式更加稳定 (比如不同模式之间可能存在旋转性，但实际上是同一类特征，这意味着使用 LBP 算子得到的模式之间不够稳定)，一种叫统一模式的局部二值模式被提出^[77]，本文将之称为 ULBP 模式。在 ULBP 模式中，那些二进制编码最多只产生两位变化 (0/1 之间的变化)，对于那些超过两位变化的编码都统一标志同一个模式，称为混

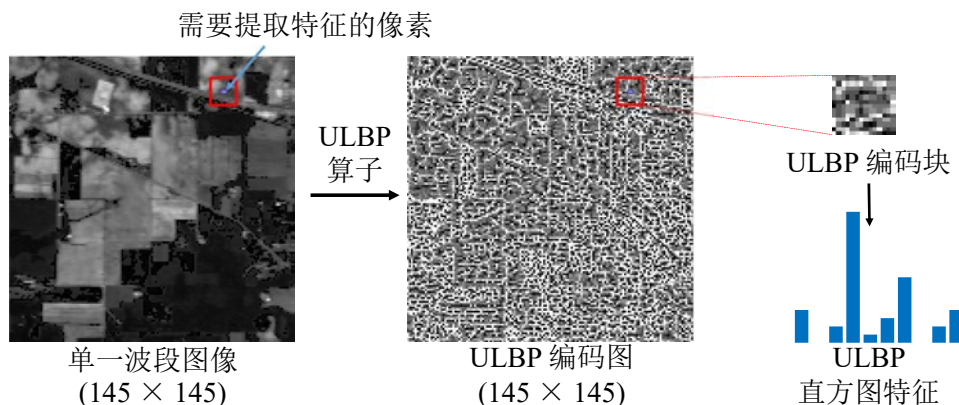


图 4-3 ULBP 在高光谱图像单波段上的特征提取过程示例

合模式。ULBP 模式可定义为如下：

$$LBP_{P,R}^{riu2}(x,y) = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c), & \text{if } U(LBP_{P,R}(x,y)) \leq 2 \\ P + 1, & \text{否则} \end{cases} \quad (4.2)$$

其中

$$U(LBP_{P,R}(x,y)) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)|. \quad (4.3)$$

在这里，函数 $s(\cdot)$ 的定义与等式 4.1 一致。比如，编码 00000000_2 和编码 11111111_2 没有任何的位变化，因此它们的 U 值为 0，而编码 00010000_2 和编码 00011000_2 发生了两次位变化，因此它们的 U 值为 2。

4.1.3 ULBP 高光谱图像特征

对于高光谱图像数据 $\mathbf{R} \in \mathbb{R}^{X \times Y \times B}$ 的 ULBP 特征提取，我们把高光谱图像的每一个波段图像当成是一张灰度图，然后该灰度图可以应用 ULBP 算子得到其 ULBP 编码图，其中每一个像素的 ULBP 编码值代替原来像素的灰度值。通过对每一个波段图像都进行类似的操作，我们可以得到跟原高光谱图像一样大小的 ULBP 编码值立方体。

得到这些 ULBP 编码值立方体之后，我们按波段对每个像素点进行直方图统计，其统计的特征代替该像素点的 ULBP 的编码值，最后将每个波段的统计特征叠加起来便构成了该高光谱图像的 ULBP 特征。如图 4-3 展示了 ULBP 模式在高光谱图像上的特征提取过程，其中示例图中的波段图像是取自 Indina Pines 数据的第 100 个波段图像。

4.2 超像素合并方法

在第二章，我们已经介绍了著名的 ERS 超像素分割算法，我们可以使用它来对高光谱图像进行超像素分割。然而，直接使用该方法分割的超像素难以达到符合地表分布的超像素，这在一定程度上不利于进行超像素融合分类。为了能够生成更直观更基于地物的同质超像素块，在这一节中，我们采用了一种区域合并的策略来进一步获得所需的超像素。本文超像素合并的方法首先使用 ERS 超像素分割算法对高光谱图像进行分割，然后使用基于区域距离度量的方法逐步合并，最终得到所需的分割图。

区域距离度量思想早在多年之前就已提出，并成功应用于高空间分辨率的遥感图像的分割中^[78]。为了能够更好的应用于高光谱图像的分类之中，本文通过借鉴其思想，将其分割任务改进为超像素的生成，使得其不需要达到很好的分割效果，但却能产生同质性更强的大块超像素，这对最终的分类结果具备极大的辅助作用。假设我们已经使用 ERS 算法对高光谱图像进行了分割，并产生了 K 个超像素，那么，我们定义任意两个超像素 (或者叫区域) S_m 和 S_n 的距离为：

$$D_{m,n} = \frac{1}{\|L_{m,n}\|^\gamma} (G_C + G_T) \quad (4.4)$$

其中 $\|L_{m,n}\|$ 表示区域 S_m 和 S_n 的共享边界长度 (按像素个数计算)，因此，如果两个超像素没有挨着，则他们的距离将会是无穷大，相反，如果两个超像素共享边界越长，则他们相似度越高，距离越小。 γ 是调节参数，用来调节共享边界所占的权值。 G_C 和 G_T 分别代表这两个区域的图像原始特征距离和纹理特征距离，它们的计算采用一种称为 G -统计值的测量方法^[77]。 G -统计距离是两个分布之间的距离，对于离散分布来说，就是直方图分布的距离，假设有两个直方图为 m 和 n ，则它们之间的 G -统计值为：

$$\begin{aligned} G_{m,n} = & \sum_{m,n} \sum_{i=0}^{t-1} f_i \log f_i + \left(\sum_{m,n} \sum_{i=0}^{t-1} f_i \right) \log \left(\sum_{m,n} \sum_{i=0}^{t-1} f_i \right) \\ & - \sum_{m,n} \left(\sum_{i=0}^{t-1} f_i \right) \log \left(\sum_{i=0}^{t-1} f_i \right) - \sum_{i=0}^{t-1} \left(\sum_{m,n} f_i \right) \log \left(\sum_{m,n} f_i \right) \end{aligned} \quad (4.5)$$

这里 t 是直方图分布的离散化个数， f_i 则对应于第 i 个频率分布值。

通过使用 G -统计的方法分别对原图像的像素值特征 (如彩色图像的 RGB 特征) 在不同超像素上的直方图分布就得到不同超像素之间的 G_C 值，而 G_T 值则是对其相应的

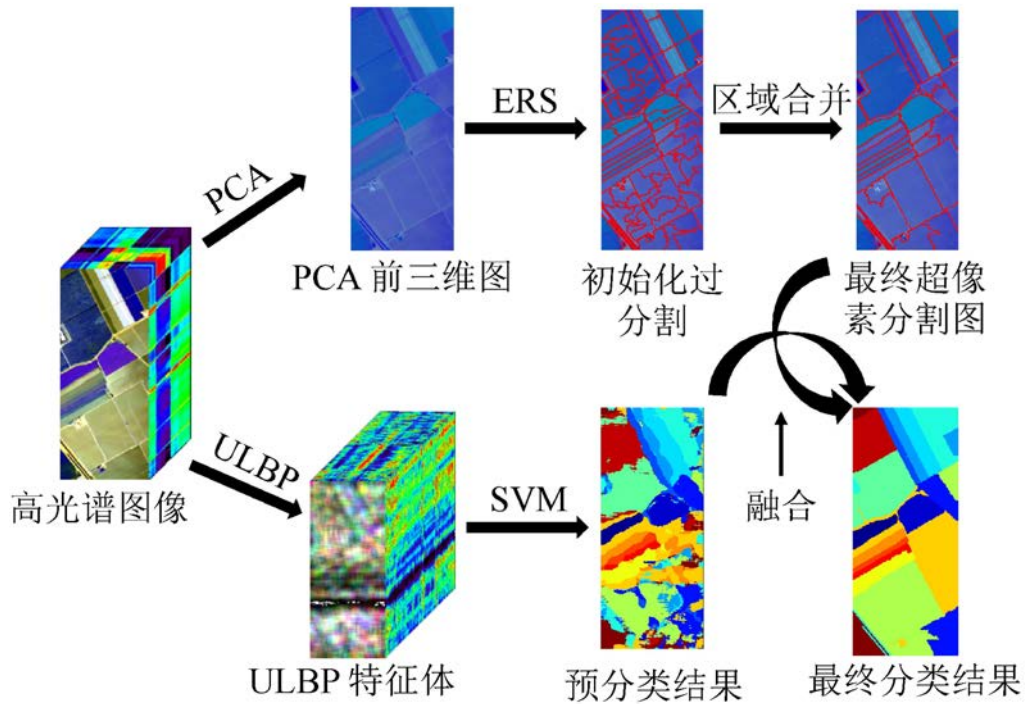


图 4-4 ULBP-SPG 框架示意图

纹理特征 (如 ULBP 特征) 求得, 如果两个区域的直方图分布越相似, 则他们的 G -统计距离就越小, 就越表明这两个区域所对应的地物类别一致。一方面, 纹理特征对边界不敏感, 但对同质区域内部保持极大的相似性, 另一方面, 光谱特征在同质内部具有较大偏差 (噪声影响), 但是对边界上比较敏感, 因此, 通过组合光谱特征和纹理特征, 能够更大程度的反映地物分布的内部相似度和边界区分度。

最后, 超像素 S_m 和 S_n 的代价距离函数定义为:

$$C_{m,n} = \frac{|S_m| \cdot |S_n|}{|S_m| + |S_n|} D_{m,n} \quad (4.6)$$

其中 $|S_m|$ 和 $|S_n|$ 分别是超像素 S_m 和 S_n 内的像素个数大小。如果两个紧紧挨着的超像素都具有类似的大小, 这个时候他们合并代价就越大, 反之, 如果两个超像素大小悬殊, 则很有必要把小的超像素合并到大的那个超像素中。

在超像素合并过程中, 通过求得任意两个超像素之间的代价距离函数, 可以判断出哪两个超像素之间代价距离最小, 然后合并代价距离最小的那两个超像素为一个超像素, 并重复上述步骤, 逐步合并直到满足所需个数的超像素为止。实验证明, 通过这种方法得到的超像素更加规整, 符合地物分布边界情况, 同质性强。

4.3 基于超像素的软决策融合

不同于简单的使用多数表决的方法，本文提出了一种基于概率的软决策融合方法。在上一章中，我们已经介绍了如何利用支持向量机分类器来得到各个预测样本的类别概率，在这一节中，我们将继续使用该方法对 ULBP 特征进行分类。假设提取出的 ULBP 特征立方体为 $\mathbf{M} \in \mathbb{R}^{X \times Y \times L}$ ，通过利用概率输出的支持向量机可以得到每一个像素点 $\mathbf{x} \in \mathbb{R}^L$ 属于每一类的预测概率 $P_c(\mathbf{x}) = P(\xi = c|\mathbf{x})$ ， $c = 1, \dots, C$ ，这将作为预分类结果。

利用 ERS 超像素分割算法对高光谱图像进行过分割，得到 K 个初始超像素，之后，使用超像素合并算法对这 K 个超像素进行合并操作，并得到 M 个最终超像素 $\{S_1, S_2, \dots, S_M\}$ 。对每一个超像素 S_i ，我们把它的的标签预测为：

$$\text{Class}(S_i) = \arg \max_c \sum_{\mathbf{x} \in S_i} P_c(\mathbf{x}), c = 1, \dots, C \quad (4.7)$$

而超像素内所有像素都将预测为与该超像素相同的类别标签。通过这种基于概率视角进行融合的方法我们称之为软决策融合方法，本文将这种方法称为 ULBP-SPG 方法，其实现框架如图 4-4 所示。

4.4 实验结果及分析

4.4.1 实验设置

为了验证本章算法 ULBP-SPG 的有效性，一系列的实验将应用在两个广泛使用的高光谱图形数据 Salinas scene 以及 Indian Pines 中。实验对比了 8 个先进的或者相关的算法，所有算法都采用基于 RBF 核的支持向量机作为分类器(使用 10 折交叉验证)，它们分别是：基准的原光谱特征分类 (RAW)，形态学特征分类 (MOR)^[41]，基于 Gabor 特征的多任务联合学习方法 (GF-MTJ)^[79]，组成多核支持向量机法 (SVMCK)^[80]，基于马尔科夫随机场的多项逻辑回归法 (MLRMRE)^[81]，直接对光谱特征使用 SVM 预分类和 ERS 超像素分割硬决策融合的方法 (SVM-ERS)^[82]，使用原光谱特征代替 ULBP 特征的软决策融合方法 (RAW-SPG) 以及 ULBP 特征分类的方法 (ULBP)。

在本文实验中的参数设置如下：在 ULBP 特征提取中，参数 P 按经验地设置为 8， R 为 1 (最常用)，而进行直方图统计的正方区域块大小为 21×21 ，它的选择大小对结果的影响在实验中进行了分析；在超像素分割中，权衡参数 λ 设置为 0.4，这个参数可以通过算法自动调节^[61]；在超像素合并中，参数 γ 固定为 0.3，此外预分割的超像素个

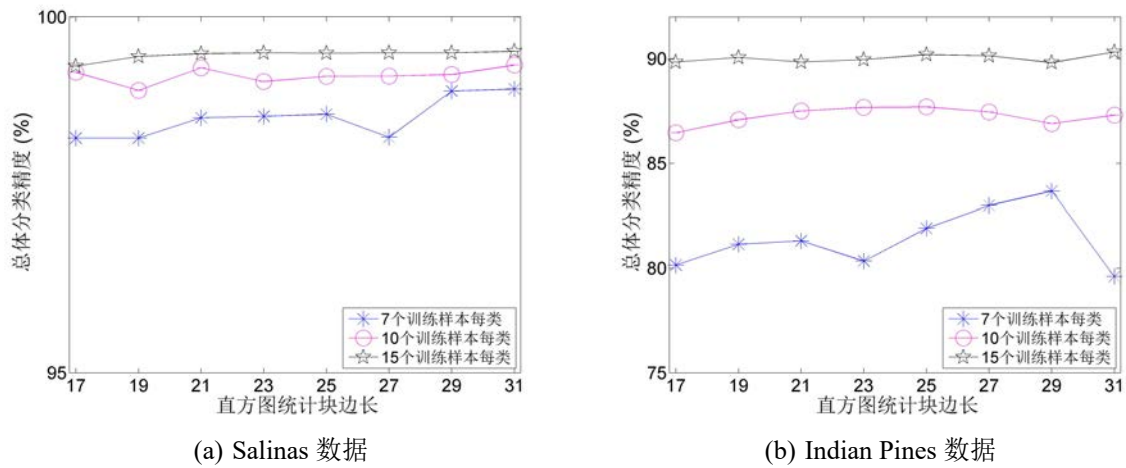


图 4-5 直方图统计块大小对总分类精度的影响

数 K 以及最终的超像素个数 M 是影响实验结果的重要参数，我们将在实验中对其进行分析。其他对比方法的参数设置都使用与原文对应的默认最优参，共享参数的算法之间其值将保持一致。

实验时，每次实验重复 10 次，每次随机选取不同的训练样本和测试样本。实验主要分析了在每类 10 个训练样本的情况下的具体分类结果，同时也给出了在训练样本为每类 7 到 15 个的情况。实验结果评价准则将采用总体分类精度 (Overall Accuracy, OA) 以及 Kappa 系数 (κ) 进行评估。

4.4.2 参数敏感度分析

在实验过程中，我们分析了一些重要参数对实验结果的影响。首先对于在提取 ULBP 特征时所使用的统计直方图特征的统计块大小，我们分析了其对总体分类精度的影响。如图 4-5 所示展示了直方图统计块大小在 17×17 , 19×19 , ..., 31×31 时两个数据上的总体分类精度的变化情况。从图中可以看出当训练样本数越大，其统计块大小对其分类精度的影响就越小，尤其是当每类训练样本数为 15 时，其精度基本上保持稳定，说明在一定的统计块大小范围内，该参数对算法稳定性的影响并不大。在余下所有的实验中，该统计块大小都设置为 21×21 。

实验还分析了初始化超像素分割数量 K 与合并后的最终超像素个数 M 对实验结果的影响，并验证了本文提出的超像素合并对分类精度所起到的显著提升作用。如图 4-6 所示，该图显示了超像素个数对分类精度的影响，其中参数 K 为使用 ERS 超像素分割算法进行预分割时所产生的超像素个数，而参数 M 则为采用超像素合并之后的超像素个数。从图中可以看出，如果直接使用 ERS 算法生成超像素而不采用本文提

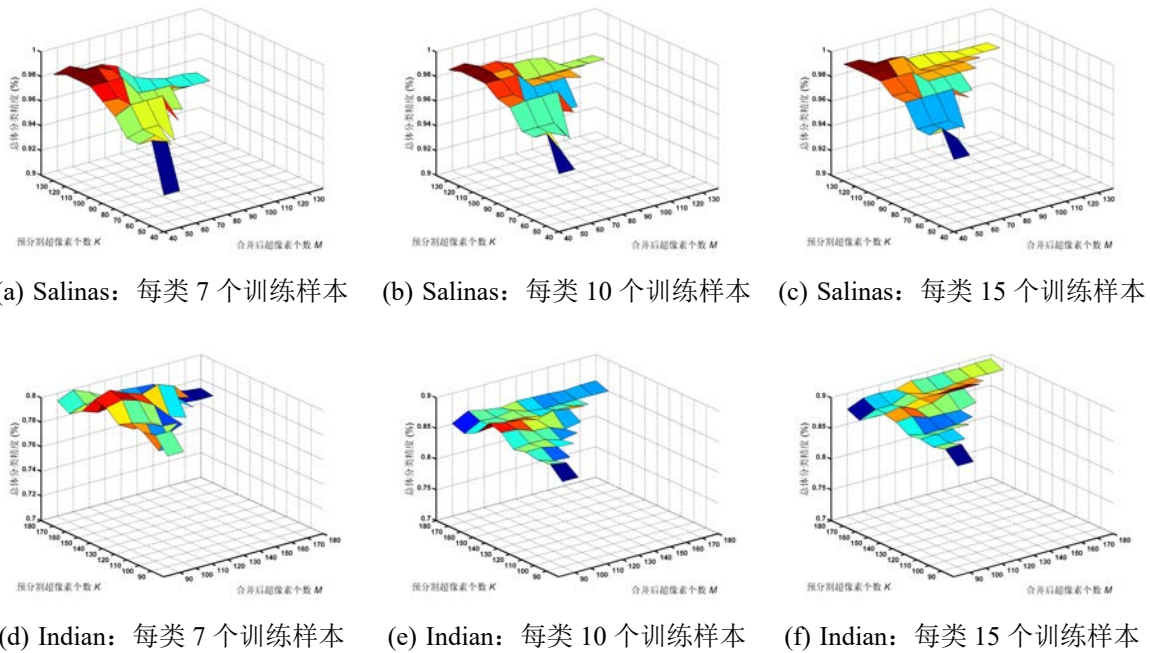


图 4-6 ULBP-SPG 的分类精度随参数 K 和 M 的变换趋势

出的合并算法，则其分类精度(对角线上的精度，因为对角线表示 K 和 M 相等，也即是没有发生合并操作)将显著低于采用超像素合并后的精度(非对角线上的精度)。特别地，在 Salinas 数据集中，可以看出超像素的合并算法的显著优势，因为该数据集地物分布比较均匀，空间信息充足，使用本文算法得到的超像素块更加符合地表分布，如图 4-4 所示。在后续的实验之中，对于 Salinas 数据和 Indian 数据，我们分别把 K 设为 100 和 150， M 为 40 和 100。

4.4.3 实验结果

在这一节，为了测试本文提出的方法的有效性，我们将在两个广泛使用的高光谱图像上 (Salinas scene 和 Indian Pines) 进行实验，并从三个方面上分析了它们的分类结果。首先，实验于每类 10 个训练样本的情况下，分别列出了它们的全像素分类结果图，然后详细列出了具体的类别分类精度和总体分类精度及其分类标准差，最后，给出了在训练样本个数为 7 到 15 的情况下，两个数据在本文算法以及相关的 8 个算法之间的分类精度。实验将对所有的像素进行分类(包括没有标签的像素)，从中充分展现本文超像素在地物分类上的优势。

(1) Salinas scene 实验数据结果

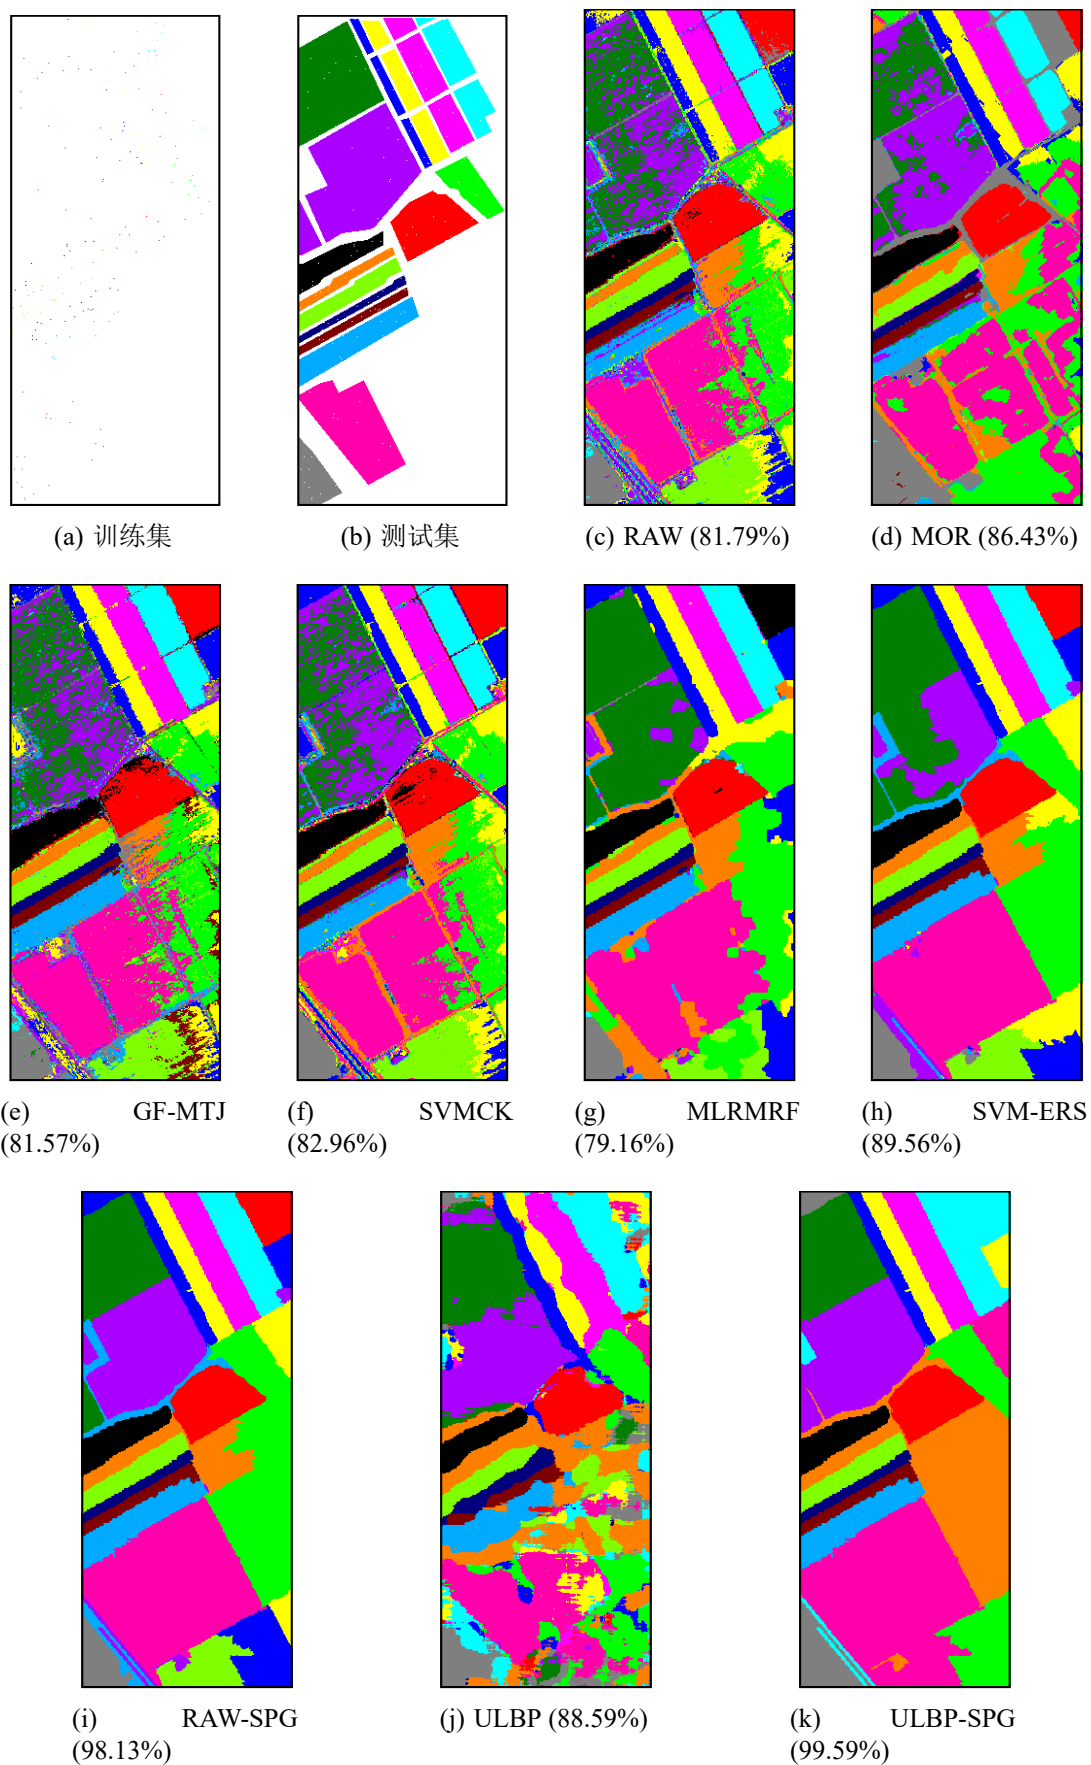


图 4-7 Salinas 数据集：每类 10 个训练样本的全像素分类结果图

表 4-1 Salinas 数据集：每类 10 个训练样本的分类精度表 (%)

类别	RAW		MOR		GF-MTJ		SVMCK		MLRMRF		SVM-ERS		RAW-SPG		ULBP		ULBP-SPG	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差
C1	95.97	4.72	99.79	0.22	98.77	2.14	98.24	1.55	100.00	0.00	100.00	0.00	100.00	0.00	96.79	1.89	100.00	0.00
C2	98.53	1.32	97.49	1.65	98.01	1.96	97.65	2.15	99.48	0.55	100.00	0.00	100.00	0.00	87.33	6.49	100.00	0.00
C3	90.83	7.79	75.49	5.92	91.45	6.48	82.80	13.36	65.51	15.58	100.00	0.00	100.00	0.00	92.94	4.30	100.00	0.00
C4	98.10	1.06	96.00	4.06	98.68	0.41	98.18	0.63	99.47	0.28	100.00	0.00	100.00	0.00	94.31	3.76	100.00	0.00
C5	94.45	2.07	90.76	3.66	96.20	1.83	94.73	1.90	99.01	0.19	98.88	0.02	98.96	0.02	87.99	5.23	98.96	0.02
C6	98.46	1.42	99.17	0.79	99.13	0.77	99.03	0.92	99.85	0.07	99.85	0.01	99.85	0.01	93.87	3.62	99.85	0.01
C7	99.40	0.10	97.48	0.72	99.61	0.15	99.57	0.06	99.85	0.04	100.00	0.00	100.00	0.00	92.05	5.40	100.00	0.00
C8	55.66	11.68	72.48	6.48	58.47	9.39	52.88	14.16	61.05	38.30	72.29	24.69	77.25	37.49	78.95	5.92	98.10	2.79
C9	97.72	1.30	92.81	4.66	96.30	1.74	97.82	0.81	98.05	0.83	100.00	0.00	100.00	0.00	93.55	5.28	100.00	0.00
C10	80.94	7.08	88.66	5.54	91.52	2.99	80.70	9.10	69.72	23.76	91.96	11.67	91.96	11.67	89.20	5.41	97.49	0.01
C11	90.93	2.54	97.62	2.06	96.80	2.28	91.69	2.68	96.07	3.74	100.00	0.00	100.00	0.00	85.57	9.03	100.00	0.00
C12	98.76	1.37	90.93	3.92	99.08	0.62	99.82	0.31	100.00	0.00	100.00	0.00	100.00	0.00	87.17	9.31	100.00	0.00
C13	97.72	1.46	96.26	0.60	98.15	0.68	98.34	0.43	99.09	0.36	98.13	0.03	98.13	0.03	80.42	10.04	98.13	0.03
C14	91.60	2.30	97.31	1.44	94.89	2.91	91.41	1.83	92.92	3.81	97.68	0.05	97.68	0.05	79.58	9.43	97.68	0.05
C15	61.08	10.65	76.50	5.09	62.59	6.59	61.40	13.23	64.18	42.95	74.34	29.07	79.94	42.13	84.41	6.80	99.93	0.00
C16	91.49	3.69	89.27	13.51	95.19	3.66	98.46	1.43	97.35	2.50	99.06	0.02	99.06	0.02	86.47	9.20	99.43	0.49
OA	82.33	1.27	86.89	1.82	84.17	1.93	81.88	2.18	83.30	5.46	90.11	4.69	91.90	8.81	87.23	1.42	99.28	0.58
Kappa	0.80	0.01	0.85	0.02	0.82	0.02	0.80	0.02	0.81	0.06	0.89	0.05	0.91	0.10	0.86	0.02	0.99	0.01

在每类为 10 个训练样本的情况下，图 4-7 展示了本文方法 ULBP-SPG 和 8 个对比方法的全像素分类结果图(单一实验)。从图中可以很明显地看出，相对于测试集(图 4-7(b))，ULBP-SPG 方法得到的预测结果(图 4-7(k))在测试部分基本上与其保持一致，而且从整个地物预测的结果来看，其很好的反映了地表的分布情况，规整且边界划分基本无瑕疵。虽然在这个实验中，RAW-SPG 也能实现如此优良的分类效果(在测试集上)，但通过多次随机实验发现，该方法非常不鲁棒，分类结果具有极大的方差，如表 4-1 所示，通过重复实验 10 次，其分类标准差为 8.81%，而本文方法只有 0.58% 的标准差，这也是为什么本文要使用 ULBP 特征作为预分类特征的原因之一。ULBP 特征的分类结果具有一个显著的特点，就是同质区域内分类良好，但是不同物质边界分类模糊，如图 4-7(j) 所示，而原光谱特征却刚好相反，其分类结果同质区域内很差(导致 RAW-SPG 分类结果方差大)，但边界分类处较好，如图 4-7(c) 所示。正因为 ULBP 特征所具备的这种特性，因此本文对其采用基于超像素的决策融合将可以显著的改善其缺点，并且充分利用其优点，通过对比图 4-7(j) 和图 4-7(k)，可以看到通过引入本文提出的软决策融合策略后，ULBP 特征的分类结果将得到极大的改善，由此证

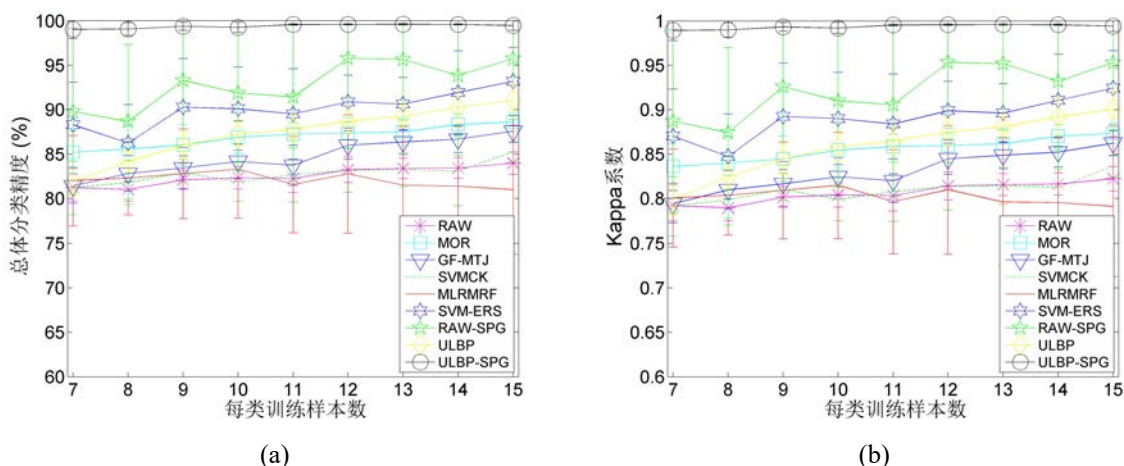


图 4-8 Salinas 数据集：每类训练样本数对分类结果的影响

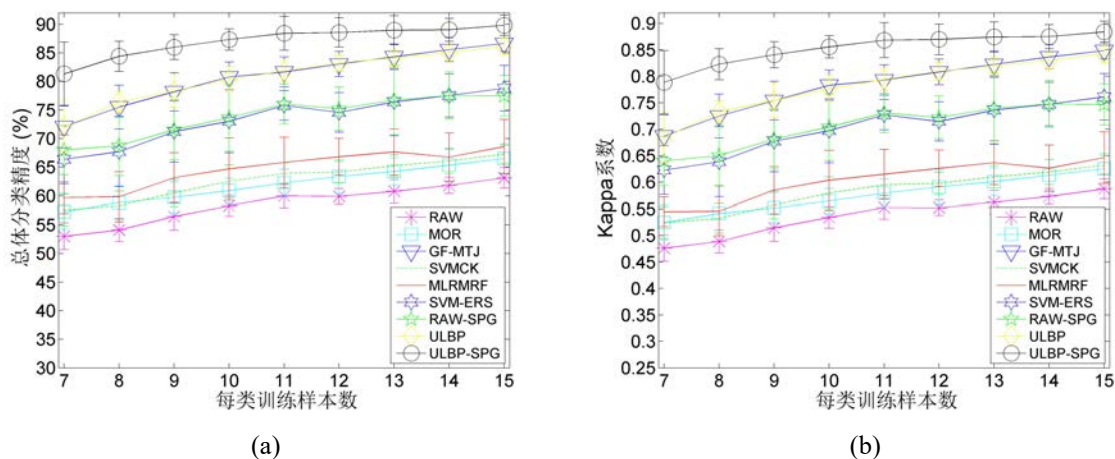


图 4-9 Indian Pines 数据集：每类训练样本数对分类结果的影响

明本文提出的基于超像素的决策融合的有效性。

具体在每一类别的分类精度情况下，表 4-1 显示了当训练样本为每类 10 个时的分类精度及其分类标准差。通过该表可以看到，本文提出的方法在大多数类别上都能得到最优的效果，而且其分类标准差也最小 (0.58%)，说明该方法非常鲁棒。总体分类精度 (OA) 和 Kappa 系数值也表明了本文方法的分类结果与真实场景图的一致性能最好，相对于 ULBP 特征的分类结果，提升了大约 12 个百分点。

图 4-8 展示了在训练样本数为每类 7 到 15 的情况下的总体分类精度 (OA) 以及 Kappa 系数。从图中可以看出，本文的 ULBP-SPG 方法在每类训练样本为 7 个的情况下其分类精度就已经接近 100%，远远高于所有的对比方法。再者，本文方法在所有这些情况下的分类精度都很稳定，表明其鲁棒性很强。该图有效地说明了本文提出的方法在小样本分类中比起相关算法具有显著的改善。

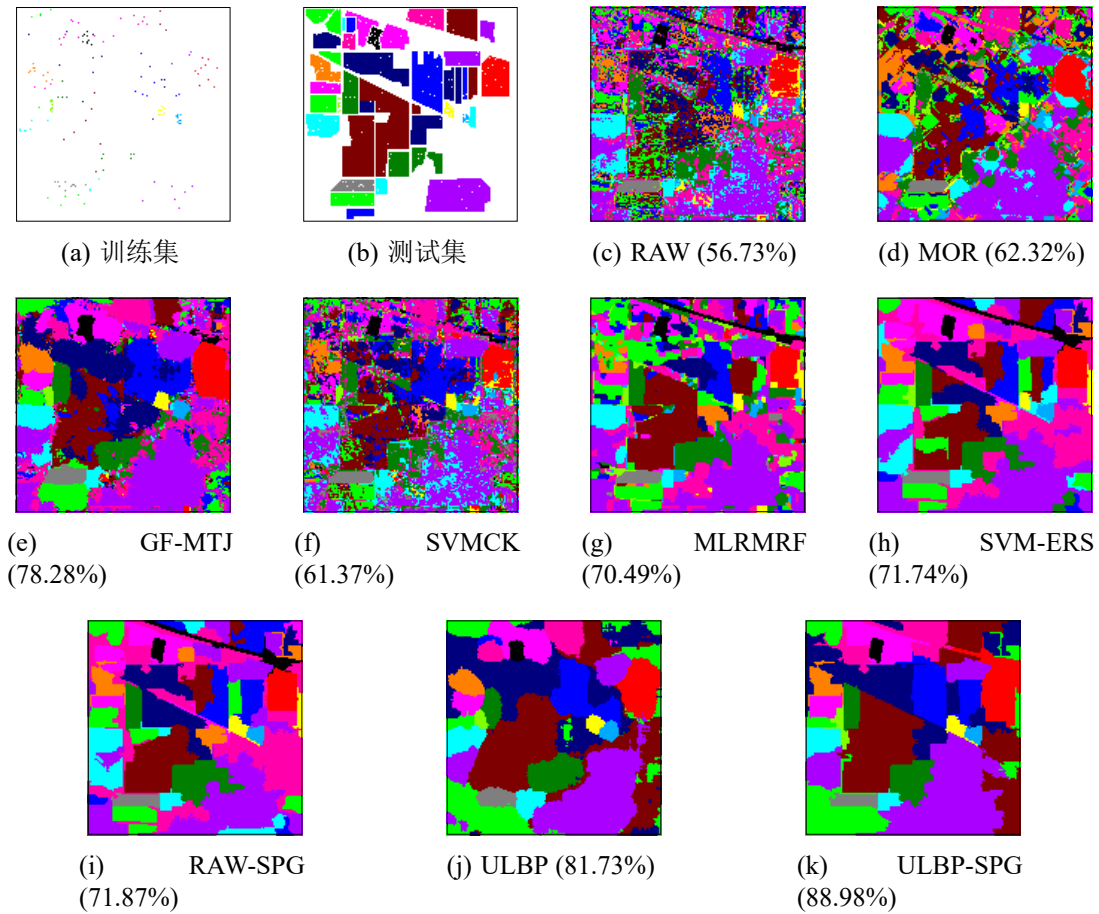


图 4-10 Indian Pines 数据集：每类 10 个训练样本全像素分类结果图

(2) Indian Pines 实验数据结果

同样的，当训练样本为每类 10 个的情况下，在 Indian Pines 数据上的分类结果如图 4-10 所示。其结果显示与 Salinas 数据类似，本文提出的方法的分类结果 (图 4-10(k)) 与测试集 (图 4-10(b)) 最相符。由于 Indian Pines 数据不像 Salinas 数据那样其地表分布如此的规则和均匀，在该数据中其地物分布比价杂乱，而且 Indian Pines 数据的空间分辨率也很低 (20m)，因此，本文算法在该数据上的分类效果并不如在 Salinas 数据上那么突出，尽管如此，对比于相关算法，其分类精度还是有显著性的提升。

在表 4-2 中我们可以看到，虽然每类只有 10 个训练样本，我们的方法仍能达到 87.34% 的总体分类精度以及 0.86 的 Kappa 值，在所有相关算法中遥遥领先，即使对于次好的 ULBP 方法，其分类精度也提升了将近 7 个百分点。同时，我们也可以看到，在大多数类别上，我们的方法的分类精度是最好的，但是本文方法也存在一个缺点，在类别的样本数太小时，如第 10 类 (该类总共只有 26 个样本)，其分类结果会有很大的偏差，有时候精度只有 0 (完全分错)，有时候精度为 100% (完全分对)，其平均精度也

表 4-2 Indian Pines 数据集：每类 10 个训练样本的分类精度表 (%)

类别	RAW		MOR		GF-MTJ		SVMCK		MLRMRF		SVM-ERS		RAW-SPG		ULBP		ULBP-SPG	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差
C1	89.41	6.54	93.06	7.05	100.00	0.00	90.82	7.78	92.47	8.56	99.06	0.50	99.06	0.50	95.53	5.46	99.06	0.50
C2	75.11	7.10	96.01	1.95	99.04	1.31	87.66	6.31	90.79	11.13	90.84	12.59	93.17	16.97	97.08	3.61	99.12	0.75
C3	51.75	5.49	53.68	8.24	68.93	11.36	50.55	5.06	66.26	17.64	72.56	9.35	72.83	10.51	74.00	13.67	85.04	8.51
C4	60.68	8.60	54.87	7.17	76.28	9.44	58.59	6.89	69.26	12.30	73.20	21.56	73.74	20.77	70.54	7.76	84.23	7.10
C5	72.73	7.27	87.50	5.38	100.00	0.00	85.91	6.50	85.00	5.27	90.45	1.79	98.41	1.10	99.77	0.72	98.41	1.10
C6	50.79	7.48	59.69	8.29	78.53	12.86	49.83	6.22	43.53	15.83	78.34	18.12	81.39	11.62	76.26	13.33	83.53	16.06
C7	79.51	8.82	74.31	8.22	84.44	7.81	73.76	9.35	70.49	20.58	85.09	11.13	83.96	10.58	83.68	7.50	86.65	8.25
C8	74.15	8.38	80.95	4.39	95.36	3.00	80.40	7.54	98.89	0.62	92.19	9.52	92.48	9.60	88.76	4.64	94.50	6.34
C9	41.59	8.68	86.38	3.44	89.00	10.70	61.81	7.25	13.70	15.52	57.49	29.00	56.57	28.11	88.54	13.24	89.68	9.90
C10	88.13	6.88	98.13	5.93	99.38	1.98	95.63	5.93	93.75	6.59	18.75	39.53	18.75	39.53	97.50	6.04	38.75	50.07
C11	60.27	7.73	89.51	7.71	99.69	0.73	79.55	10.57	80.49	12.71	92.32	16.19	92.32	16.19	95.54	3.91	100.00	0.00
C12	100.00	0.00	100.00	0.00	100.00	0.00	98.00	4.22	100.00	0.00	100.00	0.00	40.00	51.64	100.00	0.00	80.00	42.16
C13	43.37	5.47	44.44	5.75	72.73	5.64	46.62	4.22	34.35	14.83	51.22	10.54	51.10	9.58	71.61	10.60	76.28	10.27
C14	44.01	6.23	42.78	7.20	69.85	12.26	52.45	8.19	53.30	19.63	59.77	15.80	59.97	18.07	77.41	6.03	86.31	9.06
C15	85.29	5.13	65.73	7.12	95.33	3.31	81.22	8.55	96.81	2.41	93.73	3.05	97.76	0.64	88.41	7.83	92.85	8.94
C16	93.02	3.26	95.84	1.55	99.01	0.93	95.99	2.52	98.61	0.96	100.00	0.00	100.00	0.00	88.02	13.98	100.00	0.00
OA	58.30	1.82	60.90	2.16	80.79	2.62	62.54	2.84	64.71	5.42	73.03	5.53	73.64	5.82	80.37	2.23	87.34	1.86
Kappa	0.53	0.02	0.56	0.02	0.78	0.03	0.58	0.03	0.60	0.06	0.70	0.06	0.70	0.06	0.78	0.03	0.86	0.02

只能达到 38.75%，原因在于，本文提出的方法是基于超像素的分类方法，如果某类样本过于小，会使得在超像素分割时将其全部合并到邻近的超像素，这时候，由于邻近的超像素内的像素个数远超于该类的像素个数，因此合并后的超像素就被预测为邻近超像素的类别，从而导致全部分错，第 12 类 (该类总共只有 20 个样本) 的分类结果也表明了本文算法在此情况下存在的缺点。

观察图 4-9 的分类结果可以看出，当训练样本从每类 7 个增长到每类 15 个时，几乎所有方法的分类精度都呈现出上升的趋势，而在这所有的情况中，我们的方法都能保持领先，尤其是在每类训练样本数为 7 到 11 的情况下更为突出，表明了本文算法在小样本分类上的显著优势。

4.5 本章小结

本章提出了一种超像素引导的分类决策融合方法 (ULBP-SPG) 来改善高光谱图像的分类结果。首先，ULBP 特征提取了高光谱图像的纹理特征，实验结果表明，该特征能够在同质区域内部分类准确，但是却在不同地物边界处产生模糊，原因在于边界

处的纹理特征比较繁杂，导致提取的边界特征不规则，容易影响边界像素的特征表示。因此，如果能够改善 ULBP 特征所具备的缺点，则其分类效果必将得到大幅提升，然而，单单靠提取出优良的边界特征却难以实现。如果通过对高光谱图像进行超像素分割，可以得到边界清晰的超像素块，那么使用该超像素对 ULBP 特征的分类结果进行决策融合，问题便能得到解决。问题在于，如何才能得到边界明确，同质性强的超像素呢？为了解决这个问题，本文采用了先使用 ERS 超像素算法进行过分割，然后对过分割的超像素进行进一步合并的策略得到这些超像素。实验表明，通过合并操作后得到的超像素更加符合地物分布规则，同质性强。为了能让这些符合地表分布规则的超像素最大程度的对 ULBP 特征的分类结果进行修正，本文进一步提出了基于概率视觉的软决策融合方法。这些方法组合起来，便构成了本文所提出的由超像素引导的分类决策融合方法 ULBP-SPG。

实验在两个广泛使用的真实遥感数据表明 ULBP-SPG 方法能够在小样本分类中起到极好的分类效果，对比于 8 个先进或者相关的算法，证明了本文算法的有效性。

第5章 总结与展望

高光谱图像分类是高光谱图像信息处理的一项重要技术，在许多领域如目标探测、农业监测、海洋勘探等方面发挥着重要的作用。然而，高光谱图像分类仍然面临着许多挑战，其中最为显著的一个挑战在于样本数量的缺乏，为了能够在不充足样本的情况下获得更好的分类性能，本文着重研究了在小样本情况下的高光谱图像分类问题。本文首先分析和讨论了高光谱图像分类的研究现状，总结并指出了当今研究工作中存在的主要问题，并以此为基础展开本文的研究，最终提出了两种极其有效的由超像素引导的高光谱图像小样本分类学习框架。

5.1 本文的主要工作和创新点

本文在研究由超像素引导的高光谱图像分类中，主要从特征提取和分类结果决策融合两方面对现有算法进行改良，并分别在这两方面各自提出了小样本分类算法，其具体的工作及其创新点简述如下：

(1) 提出了一种基于 Gabor 特征的超像素引导的高光谱图像特征提取方法及其多任务学习框架。为了充分利用高光谱图像的空谱信息，本文设计了一系列在不同频率和方向上的 Gabor 滤波器，并通过对高光谱图像进行卷积操作得到了多组 Gabor 特征，这些特征通过引入超像素辅助的薛定谔特征变换中最终得到了不仅表征性强而且时间效率上更优的空谱特征。同时，为了能充分利用这些提取的特征，本文接着提出了一种基于支持向量机的多任务学习框架。在这个多任务学习框架上，通过构建由支持向量机分类器输出的类别预测概率表示，并通过组合多组特征的概率输出结果从而实现多任务的分类策略。实验表明该多任务学习框架可以充分利用多组特征的优势，提升了分类性能。

(2) 提出了一种由超像素引导的决策融合分类方法。为了能够得到更加符合地表分布并且同质性强的超像素，本文提出了一种先使用 ERS 算法对高光谱图像进行过分割然后再进行区域合并的超像素生成方法，从而能够得到更大，分布更均，更基于地物类别的同质超像素。同时，为了充分利用这些超像素的空间信息，本文吸收了 ULBP 特征在地物内部分类效果极好的优点，提出了一种基于超像素的软决策融合方法。在这个决策融合方法中，一个基于概率视觉的融合策略把每一个超像素预测为一类(使用支持向量机分类器的类别概率输出)，该方法可以在样本很少的情况下产生极高的分类精度，并且表现鲁棒。

5.2 未来的工作展望

就本文工作而言，相对于传统方法，虽然能够在一定程度上得到较大的改良，但仍存在许多问题需要进一步的研究：

(1) 对算法实时性的研究

在我们提出的两个学习算法中，虽然相比于一些相关方法能够起到更高的时间效率，但是仍然很慢。尤其是在特征提取方面上需要大量的计算时间，这与实际的高光谱遥感图像实时处理相矛盾，为了能够达到更优的时间效率，我们希望在后续研究中在特征提取上进行改善，或许最少数量的超像素将会得到请求。

(2) 对算法鲁棒性的研究

尽管在特定数据和特定参数下，本文算法能够起到较高的鲁棒性，但是并不能说明在更多的数据上或是其他参数上仍能发挥良好。在今后的研究工作中，应该重视理论研究，通过把算法得到的优良改善用理论来证明而不是单单的靠几个实验数据结果，只有当有正确的理论支撑算法时，鲁棒性才能够得到真正的保证。

(3) 对算法自动性的研究

在我们提出的方法中，不管是在超像素引导的特征提取上，还是在超像素引导的决策融合上，我们对算法中超像素个数的选择都是手动的，这不符合实际的操作情况，因为在实际的高光谱图像智能处理中，我们不可能手工地对每个不同的数据都能确定好它们所需的超像素个数。因此，为了使算法更智能和自动化，我们在后续的研究中将对高光谱图像超像素算法进行改良，以便算法能够自适应的产生确定数量的并且同质性强的超像素。

参 考 文 献

- [1] 梅安新, 彭望, 秦其明. 遥感导论 [M]. 北京: 高等教育出版社, 2001.
- [2] GOETZ A F, VANE G, SOLOMON J E, et al. Imaging Spectrometry for Earth Remote Sensing[J]. *Science*, 1985, 228(4704): 1147.
- [3] HILKER T, HALL F G, COOPS N C, et al. Remote Sensing of Transpiration and Heat Fluxes Using Multi-Angle Observations[J]. *Remote Sensing of Environment*, 2013, 137(10): 31–42.
- [4] 苏伟, 李京, 陈云浩, et al. 基于多尺度影像分割的面向对象城市土地覆被分类研究——以马来西亚吉隆坡市城市中心区为例 [J]. *遥感学报*, 2007, 11(4): 521–530.
- [5] LEEUWEN M V, NIEUWENHUIS M. Retrieval of Forest Structural Parameters Using LiDAR Remote Sensing[J]. *European Journal of Forest Research*, 2010, 129(4): 749–770.
- [6] TONG Q, XUE Y, ZHANG L. Progress in Hyperspectral Remote Sensing Science and Technology in China over the Past Three Decades[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 7(1): 70–91.
- [7] ZHANG C, KOVACS J M. The Application of Small Unmanned Aerial Systems for Precision Agriculture: A Review[J]. *Precision Agriculture*, 2012, 13(6): 693–712.
- [8] PELTON J N. Future of Military Satellite Systems[M] // *Handbook of Satellite Applications*. New York, NY: Springer New York, 2016: 1–15.
- [9] BIOUCAS-DIAS J M, PLAZA A, CAMPS-VALLS G, et al. Hyperspectral Remote Sensing Data Analysis and Future Challenges[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2013, 1(2): 6–36.
- [10] 张良培, 张立福. 高光谱遥感 [M]. 武汉: 武汉大学出版社, 2005.
- [11] 童庆禧, 张兵, 张立福. 中国高光谱遥感的前沿进展 [J]. *遥感学报*, 2016, 20(5): 689–707.
- [12] 童庆禧, 王晋年, 张兵, et al. 立足国内开拓创新走向世界——中国科学院遥感应用研究所高光谱遥感发展 30 年回顾 [J]. *遥感学报*, 2009, 13(s1): 21–33.
- [13] 高恒振. 高光谱遥感图像分类技术研究 [D]. 长沙: 国防科学技术大学, 2011.
- [14] 杜培军, 夏俊士, 薛朝辉, et al. 高光谱遥感影像分类研究进展 [J]. *遥感学报*, 2016, 20(2): 236–256.
- [15] 贾森. 非监督的高光谱图像解混技术研究 [D]. 杭州: 浙江大学, 2007.
- [16] CHANG C-I. *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*[M]. New York: Plenum Publishing Co., 2003.
- [17] BAJCSY P, GROVES P. Methodology for Hyperspectral Band Selection[J]. *Photogrammetric Engineering and Remote Sensing*, 2004, 70(7): 793–802.
- [18] JIA X, KUO B C, CRAWFORD M M. Feature Mining for Hyperspectral Image Classification[J]. *Proceedings of the IEEE*, 2013, 101(3): 676–697.

- [19] A. RICHARDS J, JIA X. Remote Sensing Digital Image Analysis[M]. New York: Springer-Verlag, 1999.
- [20] BENEDIKTSSON J A, SVEINSSON J R, AMASON K. Classification and Feature Extraction of AVIRIS Data[J]. IEEE Transactions on Geoscience and Remote Sensing, 1995, 33(5): 1194–1205.
- [21] BAUDAT G, ANOUAR F. Generalized Discriminant Analysis Using A Kernel Approach[J]. Neural Computation, 2000, 12(10): 2385.
- [22] LI W, PRASAD S, FOWLER J E, et al. Locality-Preserving Discriminant Analysis in Kernel-Induced Feature Spaces for Hyperspectral Image Classification[J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(5): 894–898.
- [23] KUO B C, LANDGREBE D A. Nonparametric Weighted Feature Extraction for Classification[C] // Australasian Joint Conference on Artificial Intelligence. 2005: 567–576.
- [24] RODARMEL C, SHAN J. Principal Component Analysis for Hyperspectral Image Classification[J]. Surveying and Land Information Systems, 2002, 62.
- [25] WANG J, CHANG C-I. Independent Component Analysis-Based Dimensionality Reduction with Applications in Hyperspectral Image Analysis[J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(6): 1586–1600.
- [26] 杜培军, 王小美, 谭琨, et al. 利用流形学习进行高光谱遥感影像的降维与特征提取 [J]. 武汉大学学报 (信息科学版), 2011, 36(2): 148–152.
- [27] BELKIN, MIKHAIL, NIYOGI, et al. Laplacian Eigenmaps for Dimensionality Reduction and Data Representation[J]. Neural Computation, 2006, 15(6): 1373–1396.
- [28] HOU B, ZHANG X, YE Q, et al. A Novel Method for Hyperspectral Image Classification Based on Laplacian Eigenmap Pixels Distribution-Flow[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2013, 6(3): 1602–1618.
- [29] CHEN S, ZHANG D. Semisupervised Dimensionality Reduction with Pairwise Constraints for Hyperspectral Image Classification[J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(2): 369–373.
- [30] YANG S, JIN P L, LI B, et al. Semisupervised Dual-Geometric Subspace Projection for Dimensionality Reduction of Hyperspectral Image Data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(6): 3587–3593.
- [31] LIAO W, BELLENS R, PIZURICA A, et al. Classification of Hyperspectral Data Over Urban Areas Using Directional Morphological Profiles and Semi-Supervised Feature Extraction[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(4): 1177–1190.
- [32] JIA S, TANG G, ZHU J, et al. A Novel Ranking-Based Clustering Approach for Hyperspectral Band Selection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(1): 88–102.
- [33] IFARRAGUERRI A, PRAIRIE M W. Visual Method for Spectral Band Selection[J]. IEEE Geoscience and Remote Sensing Letters, 2004, 1(2): 101–106.

- [34] WELCH R M, SENGUPTA S K, CHEN D W. Cloud Field Classification Based upon High Spatial Resolution Textural Features: 1. Gray Level Co-occurrence Matrix Approach[J]. *Journal of Geophysical Research Atmospheres*, 1988, 93(D10): 12663–12681.
- [35] TSAI F, CHANG C-K, RAU J-Y, et al. 3D Computation of Gray Level Co-occurrence in Hyperspectral Image Cubes[C] // *International Conference on Energy Minimization Methods in Computer Vision and Pattern Recognition*. Berlin, Heidelberg: Springer-Verlag, 2007: 429–440.
- [36] REN Y M, ZHANG Y N, WEI W. Hyperspectral Image Classification via Discriminative Sparse Representation with Extended LBP Texture[J]. *Advanced Materials Research*, 2014, 989-994: 3885–3888.
- [37] LI W, CHEN C, SU H, et al. Local Binary Patterns and Extreme Learning Machine for Hyperspectral Imagery Classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(7): 3681–3693.
- [38] BRUCE L M, KOGER C H, LI J. Dimensionality Reduction of Hyperspectral Data using Discrete Wavelet Transform Feature Extraction[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2002, 40(10): 2331–2338.
- [39] SHEN L, JIA S. Three-Dimensional Gabor Wavelets for Pixel-Based Hyperspectral Imagery Classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(12): 5039–5046.
- [40] PLAZA A, MARTINEZ P, GUALTIERI J A, et al. Spatial/Spectral Identification of Endmembers from AVIRIS Data using Mathematical Morphology[J]. *Proc X Nasa/jet Propulsion Laboratory Airborne Earth Science Workshop*, 2001.
- [41] BENEDIKTSSON J A, PALMASON J A, SVEINSSON J R. Classification of hyperspectral data from urban areas based on extended morphological profiles[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(3): 480–491.
- [42] MURA M D, BENEDIKTSSON J A, WASKE B, et al. Extended Profiles with Morphological Attribute Filters for the Analysis of Hyperspectral Data[J]. *International Journal of Remote Sensing*, 2010, 31(22): 5975–5991.
- [43] DUAN W, LI S, FANG L. Spectral-Spatial Hyperspectral Image Classification Using Superpixel and Extreme Learning Machines[C] // *Chinese Conference on Pattern Recognition (CCPR)*. 2014: 159–167.
- [44] LI J, ZHANG H, ZHANG L. Efficient Superpixel-Level Multitask Joint Sparse Representation for Hyperspectral Image Classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(10): 5338–5351.
- [45] FANG L, LI S, DUAN W, et al. Classification of Hyperspectral Images by Exploiting Spectral-Spatial Information of Superpixel via Multiple Kernels[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(12): 6663–6674.
- [46] ZHANG X, E. CHEW S, XU Z, et al. SLIC Superpixels for Efficient Graph-Based Dimensionality Reduction of Hyperspectral Imagery[C] // *SPIE Defense + Security: Vol 9472*. 2015.

- [47] HECKER C, van der MEIJDE M, van der WERFF H, et al. Assessing the Influence of Reference Spectra on Synthetic SAM Classification Results[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(12): 4162–4172.
- [48] CHANG C-I. An Information-theoretic Approach to Spectral Variability, Similarity, and Discrimination for Hyperspectral Image Analysis[J]. *IEEE Transactions on Information Theory*, 2000, 46(5): 1927–1932.
- [49] DU P, XIA J, ZHANG W, et al. Multiple Classifier System for Remote Sensing Image Classification: A Review[J]. *Sensors*, 2012, 12(4): 4764–92.
- [50] KAWAGUCHI S, NISHII R. Hyperspectral Image Classification by Bootstrap AdaBoost With Random Decision Stumps[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(11): 3845–3851.
- [51] SU H, YONG B, DU P, et al. Dynamic Classifier Selection Using Spectral-Spatial Information for Hyperspectral Image Classification[J]. *Journal of Applied Remote Sensing*, 2014, 8(1): 085095.
- [52] ZHU X X, TUIA D, MOU L, et al. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2017, 5(4): 8–36.
- [53] CHEN Y, LIN Z, ZHAO X, et al. Deep Learning-Based Classification of Hyperspectral Data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2094–2107.
- [54] HU W, HUANG Y, WEI L, et al. Deep Convolutional Neural Networks for Hyperspectral Image Classification[J]. *Journal of Sensors*, 2015, 2015(2): 1–12.
- [55] MAKANTASIS K, KARANTZALOS K, DOULAMIS A, et al. Deep Supervised Learning for Hyperspectral Data Classification through Convolutional Neural Networks[C] // *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. 2015: 4959–4962.
- [56] TRAN D, BOURDEV L, FERGUS R, et al. Learning Spatiotemporal Features with 3D Convolutional Networks[C] // *IEEE International Conference on Computer Vision (ICCV)*. 2015: 4489–4497.
- [57] MOU L, GHAMISI P, ZHU X X. Deep Recurrent Neural Networks for Hyperspectral Image Classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(7): 3639–3655.
- [58] SHI J, MALIK J. Normalized Cuts and Image Segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 888–905.
- [59] FELZENSZWALB P F, HUTTENLOCHER D P. Efficient Graph-Based Image Segmentation[J]. *International Journal of Computer Vision*, 2004, 59(2): 167–181.
- [60] MOORE A P, PRINCE S J D, WARRELL J, et al. Superpixel Lattices[C] // *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2008: 1–8.
- [61] LIU M Y, TUZEL O, RAMALINGAM S, et al. Entropy Rate Superpixel Segmentation[C] // *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2011: 2097–2104.

- [62] VINCENT L, SOILLE P. Watersheds in Digital Spaces: An Efficient Algorithm Based on Immersion Simulations[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1991, 13(6): 583–598.
- [63] COMANICIU D, MEER P. Mean Shift: A Robust Approach Toward Feature Space Analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(5): 603–619.
- [64] LEVINSHTEIN A, STERE A, KUTULAKOS K N, et al. TurboPixels: Fast Superpixels Using Geometric Flows[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(12): 2290–2297.
- [65] ACHANTA R, SHAJI A, SMITH K, et al. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274–2282.
- [66] CHEN J, LI Z, HUANG B. Linear Spectral Clustering Superpixel[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3317–3330.
- [67] HUGHES G. On The Mean Accuracy of Statistical Pattern Recognizers[J]. IEEE Transactions on Information Theory, 1968, 14(1): 55–63.
- [68] RICHARDS J A. Remote Sensing Digital Image Analysis: An Introduction[M]. 2nd. Secaucus, NJ, USA : Springer-Verlag New York, Inc., 1993.
- [69] CZAJA W, EHLER M. Schroedinger Eigenmaps for the Analysis of Biomedical Data[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(5): 1274–1280.
- [70] CAHILL N D, CZAJA W, MESSINGER D W. Schroedinger Eigenmaps with Nondiagonal Potentials for Spatial-Spectral Clustering of Hyperspectral Imagery[C] // Algorithms and Technologies for Multi-spectral, Hyperspectral, and Ultraspectral Imagery XX : Vol 9088. 2014 : 908804.
- [71] WELDON T P, HIGGINS W E, DUNN D F. Efficient Gabor Filter Design for Texture Segmentation[M]. Berlin : Springer Berlin Heidelberg, 1994 : 311–324.
- [72] SHEN L, BAI L, AUER D. 3D Gabor Wavelets for Evaluating SPM Normalization Algorithm[J]. Medical Image Analysis, 2008, 12(3): 375.
- [73] SHEN L, BAI L. A Review on Gabor Wavelets for Face Recognition[J]. Pattern Analysis and Applications, 2006, 9(2-3): 273–292.
- [74] GABOR D. Theory of Communication. Part 1: The Analysis of Information[J]. Journal of the Institution of Electrical Engineers-Part III: Radio and Communication Engineering, 1946, 93(26): 429–441.
- [75] WU T-F, LIN C-J, WENG R C. Probability Estimates for Multi-class Classification by Pairwise Coupling[J]. Journal of Machine Learning Research, 2004, 5(Aug): 975–1005.
- [76] ASIF M S. Dynamic Compressive Sensing: Sparse Recovery Algorithms for Streaming Signals and Video[J]. Georgia Institute of Technology, 2013.

- [77] OJALA T, PIETIKAINEN M, MAENPAA T. Multiresolution Gray-scale and Rotation Invariant Texture Classification with Local Binary Patterns[J]. IEEE Transactions on pattern analysis and machine intelligence, 2002, 24(7): 971–987.
- [78] HU Z, WU Z, ZHANG Q, et al. A Spatially-Constrained Color–Texture Model for Hierarchical VHR Image Segmentation[J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(1): 120–124.
- [79] JIA S, DENG B. An Efficient Gabor Feature-Based Multi-task Joint Support Vector Machines Framework for Hyperspectral Image Classification[C] // Chinese Conference on Pattern Recognition. 2016: 14–25.
- [80] CAMPS-VALLS G, GOMEZ-CHOVA L, MUNOZ-MARI J, et al. Composite Kernels for Hyperspectral Image Classification[J]. IEEE Geoscience and Remote Sensing Letters, 2006, 3(1): 93–97.
- [81] KHODADADZADEH M, LI J, PLAZA A, et al. Spectral-Spatial Classification of Hyperspectral Data Using Local and Global Probabilities for Mixed Pixel Characterization[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(10): 6298–6314.
- [82] HE Z, SHEN Y, ZHANG M, et al. Spectral-Spatial Hyperspectral Image Classification via SVM and Superpixel Segmentation[C] // IEEE International Instrumentation and Measurement Technology Conference (I2MTC). 2014: 422–427.

致谢

时间如白驹过隙，一转眼间，便要硕士毕业了，三年的研究生生活，留给我的远不止这篇硕士毕业论文那么简单，更多的是内心的茁壮成长。

首先深深地感谢我的导师——贾森教授对我的信任和支持，更多的是教诲和指导！正是他这种如父爱般和蔼可亲的导师风格，让我能够在学术上与他实现无障碍的沟通，同时，贾老师渊博的知识、敏捷的思维和对前沿方向的洞察力，带领着我走上了从一个科研的初出茅庐者到独立科研者的道路，使我在科研能力和学习能力上稳步提升，研究也逐渐迈向深入。贾老师不仅教给我科学知识和科研方法，他还在我的生活上给予支持。每当我心情低落，身心繁重的时候，他总是可以察觉并给予我亲切的关怀和良性的建议，让我重新振作并继续前行。更重要的是，他正直的人品、脚踏实地的求学态度，不知不觉地影响着我，使我更深刻地明白在科研上宁静致远的道理。保持身体健康和快乐的心情也是我从他那里学到的宝贵财富。

感谢深圳大学计算机与软件学院给了我出国学习的机会，让我进一步开阔了视野，提高了我的人际交往能力以及科研水平。

感谢我亲爱的胡杰和唐贵华师兄，你们是我科研生活上最佳伴侣，有你们的存在，使我的科研生活增添了许多乐趣。感谢胡杰师兄带领我去参加学术会议，开拓了我的眼界，丰富了我的生活。

感谢计算机视觉实验室的小伙伴们和师弟师妹们，是你们让我意识到我不是形单影只的在前行，在以后的日子里我会更加珍惜与你们在一起的时光。

最后，深深地感谢我的父母和我的两个姐姐，你们是我最大的精神支柱，是你们无微不至的照顾我的生活，支持和鼓励我，让我永远做我自己最想做的事。你们无私地付出和默默地奉献是我努力奋斗的最大动力。

攻读硕士学位期间研究成果

论文

- [1] Sen Jia, **Bin Deng**, Jiasong Zhu, Xiuping Jia and Qingquan Li. Local Binary Pattern-Based Hyperspectral Image Classification With Superpixel Guidance. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(2): 749–759. (2017 年影响因子: 4.942)
- [2] Sen Jia, **Bin Deng**, Jiasong Zhu, Xiuping Jia and Qingquan Li. Superpixel-Based Multitask Learning Framework for Hyperspectral Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(5): 2575–2588. (2017 年影响因子: 4.942)
- [3] Sen Jia, **Bin Deng** and Qiang Huang. An Efficient Superpixel-Based Sparse Representation Framework for Hyperspectral Image Classification. *International Journal of Wavelets, Multiresolution and Information Processing*, 2017, 15(06): 1750061. (SCI 收录)
- [4] Sen Jia, **Bin Deng**, Huiming Xie and Lin Deng. A Gabor Feature Fusion Framework for Hyperspectral Imagery Classification. *IEEE International Conference on Image Processing (ICIP)*. 2017: 2394–2397. (EI 收录)
- [5] Sen Jia, **Bin Deng**. An Efficient Gabor Feature-Based Multi-task Joint Support Vector Machines Framework for Hyperspectral Image Classification. *Chinese Conference on Pattern Recognition (CCPR)*. 2016: 14–25. (EI 收录)
- [6] Sen Jia, **Bin Deng** and Xiuping Jia. Superpixel-Level Sparse Representation-Based Classification for Hyperspectral Imagery. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. 2016: 3302–3305. (EI 收录)

专利

- [1] 贾森, **邓彬**, 邓琳. 基于超像素级信息融合的高光谱图像的分类方法及系统. 公开号: C-N106469316A. (实审中)