

# 高光谱遥感影像分类研究进展

杜培军<sup>1,2</sup>, 夏俊士<sup>1,2</sup>, 薛朝辉<sup>1,2</sup>, 谭琨<sup>3</sup>, 苏红军<sup>4</sup>, 鲍蕊<sup>1,2</sup>

1. 南京大学 卫星测绘技术与应用国家测绘地理信息局重点实验室, 江苏 南京 210023;
2. 南京大学 江苏省地理信息技术重点实验室, 江苏 南京 210023;
3. 中国矿业大学 资源环境信息工程江苏省重点实验室, 安徽 徐州 221116;
4. 河海大学 地球科学与工程学院, 江苏 南京 210098

**摘要:** 随着模式识别、机器学习、遥感技术等相关学科领域的发展, 高光谱遥感影像分类研究取得快速进展。本文系统总结和评述了当前高光谱遥感影像分类的相关研究进展, 在总结分类策略的基础上, 重点从以核方法为代表的新型分类器设计、特征挖掘、空间-光谱分类、基于主动学习和半监督学习的分类、基于稀疏表达的分类、多分类器集成六个方面对高光谱影像像素级分类最新研究进行了综述。针对今后的研究方向, 指出高光谱遥感影像分类一方面要适应大数据、智能化高光谱对地观测的发展前沿, 继续引入机器学习领域的新理论、新方法, 综合利用多源遥感数据、多维特征空间互补的优势, 提高分类精度、分类器泛化能力和自动化程度; 另一方面要关注高光谱遥感应用的需求, 突出高光谱遥感记录精细光谱特征的优势, 针对应用需求发展有效的分类方法。

**关键词:** 高光谱遥感, 分类, 支持向量机, 特征挖掘, 多分类器集成

**中图分类号:** TP701 **文献标志码:** A

**引用格式:** 杜培军, 夏俊士, 薛朝辉, 谭琨, 苏红军, 鲍蕊. 2016. 高光谱遥感影像分类研究进展. 遥感学报, 20(2): 236–256

Du P J, Xia J S, Xue Z H, Tan K, Su H J and Bao R. 2016. Review of hyperspectral remote sensing image classification. *Journal of Remote Sensing*, 20(2): 236–256 [DOI:10.11834/jrs.20165022]

## 1 引言

遥感传感器的光谱分辨率不断提高, 人们对地物光谱属性、特征的认知也不断深入, 许多隐藏在狭窄光谱范围内的地物特性逐渐得以发现, 大大加速了遥感技术的发展, 使高光谱遥感成为21世纪遥感领域重要的研究方向之一(童庆禧等, 1985, 2006; Goetz, 2009)。高光谱遥感指具有高光谱分辨率的遥感数据获取、处理、分析和应用的科学与技术, 通常采用覆盖一定波谱范围的成像光谱仪和非成像光谱仪两种传感器获取数据, 利用大量窄波段电磁波获取感兴趣目标的理化信息, 其基础是光谱学(Spectroscopy)(浦瑞良和宫鹏, 2000; 童庆禧等, 2006; Schaepman等, 2009)。成像光谱仪在电磁波谱的紫外、可见光、近红外和中红外区域, 获得大量光谱连续且光谱

分辨率较高的图像数据(有时称为数据立方体), 非成像光谱仪如地物光谱仪则直接获取观测点连续的光谱数据。

高光谱遥感对地观测技术的研究受到世界各国的普遍关注, 国内外已相继研发出大量航空高光谱传感器和星载高光谱传感器。按照相关研发机构的规划, 未来几年内将会有HERO、EnMAP、Flora、FLEX、SpectraSat、MEOS等星载高光谱传感器投入使用(Schaepman等, 2009), 中国高分5号星载高光谱传感器也在研发当中。可以预见未来几年, 星载、航空、低空(无人机)和地面成像光谱仪将提供丰富的高光谱遥感数据。

不同于多光谱遥感, 高光谱遥感能够获取地表物体上百个连续谱段的信息, 提供丰富的光谱信息来增强对地物的区分能力(Chang, 2003)。高光谱遥感在国民经济、国防建设等方面都发挥着重

收稿日期: 2015-01-28; 修订日期: 2015-09-06; 优先数字出版日期: 2015-09-13

基金项目: 国家自然科学基金项目(编号: 41471275); 江苏省杰出青年基金项目(编号: BK2012018)

第一作者简介: 杜培军(1975-), 男, 教授, 研究方向为遥感图像处理与地学应用。E-mail: dupjrs@126.com

要作用,已经广泛地应用于地表分类、目标探测、农业监测、矿物填图、环境管理和国防建设等领域(浦瑞良和宫鹏,2000;张良培和张立福,2005;童庆禧等,2006;张兵和高连如,2011)。

分类是高光谱遥感影像处理和应⽤的一项重要内容,其最终目标是给影像中的每个像元赋以唯一的类别标识。然而,高光谱遥感影像的高维特性、波段间高度相关性、光谱混合等使得高光谱遥感影像分类面临巨大挑战(Shahshahani和Landgrebe,1994)。一方面,由于信号的高维特性、不确定性、信息冗余和地表覆盖的同物异谱及同谱异物,导致高光谱数据结⽤呈高度非线性,一些基于统计模式识别的分类模型难以直接对原始高光谱数据进⽤分类识别。另一方面,在图像监督分类领域,先验样本有限且质量不均一,分类器模型的参数无法估计或估计不准确。在这种情况下,对高光谱影像的准确分类需要建立复杂的数学表达模型以真实地反映数据的内在本质,但模型求解过程往往需要一些繁琐的前处理或后处理。研究和实践表明,当前机器学习、计算机视觉和模式识别理论与方法已成为高光谱遥感影像分类的重要技术手段。

本文结合高光谱遥感影像分类的常用方法、最新进展和发展前沿,在探讨高光谱遥感影像分类策略的基础上,对高光谱遥感影像分类的主要挑战和关键技术、发展前沿和热点论题进⽤综述与分析,探索其发展趋势,以供从事高光谱遥感影像处理与应⽤的研究人员参考。

## 2 高光谱遥感影像分类策略

高光谱遥感影像分类是在常规多光谱遥感影像分类的基础上,结合高光谱影像的特点进⽤目标区分和识别的过程,是对遥感图像基本分类方法的扩展与延伸(童庆禧等,2006)。相对于一般遥感图像分类,高光谱遥感影像分类的特点在于:(1)特征空间维数高,数据相关性强,冗余度高,运算时间长;(2)要求的训练样本多;(3)可用于分类的特征多,既包括直接光谱向量,还可以计算植被指数、光谱吸收指数、导数光谱、纹理特征、形状指数等派生特征;(4)图像的二阶统计特征在识别中的重要性增加。

目前高光谱遥感影像分类采⽤的策略主要包括:(1)以训练样本为依⽤的监督分类与非监督分

类;(2)以分类特征输入为依⽤的分类策略;(3)以像元构成假设为前提的硬分类和软分类;(4)以基本操作单元为基础的像素级分类和对象级分类;(5)以分类器数量为区分准则的单分类器和多分类器集成。

相比于高光谱遥感影像的高维特征数量,参与监督分类的训练样本往往十分有限。当样本数量有限时,往往会出现分类精度随特征维数上升而下降的所谓Hughes现象,或称为维数灾难(Curse of dimensionality)(Hughes,1968)。为了能够得到较好的分类结果,一般训练样本应该多倍于特征维数,甚至使⽤100倍于特征维数的训练样本才能够得到理想的分类结果(童庆禧等,2006)。

针对特征维数高、样本数量少的特点,传统方案是通过波段选择和特征提取进⽤降维处理,将原始数据压缩到低维空间。近年来出现了两种新的解决方案:一是发展适用于小样本、高维特征的分类器,如支持向量机分类器;二是半监督分类,即将半监督学习引入到遥感影像分类中,在已知类别标记的训练样本不足的情况下,将未知类别的样本引入训练过程。

从分类采⽤的特征判据来看,高光谱遥感影像的分类方案包括:(1)直接利⽤原始高光谱数据分类,关键在于将待分类光谱(测试光谱)与参考光谱按照一定的相似性度量准则进⽤分析;(2)先对原始高光谱影像通过波段选择或特征提取进⽤降维处理,然后根据一定的准则选择若干降维后的分量作为分类判据进⽤分类;(3)从原始数据中提取其他特征(如形态学剖面、纹理特征等空间特征),或引入辅助数据,综合采⽤多维特征分类。

硬分类和软分类是高光谱遥感影像分类另外一种常用的划分策略。硬分类(hard classification)将遥感影像中的每一个像素都赋予一个单一类别,划分依⽤是像素特征(光谱特征、纹理特征或多种特征混合)与已知各类别统计特征的相似性。软分类(soft classification)根据像素对应地表范围往往由多个类别地物组成的实际情况,假设每个像素都可能属于多个类别或由多个类别组成,按照特定的算法计算像素与各个类别的关系,分类输出是该像素属于每一类别的概率(模糊分类)、或者每一类别地物(端元)在该像素中的比例(混合像元分解)。

早期遥感影像分类以像素作为基本操作单元。由于以像素为基本单元的分类既不符合地理

空间对象的分布规律, 又不符合人脑认知和解译图像的模式, 近年来基于对象的分类(object-based classification, 有时也称为面向对象的影像分类 object-oriented classification)成为遥感影像分类一个新的研究热点, 并在高空间分辨率高光谱遥感影像分类中得到了应用(Blaschke, 2010)。

通常遥感影像分类往往是选择单一分类器的输出作为最终结果。模式识别的理论和实践都表明, 没有一个模式分类器在本质上优于其他分类器, 最优分类器的选择受到多种因素的影响, 如研究区景观结构、所选择的遥感数据特点、训练

样本或先验知识、分类器本身特点等。针对单一分类器的不足和选择最优分类器的困难, 多分类器系统被引入高光谱遥感影像分类领域, 得到了广泛的应用。不同的分类器对分类提供互补信息, 可以利用这种互补信息来提高识别性能, 把多个分类器的输出联合起来进行分类决策。多分类器系统被视为控制遥感影像分类不确定性、提高分类精度的有效策略之一(Benediktsson 等, 2007; Du 等, 2012)。

根据以上分析, 将高光谱遥感影像分类的技术框架和策略总结为图 1 所示。

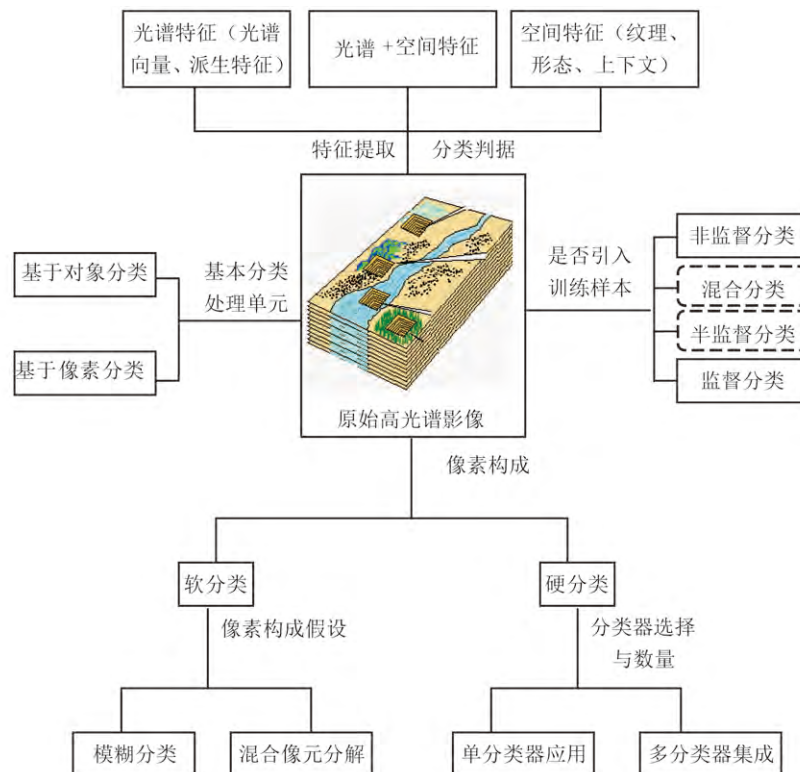


图 1 高光谱遥感影像分类的技术框架和策略

Fig. 1 Technical framework and strategy of classification for hyperspectral imagery

### 3 高光谱影像分类的挑战与进展

高光谱遥感影像分类面临的挑战主要包括(Plaza 等, 2009; Bioucas-Dias 等, 2013; Camps-Valls 等, 2014):

(1) 维数灾难的挑战。在特定的分类器和训练样本条件下, 高光谱影像的分类精度会随着特征维数的增大而呈现先增后减的趋势, 分类器的泛化能力会随着维数的增大而变弱。

(2) 非线性数据结构的挑战。信号的高维特

性、不确定性、信号冗余以及地表物体的异质性等导致了高光谱数据结构的高度非线性, 一些基于统计模式识别理论的分类模型难以对原始高维数据进行分类识别。

(3) 不适定问题的挑战(Shahshahani 和 Landgrebe, 1994)。在统计学习中, 由于已标记样本有限和样本质量不均一, 统计模型往往不足以表达高光谱影像的数据分布, 模型参数无法估计或估计不准确。

(4) 空间同质性和异质性问题挑战。由于真

实地表物体的分布呈现区域性, 相邻位置通常代表相同的物体。然而, 逐像素的分类结果往往与此相违背, 空间先验知识没有在分类问题中发挥作用。因此, 需要引入空间上下文、纹理、语义、对象、形状等特征和知识, 以提高分类精度。

针对这些挑战, 国内外学者一方面充分利用模式识别、机器学习等领域的最新发展和先进算法, 另一方面充分挖掘高光谱遥感数据隐含的丰富信息和特征, 发展了一系列的解决方案, 主要包括:

(1)核变换技术: 可以很好地解决“复杂非线性数据结构”的问题(Melgani和Bruzzone, 2004)。

(2)特征挖掘技术: 能够寻找出有效特征集, 在一定程度上缓解“维数灾难”现象(Jia 等, 2013)。

(3)半监督学习和主动学习用于高光谱影像分类: 解决高光谱影像处理的“不适宜”问题(Crawford 等, 2013)。

(4)光谱-空间分类: 可以综合利用光谱和空间特征, 很好地解决高光谱分类中“空间同质性与异质性”问题(Fauvel 等, 2013)。

(5)稀疏表达: 将高维信号表示成少数字典原子及其系数的线性组合, 在去噪的同时发掘数据本源并对其进行有效表征, 传递字典原子的类别信息, 依据最小重构误差可实现较准确的信号分类。

(6)多分类器集成: 可以解决单一分类器泛化性能差、选择分类器主观性强等问题(Du 等, 2012)。

### 3.1 新型分类器的引入与应用

新型分类器的引入是高光谱遥感影像处理和模式识别、机器学习结合的一个重要方面, 近年来最具代表性的就是支持向量机SVM(Support Vector Machines)、人工免疫系统AIS (Artificial Immune System)等在高光谱遥感影像分类中的应用。

SVM是核变换技术的代表算法之一, 是一种具有精度高、运算速度快、泛化能力强等优点的统计学习新算法, 其主要思想是利用核变换将低维空间线性不可分问题, 转换到高维空间进行准确分类, 广泛应用于遥感数据处理的各个方面。Melgani 和Bruzzone(2004)对SVM在高光谱遥感图

像分类领域中的应用最早开展了试验。为了进一步提高SVM用于高光谱遥感影像分类的性能, 从以下几方面对SVM进行了扩展(见表 1):

(1)针对SVM核函数的研究。Camps-Valls等进一步探讨了核函数在SVM分类器中的作用, 提出了混合核SVMs方法 (Camps-Valls 和 Bruzzone, 2005; Camps-Valls 等, 2006)。将多核学习框架与SVM分类器结合应用于高光谱遥感数据分类, 构建了代表性多核学习方法(Gu 等, 2012)。

(2)多特征综合的SVM分类。针对遥感图像中包含的空间信息, 建立了集成SVMs与马尔可夫随机场的分类方法, 有效地综合了遥感数据中的空间信息与光谱信息(Moser和Serpico, 2013)。

(3)针对小样本学习的半监督SVM分类。将半监督学习与主动学习策略应用于高光谱遥感数据分类中, 可以解决SVMs分类过程中未知样本的标记问题(Persello 和 Bruzzone, 2014)。将主动学习方法应用于SVM高光谱遥感数据分类中, 提出了支持向量边界采样和基于信息熵的Query By Bagging的样本标记方法(Tuia 等, 2009)。

(4)SVM与其他分类器的结合, 如将自组织映射神经网络与SVM相结合的半监督高光谱数据分类方法(Patra 和 Bruzzone 2014)、基于Mean Shift分割的半监督SVM方法等(Tan 等, 2014)。

表 1 SVM在高光谱影像分类的拓展

Table 1 Hyperspectral image classification based on the SVM extension

扩展方法	方法描述	代表文献
核函数扩展	混合核函数	Camps-Valls和Bruzzone, 2005
多特征综合 SVM	空间信息与光谱信息	Moser 和 Serpico, 2013
半监督SVM	小样本学习	Persello 和 Bruzzone, 2014; Tan和Li等, 2014
其他扩展	SVM与其他分类器的结合	Patra 和 Bruzzone 2014

虽然核变换方法在一定程度上取得了较为满意的分类精度, 但是在核函数和最优参数组合的选择方面仍然是一个难点。

另一个有代表性的分类新方法是人工免疫系统。Zhong 等人(2006)提出了应用模拟退火算法和克隆选择算法相结合的遥感影像分类算法, 进一步发展了如非监督人工免疫分类器 (Zhang 等, 2006)、基于克隆选择算法的分类(钟燕飞 等,

表 2 特征提取方法

Table 2 Feature extraction algorithms

提取方法	特征量	方法描述	参考文献
监督特征提取	均值向量/协方差矩阵	LDA, CA等	Richards和Jia, 2006
	正则化非参数提取	NDA, NWFE	Fukunaga和Fukunaga, 1997;Kuo和Landgrebe, 2004
	核函数特征提取	GDA, KLFDA	Baudat和Anouar,2000;Li 等, 2011
	简单波段组合	BG, BG(U), BG(CC), BC	Su 等, 2011; Groves和Bajcsy, 2004; Du和Yang, 2008; Martínez-Usó等, 2007
非监督特征提取	数学变换方法	PCA, MNF, NACP, 分割PCA	Richards和Jia, 2006; Jia 等, 2013
	信号分离的方法	ICA, 小波分析	陈刚 等, 2010
	其他方法	流形学习	杜培军 等, 2011; Xue 等, 2015b
半监督特征提取	SELF	半监督局部判别分析	Liao 等, 2013
	SSDR	成对约束的半监督特征 提取算法	Chen和Zhang, 2011
	SSPCA	半监督概率主成分分析	Xia 等, 2014b

2005)、基于资源有限性人工免疫系统的分类(钟燕飞等, 2006)和基于多值免疫网络的分类(钟燕飞等, 2007), 取得了较好的结果。在分析人工免疫系统原理及其模型特点的基础上, 发展了基于特异识别原理和克隆选择原理的遥感影像信息提取模型, 并应用于遥感影像自动识别和分类(王明常等, 2005)。

多项式逻辑回归MLR(Multinomial Logistic Regression)也在高光谱遥感影像分类中取得了良好的应用效果, 相关研究主要集中在两个方面: (1)针对MLR分类器本身存在的问题, 引入新方法改进分类器; (2)针对MLR的模型特点, 结合不同的技术策略进行分类, 如基于核变换的MLR(MKLR)(Karsmakers等, 2007)、基于稀疏表示的MLR(SMLR)(Krishnapuram等, 2005)、基于光谱-空间信息的MLR分类(Li等, 2010)等。鉴于高光谱分类中的“同谱异物”现象都是不可避免的, 空间信息能够很好地弥补这个不足, 在MLR的基础上根据贝叶斯准则引入表征空间信息的马尔可夫随机场模型作为先验知识, 最后求出后验概率完成分类过程, 进而将稀疏表示(Li等, 2011; Li等, 2013)、子空间投影(Li等, 2012)、软分类(Li等, 2013)等思路融入到MLR分类, 在模式识别新方法应用于高光谱影像分类方面取得了新的成果。

针对人工神经网络训练过程中需要参数的设定、分类速度慢等问题, Huang等人(2006, 2010,

2012)提出了极限学习机ELM(Extreme Learning Machine), 仅通过一步计算即可求出学习网络的输出权值, 与传统神经网络和SVM相比具有较强的网络泛化能力和较快的学习速度, 且精度适当或更高。但由于ELM在构造神经网络时, 参数都是随机选择的, 很大程度上造成了ELM不稳定。为了解决这一难题, 将Bagging和AdaBoost与ELM结合, 提出一种集成极限学习机(Ensemble ELM, E2LM)用于高光谱遥感影像分类(Samat等, 2014)。与核方法结合, 可以构建基于核函数的极限学习机, 与SVM算法比较, 能得到更好的分类精度(Pal等, 2013)。Chen等人(2014)也提出一种结合空间信息和光谱信息的核函数极限学习机, 得到了优于SVM的分类结果。

### 3.2 面向高光谱遥感影像分类的特征挖掘

特征挖掘旨在降低数据维数, 在一个低维空间中对高光谱影像进行分类, 以减弱分类的“不适宜问题”, 根据是否改变原始光谱空间, 包括特征提取(Feature extraction)和波段选择(Band selection)(Chang, 2003; Bajcsy和Groves, 2004)。Jia等人(2013)提出了特征挖掘(Feature mining)的概念, 以此综合特征提取、波段选择和其他用于特征空间重构的运算。

特征提取通过一定的数学模型将若干波段组合为低维的几个特征。在特征提取方法中, 知识引导的特征提取基于对光谱特征的理解对相关波段进行数学运算以获取深层次信息; 然而, 专家

知识往往很难得到,因此发展了一诸多基于统计方法的特征提取算法,关键在于如何构建合适的变换矩阵。依据是否利用先验知识,统计特征提取方法可以分为非监督特征提取和监督特征提取(见表2)。

监督特征提取利用了训练样本数据,通过构建类别可分性函数(线性决策分析、典型相关分析和决策边界特征提取等)(Richards和Jia, 2006; Benediktsson等, 1995)、正则化技术(Kuo和Landgrebe, 2004)和核函数(泛化判别分析、核局部Fisher判别分析)(Baudat和Anouar等, 2000; Li等, 2011)等方法,解决分类中存在的问题。

非监督特征提取算法基于原始数据进行操作,不利用先验知识和训练数据,主要通过波段组合(Bajcsy和Groves等, 2004; Du和Yang, 2008; Martínez-Usó等, 2007; Su等, 2011)、数学变换(张兵, 2004)、信号分离等方法降低特征空间的维数或保留其内部内蕴特征,从而提高分类精度(杜培军等, 2011; Xue等, 2014)。

最近,基于稀疏图嵌入流形学习的特征提取方法受到了关注。在基于稀疏图嵌入的流形学习中,传统方法的图构建过程计算复杂度较高,且未考虑空间信息,不足以充分刻画高光谱遥感影像数据的复杂非线性流形特性。为此, Xue等人(2015a)探索了一种协同稀疏图嵌入方法进行特征提取和分类的方法,一方面采用矩阵运算快速构建稀疏图结构,另一方面引入空间信息,以改进特征提取效果,同时基于协同稀疏图嵌入方法设计了多图嵌入的流形学习方法(稀疏多流形学习),在特征提取过程中有效引入了地物光谱信息的差异,提升了地物在特征空间的可分性。

通常情况下,有标记的样本数据相对较少,如果只使用少量的标记样本,所提取的特征很难具有良好的判别能力。近年来,如何从标记数据以及未标记数据中提取出有用的特征以改善学习性能吸引了越来越多研究者的关注,称为半监督特征提取。主要方法如成对约束方法(Chen等, 2011)、局部缩放切割(Zhang和Gao, 2011)、半监督局部判别分析(Liao等, 2012)和对偶几何子空间(Yang等, 2014b)的方法等。

波段选择目的在于从原始波段集合中选择若干波段构成一个子集,使得后续分析的性能高于或不低于使用原始全部波段得到的结果,其特点

在于保留了各个波段的物理特性。波段选择的关键在于定义何种测度指标作为目标函数,如滤波器型波段选择方法(Filter approach)采用一个独立于后续分类器的信息测度作为目标函数,而封装型波段选择方法(Wrapper approach)则利用一个给定分类器的分类性能进行波段选择。封装型波段选择方法由于利用了分类器的结果评价降维性能,运算复杂度高、运行速度较滤波型方法慢。总体来看,目前滤波型波段选择方法的研究相对较多,依据是否利用先验训练样本,可以分为监督波段选择和非监督波段选择等两类。

监督波段选择方法在构建信息测度目标函数时,利用了不同地物类别的判别能力,即能够反映地物光谱特征的波段应该被选择。但是大部分情况下,地物之间的相似性非常高且实验室光谱数据可能无法获得,这时可以利用训练样本构建目标函数。如利用训练样本信息对类别进行建模的参数型方法,最为典型的是JM距离(Chang, 2003; Ifarraguerri和Prairie, 2004; Richards和Jia, 2006),其他距离也得到了广泛应用,如光谱角、欧氏距离、马氏距离、信息散度(Martínez-Usó等, 2007)、光谱信息散度(Chang, 2000)、正交投影散度、最小估计丰度方差(Yang等, 2011)等。另外,还有一些直接利用训练样本信息的非参数型方法,如互信息(Guo等, 2006)、稀疏条件随机场(Zhong和Wang, 2008)以及核方法等(表3)。

表3 监督波段选择方法

Table 3 Supervised band selection methods

方法	方法描述	参考文献
参数型方法	JM、SAM、马氏距离、信息散度等	Chang, 2003; Ifarraguerri和Prairie, 2004
非参数型方法	信息量、互信息、稀疏条件随机场	Guo等, 2006; Zhong和Wang, 2008

不需要考虑特定应用的非监督波段选择方法中,最简单的是采用SNR作为目标函数的信息测度,利用该方法可以将一部分水汽吸收波段删除。然而,在选择出的不同波段特征中常常存在大量的信息冗余。为了解决该问题,可以利用线性预测LP(Linear Prediction)误差分析方法选择那些与已选子集中最不相似的波段(Du和Yang, 2008),或者利用聚类子空间(cluster space)的方法

进行波段选择, 首先对数据进行聚类, 然后从每一聚类中心中选择一个代表性的波段, 实现波段选择 (Mitra等, 2002)。

除了构建合适的信息测度函数外, 使用何种搜索策略也会对后续的分类结果产生重要影响。一般情况下有3种搜索策略: (1)穷尽搜索: 即在搜索空间内将所有的波段组合均进行评价的算法, 虽然该方法能够搜索到最佳结果, 但算法复杂度非常高, 难以得到有效的应用。因此, 可以退而求其次, 采用次优的搜索方案。(2)贪心搜索: 如针对中等规模的搜索空间, 可以采用分支界定法B&B(Branch and bound) (Narendra和Fukunaga, 1977)、序列前向选择SFS (Sequential forward selection)(Serpic和Moser, 2007)或后向删除法SBS (Sequential backward selection)(Sun等, 2014)进行搜索, 但是SFS和SBS缺乏反馈机制, 某一波段一旦被选定或删除后, 就没法再更改。因此, 具有反馈机制的序列浮动前向选择SFFS (Sequential floating forward selection)(Su 等, 2014a)和序列浮动后向选择SFBS(Sequential floating backward selection)方法可以进一步提高搜索的效率。(3)启发式搜索: 近年来群体智能优化算法也开始应用到高光谱遥感领域, 出现了基于遗传算法(Yao等和Tian,2003)、克隆算法(Zhang等, 2007)、粒子群优化(Yang 等, 2012; Su 等, 2014a)、萤火虫算法(Su 等, 2014b)等的新型波段选择方法。

总体来看, 当前对特征挖掘技术的研究主要集中在特征提取方面, 从统计学、矩阵分析、投影变换、信号分离等角度来研究, “低维流形”已成为当前的热点新技术。波段选择最核心的问题是寻找有效的搜索策略和评价标准。但是, 两种方法也都有其不足之处: 特征提取将特征空间从高维变到低维, 并用少数特征代表原始数据, 需要计算数据的统计特征, 计算复杂度较高, 且计算出来的统计特征不具备物理含义; 波段选择是寻找某个子集来代替原始数据, 在一定程度上丢掉了部分信息, 而且具有局限性, 选择的特征往往只适于某种处理需求。此外, 在特征提取/选择之前, 如何提前确定需选择的特征数目依然是一个值得研究的问题。

### 3.3 半监督学习和主动学习的分类应用

半监督学习SSL(Semi-supervised learning)和主

动学习AL(Active Learning)可充分利用有限的已标记训练样本、挖掘大量未标记像元的信息, 以减弱高光谱遥感影像分类中的“不适定”问题, 利用大量的未标记样本和少量的已标记样本来共同学习, 构建更有效的分类器(见表4)。

表4 半监督学习和主动学习高光谱分类应用  
Table 4 Hyperspectral image classification based on semi-supervised learning and active learning

	方法	代表文献	特点
SSL	自训练	Dopido等, 2013	训练过程易误差累计
	协同训练	Zhang等, 2014b	差异性训练器的构建是难点
	生成模型	Shahshahani和Landgrebe, 1994; Jackson和Landgrebe, 2002	模型优化困难
	低密度分离	Chi和Bruzzone, 2007	主要基于SVM, 计算效率不能保证
	基于图的方法	Camps-Valls等, 2007	可扩展性低, 模型泛化性能不高
AL	大间隔	Patra和Bruzzone, 2011	主动学习方法不依赖于样本聚类假设
	后验概率	Li等, 2011	收敛速度快, 但需要耗费监督员
	基于投票	Tuia等, 2009; Di和Crawford, 2012	额外的人工标记的工作

SSL在高光谱影像分类中的实现方法包括:

(1)自训练(self-training): 在迭代过程中通过某种技术手段不断增加可靠性较高的新样本来反复训练单一分类器, 每个迭代过程结束后分类器用于预测所选择的样本标记信息(Dopido等, 2013)。Tan等人(2014)基于SVM提出了一种高效的自训练半监督方法, 首先利用分割方法获得图像对象, 之后从图像对象中获得可靠性高的未标记样本来不断训练SVM。

(2)协同训练(co-training): 基于不同特征/视图训练具有差异度的分类器, 并利用这种差异性不断训练分类器(Zhang等, 2014)。Jun和Ghosh(2013)基于无参数贝叶斯分类框架提出了一种空间自适应的半监督分类方法, 充分考虑了未标记样本在影像空间上的分布变异性。

(3)生成模型: 采用生成模型建立分类器, 然后利用期望最大化来估计分类器参数(Shahshahani和Landgrebe, 1994; Jackson和Landgrebe, 2002)。Rattle等人(2010)提出了半监督神

神经网络(SSNNs)来快速处理大规模遥感影像。随后, Munoz-Mari等人(2012)利用层次聚类树提出了一种半自动的分类方法, 同时得到分类图和分类结果的置信图。

(4)基于低密度分离的方法: 同时利用无标记样本和有标记样本调整决策边界, 使其穿过各类之间的低密度区域, 如基于核方法的代价效益迭代半监督学习、优化代价函数的半监督支持向量机。(Chi和Bruzzone, 2007; Dundar和Landgrebe, 2004)。为解决SSL对于算法参数和先验知识的依赖性, Tuia和Camps-Valls(2011)基于未标记样本和已标记样本建立线性核, 提出了改进型的 $S^3VMs$ 来简化SSL过程中涉及的参数选择等问题。

(5)基于图的方法: 利用未标记样本通过图对学习过程进行正则化, 通过核复合方法融合空间和光谱信息, 以综合解决样本有限、非线性等问题(Camps-Valls等, 2007)。Li等人(2010)将多元逻辑回归扩展到半监督方式, 采用图方法进行类别标记信息传播, 在高光谱影像分割中取得了较好的效果。

主动学习通过各种启发方式从未标记样本库中选择无偏的、信息量大的样本, 并与少量有标记样本来共同学习更有效的分类器。主动学习可以分为3类方法(Tuia等, 2009): (1)基于SVM的大间隔方法, 如边际选择(Margin sampling); (2)基于后验概率分布的方法; (3)基于投票选择的方法。

Rajan等人(2008)首次将主动学习用于高光谱遥感影像分类, 提出一种基于概率分类模型的主动学习方法, 但由于计算效率问题, 该方法并不能应用于SVM。Tuia等人(2009)改进了基于最小边原则(MS-cSV)和基于投票EQB (Query-by-bagging)的主动学习方法, 选择样本并利用SVM来分类, 以提高原方法的适应性和计算效率。

上述方法在学习迭代时, 每次迭代只能处理一个未标记样本, 计算效率较低, Demir等人(2011)提出了一种批处理的主动学习策略。基于多视图理论, Di和Crawford(2011)将数据正则化引入到主动学习中, 提出了连续共同正则的分类方法。随后, Di和Crawford(2012)提出了基于多视图生成的主动学习方法, 探索了多种视图生成方法, 包括聚类、随机选择和子集切片等。

由于现有的主动学习方法并没有考虑聚类的特性, Patra和Bruzzone(2011)基于SVM提出了一种

聚类主动学习方法。样本的有限性问题可以利用来自不同源的其他样本来弥补, 但是这必然带来分类器重新适应的问题, 为此Tuia等人(2011)利用空间适应的方法, 结合主动学习使分类器可以适应不同源的样本输入。类似地, Persello和Bruzzone(2012)将空间适应(迁移)和主动学习结合并用于高光谱影像分类, 从而解决异源样本的适应性问题。Li等人(2011)改进了breaking ties的主动学习方法并用于高光谱遥感影像分割。进一步, Li等人(2013a)将主动学习用于高光谱影像空-谱分类。

主动学习的核心问题是设计启发式的样本选择方法。对于分类问题, 主动学习的效果较多地依赖于分类器的初始泛化能力, 且在迭代过程中并没有考虑分类器的自适应调整和样本库信息反馈问题, 易出现误差积累的现象。关于主动学习在遥感数据处理中的应用的综述, 可以参考Crawford等人(2013)的文献。

SSL和AL都是通过样本的充分利用来改善分类的“不适宜”问题, SSL更重视样本数量对分类模型的优化, 而AL则更重视样本质量对分类模型性能的提升。因此, SSL和AL在有效利用样本方面可以优势互补, 二者的结合能够进一步提升分类器的泛化性能(Munoz-Mari等, 2012; Dopido等, 2013; Persello和Bruzzone, 2014)。

### 3.4 光谱-空间分类

常规高光谱影像逐像素分类仅仅使用光谱特征而未考虑空间信息, 分类结果往往具有很多离散的孤立点(椒盐现象), 使得分类精度大大下降, 与实际地表覆盖的连续性分布不相符。引入空间信息可以减弱这种现象, 能够获得空间连续性较好且精度较高的分类图。光谱-空间特征相结合的研究已成为当前热点, 核心问题在于如何提取纹理、形状、对象、语义等空间信息, 以及如何有效地将光谱信息与空间特征相结合(Fauvel等, 2013)。纹理特征、马尔可夫随机场(Jackson和Landgrebe, 2002; 李娜等, 2014)、形态学剖面(Benediktsson等, 2003, 2005; 李祖传等, 2010; Ghamisi等, 2014a, 2014b)等是表达空间特征的有效方法。

光谱-空间分类方法根据处理思路的不同可以分为同步处理(simultaneously processing)和后处理



(post-processing)两种策略(Fauvel 等, 2013), 如图 2, 表 5 所示。

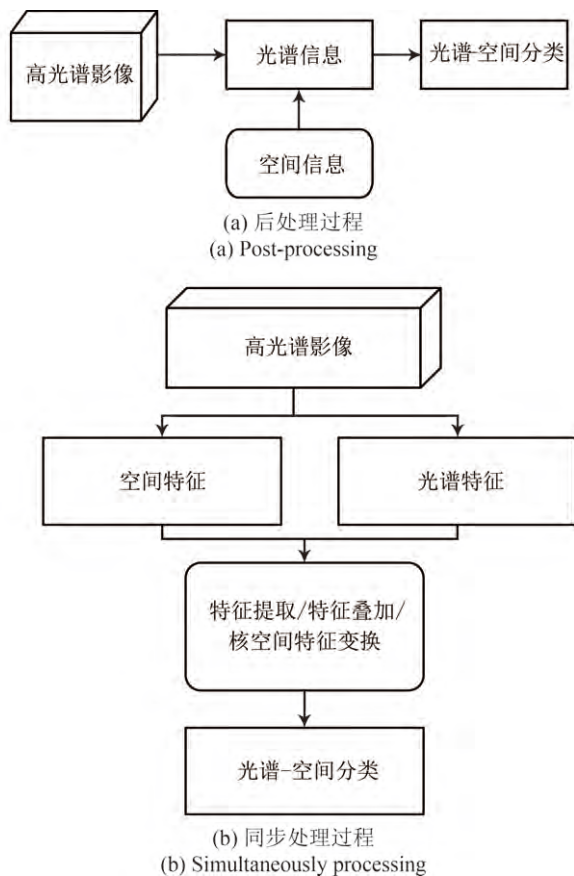


图 2 两种光谱-空间分类处理策略

Fig. 2 Two strategies for spectral-spatial classification

表 5 光谱-空间分类算法

Table 5 Spectral-spatial classification approaches

策略	典型方法	优缺点
同步处理	简单空间特征与光谱特征 的结合	光谱和空间信息充分融合
	多核复合空间和光谱特征 (Camps-Valls和Bruzzone, 2005; Camps-Valls, 2006; Tuia等, 2010; Gu等, 2012; Li 等, 2013b)	增大数据维数和计算复杂 度, 分类过程进一步陷入 不适定问题
后处理	基于聚类方法 (Tarabalka等, 2009, 2011)基于分割的方法 (Tarabalka等, 2010a, 2010b)	方法简单“椒盐噪声”减 弱, 联合监督分类与非监 督分类的优势, 总体分类 精度提高
	隐马尔可夫随机场 (Ghamisi等, 2014c); 超图 方法(Ji等, 2014); 马尔可 夫随机场方法(Li 等, 2011b, 2012; Khodadadzadeh等, 2014)	受分类结果影响大, 若某 一地物的大部分像元被错 分, 利用后处理方法会加 剧这种错误

同步处理策略将提取的空间特征和光谱特征一起输入分类器得到分类结果。这种处理方式涉及特征融合的问题, 通常可采用简单堆栈的方式(串行方式)或特征叠合的方式(并行方式)。串行方式将极大地增大数据维数和计算复杂度, 同时也会使分类过程进一步陷入不适定问题。将空间和光谱信息分别变换到不同的核空间中, 可以通过多核复合来融合空间和光谱特征(Camps-Valls和Bruzzone, 2005; Camps-Valls等, 2006; Tuia等, 2010; Gu等, 2012; Li 等, 2013b)。形态学剖面(Fauvel等, 2008)以及形态学属性剖面在空间特征提取方面(Mura等, 2011)效果明显。

后处理策略是先获得基于像素的初始分类结果, 然后利用图像分割方法对原始分类结果进行逐对象的正则化处理, 以得到空间同质度较高的分类图。常用的分割方法有面向对象提取/同质地物提取(Kettig和Landgrebe, 1976)、划分聚类(Tarabalka等, 2009)、层次聚类(Tarabalka等, 2011)、分水岭分割(Tarabalka等, 2010a, 2010b)、标记控制(Tarabalka等, 2010b, 2012)、区域生长(Tilton 等, 2012)、随机最小生成树(Bernard 等, 2012)、马尔可夫随机场和多元逻辑回归相结合的方法(Li 等, 2011b 等, 2012; Khodadadzadeh等, 2014)、隐马尔可夫随机场(Ghamisi 等, 2014c)以及超图方法(Ji 等, 2014)。正则化处理往往采用简单的多数投票(Tarabalka 等, 2009)方法。

在同步处理方面, 陈善静等人(2013)提出了一种空-谱二维特征蚁群组合优化支持向量机的高光谱图像分类算法。在后处理方面, 耿修瑞等人(2004)利用地物在空间上分布连续这一特性, 提出了一种先分块、再分类的高光谱影像分类方法。李娜等人(2014)利用马尔可夫随机场模型进行光谱和空间信息的融合, 采用基于光谱信息的概率支持向量机方法提高马尔可夫随机场模型中光谱能力函数项的类条件概率估计精度。

总体来看, 光谱和空间特征相结合的分类技术已从简单的特征提取与组合发展到更高层次的特征融合(如基于核的特征融合等)。当前, 基于图像分割的光谱-空间分类方法是研究的热点, 如何从高光谱影像中有效地提取对象特征、如何进行对象标记仍需要进一步探索。

### 3.5 稀疏表示与字典学习的应用

稀疏表达将原始高维信号用尽可能少的非零系数及其相对应的字典原子来线性表示, 大大简

化了信号处理过程。同时, 信号的稀疏编码过程传递了原子的类别标记信息, 为高光谱影像分类开辟了一个崭新的途径。关于稀疏表达原理及其在计算机模式识别中的应用, Wright等人(2009, 2010)进行了详细的阐述。

在高光谱遥感影像处理领域, 稀疏多元逻辑回归方法首先得到应用(Borges等, 2006; Li等, 2013c; Qian等, 2013), 随后有学者进一步提出了稀疏条件随机场模型, 同时选择特征和训练分类模型(Zhong和Wang, 2008和2011)。从信号重建误差最小的角度, 进一步发展了引入空间信息和核变换的分类方法(Chen等, 2011, 2013)。联合协作稀疏表达(Joint Collaborative Representation)(Zhang等, 2014a)是另外一种引入空间信息的方法, 已应用于到高光谱影像分类(Zhang等, 2014a; Li等, 2014a, 2014b)。Yang等人(2014a)提出了双稀疏单层前馈神经网络并用于高光谱影像分类。上述方法在解决小样本的分类方面效果较差。Ul Haq等人(2012)提出了一种快速和稳健的同伦稀疏分类算法。为了充分发掘影像高频和低频成分对影像分类的作用, 提出了基于稀疏表达和形态成分分析的高光谱影像光谱-空间分类方法, 利用基于稀疏表达的形态成分分析模型将特征影像分离成高频和低频成分, 采用SVM进行分类(Xue等, 2015b)。针对传统稀疏表达采用最小重建误差原则进行分类时易导致泛化性能低和未考虑字典学习过程的弊端, 采用带有全变差约束的稀疏表达进行特征学习, 建立类别依赖的字典和SMLR分类器同步优化判别稀疏表达方法, 在引入空间信息的同时提升了分类器的泛化性能(Du等, 2015)。

国内学者在空间-光谱分类方面也做了一些探讨。利用HSI数据构造字典, 借助稀疏表达得到稀疏系数, 以稀疏系数和光谱信息训练随机森林, 并利用投票得到最终分类结果(宋相法和焦李成, 2012), 进一步以稀疏表示和集成为工具, 提出了多标记分类方法(宋相法, 2013)。在字典学习方面, 刘建军等人(2012)通过构造结构化字典, 建立了基于稀疏表示的高光谱影像分类模型, 并添加空间相关性约束来提高分类精度。在引入空间信息方面, 利用稀疏表示和自回归模型, 设计字典, 并用8邻域进行空间约束, 以最小重构误差为准则实现高光谱影像分类(宋琳等, 2012)。针对稀疏表达的非负约束问题, 通过引入随机矩阵来改

善传统稀疏表达分类模型中的测量矩阵以更好满足限制等距特性条件, 同时限定系数向量的非负性以提高重构系数的可解释性(孙伟伟等, 2013)。

但是以上方法没有考虑稀疏矩阵元素之间的联系(如空间位置、结构、物理关系等)。考虑先验知识引导的结构化稀疏表达方法将提高稀疏表达的可解译性、稳定性、可预测性、数值效率(Jenatton等, 2011)。Sun等人(2014b)研究了先验知识引导的结构化稀疏表达与分类方法, 并用于高光谱影像分类。在稀疏表达中, 字典学习过程可以较大地提升稀疏表达效果(Rubinstein等, 2010; Tomic和Frossard, 2011)。Chen等人(2011)、Wang等人(2014)初步研究了高光谱影像稀疏表达中的字典构建(或字典学习)问题。

### 3.6 多分类器集成的应用

多分类器系统 MCS(Multiple Classifier System)通过对分类器集合中的基分类器进行选择 and 组合, 能够获取比任何单一分类器更高的精度, 近年来在高光谱遥感影像分类中得到广泛应用(Kuncheva, 2007; Benediktsson等, 2007; Du等, 2012)。

构建一个多分类器系统, 通常包括确定系统结构、选择基分类器构造方式和选择组合策略3个步骤(Woźniak等, 2014)。多分类器系统结构包括并行结构、串行结构和混合结构等。并行结构直接利用某种策略综合多个单分类器分类结果, 串行结构将前一层的分类结果(类别标签或概率)作为后一层的输入, 混合结构是并行结构和串行结构的综合。目前多分类器系统在高光谱影像分类中的应用以并行结构为主。

Du等人(2012)将支持向量机、决策树、BP神经网络、最小距离分类器和最大似然分类器的输出作为第二层支持向量机的输入, 在OMIS II高光谱遥感影像分类中取得了较高的精度。Bakos和Gamba(2011)构造了一种分层混合决策树的高光谱遥感影像分类算法, 在每个决策树节点, 输入最有效的数据处理链, 通过组合针对特定类别的数据处理链的优点来提高整体分类精度。

多分类器系统基分类器构造方式包括(表6):

(1) 基于不同样本的构造方式。基于相同的训练集, 采用不同的抽样技术得到不同的输入训练样本, 常见算法如Bagging (Breiman, 1996)和AdaBoost(Freund和Schapire, 1996)。Bagging和

AdaBoost对不稳定基分类器如决策树和神经网络等特别有效。Kawaguchi和Nishii (2007) 提出了一个优于支持向量机和神经网络的单层决策树AdaBoost方法。Chan和Paelinckx (2008)将Adaboost决策树算法应用于高光谱影像生态环境制

图, 取得了优于神经网络的性能。Samat 等人(2014) 提出基于快速神经网络—极限学习机 $E^2LM$  (Ensemble ELM) 的多分类器集成算法, 即Bagging和AdaBoost与ELM模型集成, 用于高光谱遥感影像分类, 得到了较好的分类精度。

表 6 多分类器系统用于高光谱影像的典型算法及其优缺点

Table 6 Typical algorithms with their advantage/disadvantage of multiple classifier system applied to hyperspectral images

构造方式	典型算法	优缺点	代表文献
基于不同样本	Bagging-ELM	速度快, 精度提高有限, 但高于Bagging-CART	Samat 等(2014)
	AdaBoost-CART	精度比Bagging-CART高, 但速度慢, 噪声敏感	Kawaguchi和Nishii (2007); Chan和Paelinckx (2008)
	AdaBoost-ELM	精度比Bagging-ELM高, 运行速度慢	Samat 等(2014)
基于不同特征集	Random Forest	精度和AdaBoost-CART相当且较稳定, 所需参数少, 运行速度快	Ham 等(2005); Chan和Paelinckx (2008); Waske 等(2009)
	Rotation Forest	精度比Random Forest高, 运行速度慢, 对参数(子空间数目)敏感	Xia 等(2014a)
	动态子空间集成	精度高于随机子空间, 自动选择子空间特征数目, 但运行时间较长	Yang 等(2010)
	随机子空间SVM	精度高于SVM, 对参数(子空间特征数)敏感	Waske 等(2010)
	分组SVM集成	精度略有提高, 分组数需事先选定	Ceamanos 等(2010)
	旋转SVM集成	精度高于随机子空间SVM, 但运行时间长, 对参数(子空间数目)敏感	Xia 等(2014b)
	分组特征集成	精度提高明显, 但特征提取和空间特征需仔细选择	Du 等(2011)
基于不同数量分类器	动态分类器选择	整体精度提高有限, 局部区域精度提高明显, 运算时间慢	Smits (2002)
	基于光谱和空间信息的动态分类器选择	整体精度优于传统动态分类器选择, 需要设定阈值, 运行时间慢	Su 等(2014c)
	动态分类器系统	精度优于传统动态分类器选择, 但特征提取算法需仔细选择	Damodaran和Nidamanuri (2014)

(2) 基于不同特征集的构造方式。与基于不同样本的构造方式原理一致, 但该构造方式强调对同一训练集的不同特征表达, 可通过随机子空间法等方法来实现(Ho, 1998)。其中最著名的算法是Random Forest (Breiman, 2001)。Ham 等人(2005)探讨了Random Forest在高光谱遥感影像分类中的应用, 提出了二类层次分类器的随机森林分类方案, 通过提高分类器之间的多样性, 提高了分类精度。Chan和Paelinckx (2008)进一步评价了Random Forest 和Adaboost 等集成学习算法在高光谱影像生态环境制图中的应用, 表明二者的分类精度优于人工神经网络, 但Random Forest训练速度更快、分类性能更稳定。Waske等人(2009)在比较支持向量机和Random Forest后, 得出同样的结论, 且Random Forest的参数比支持向量机更容易设定。Xia 等人(2014a) 将另外一种最新的多分类器方法—Rotation Forest用于高光谱影像分类, 并

与支持向量机以及其他多分类器算法包括Bagging、AdaBoost、Random Forest进行了比较, 结果表明, Rotation Forest获取了最高的分类精度。Waske等人(2010) 提出了一种基于随机子空间的支持向量机集成算法, 在训练样本数目较少的情况下较为有效。Ceamanos等人(2010)提出了一种基于支持向量机的分类器集合用于高光谱影像, 首先根据波段相似性将所有波段划分为若干组, 然后对每一组利用支持向量机进行分类, 最后将所有各组的输出采用一个额外的支持向量机进行组合和分类, 其分类精度优于标准的支持向量机。为了进一步提高支持向量机集成算法的性能, Xia 等人(2014b)提出了一种基于旋转策略的支持向量机集成算法。Yang 等人(2010) 提出一种动态子空间集成算法, 能够动态选择参与基分类器的特征数目, 精度优于随机子空间集成算法。Du等人(2011) 将原始高光谱遥感影像按照波段相

似性划分为若干组, 然后对每一组分别应用光谱、空间和特征提取输出等利用不同分类器进行分类, 最后进行决策级融合, 结果表明分类精度优于使用原始所有波段直接分类。

(3) 基于不同数量分类器的构造方式。在多分类器系统中, 一般选择全部生成的基分类器或其子集进行组合生成最终分类结果。由于高光谱遥感影像的复杂性, 基分类器在不同样本区域内的分类效果具有差异性, 这对分类结果会产生一定的影响, 需要利用一些先验知识或统计知识加以调整。针对以上问题, 引入了局部准确率的概念提出动态分类器选择算法, 能够自适应地选择分类器组合及确定分类器权重, 利用分类统计信息指导分类结果的集成判决(Smits, 2002)。Su等人(2014b)提出一种利用空间和光谱信息来确定像素类别的动态分类器选择算法, 分类精度比单纯利用光谱信息的动态分类器选择算法分别提高1.13%和4.47%。动态分类器系统利用特征提取算法, 对不同的基分类器选择最优的数据特征集参与集成, 分类精度优于常规多分类器系统(Damodaran和Nidamanuri, 2014)。

组合策略主要有投票法(Xu等, 1992)、贝叶斯平均法(Kuncheva, 2007)、统计意见一致法(Benediktsson和Swain, 1992)、证据理论(Kuncheva, 2007)和模糊积分法(Abdallah等, 2012)等。Du等(2012)对这些组合策略进行了全面比较, 发现其精度相当, 但投票法操作简单且无需先验知识, 因此在多分类器系统中得到广泛应用。

## 4 结 论

综合以上相关研究的进展和动态, 高光谱遥感影像分类主要呈现出以下发展趋势:

(1) 新型分类器与分类算法研发仍然是高光谱影像分类的主要研究方向, 特别是模式识别、机器学习领域的新理论、新方法将在高光谱影像分类中得到更多应用。可以预期, 随着模式识别、机器学习的快速发展, 各种新方法必将在高光谱遥感影像分类中得到广泛应用, 尤其是主动学习、半监督学习、迁移学习、集成学习等将得到更深入的应用。

(2) 多特征综合、多数据融合、多尺度复合将有助于提高分类精度。最近几年空间-光谱特征综

合的分类是一个研究热点。由于高光谱遥感影像在获取方式等方面的局限性, 将其与其他数据如LiDAR、SAR和高分辨率影像等融合, 将进一步提高分类精度。针对不同的地物目标特征和分类需求, 采用数据驱动的多尺度复合分类方法, 充分发挥高光谱遥感影像在感兴趣目标类别精细划分方面的优势, 将使高光谱影像分类与实际应用需求更加结合紧密。

(3) 泛化能力强的分类方法是需要进一步研究的方向。尽管目前已提出许多新的高光谱遥感影像分类方法, 但由于各种算法本身的理论限制或高光谱遥感影像的特点, 导致算法普遍存在泛化能力弱的问题, 研究和构建泛化能力的分类方法强的分类器是一个重要的方向。一方面需要对单一分类算法进行优化, 使其能够适应更多样性、更复杂的情况; 另一方面是充分利用多分类器系统的优势, 深入研究多分类器集成的方法与应用, 综合多分类器的优势, 获得更稳定的分类性能。

在总结高光谱遥感影像分类国内外研究进展和热点的同时, 也需要进一步思考和探索以下问题:

(1) 在继续研究新型分类方法的同时, 要更加重视高光谱遥感的核心优势和本质特征。从相关研究来看, 当前高光谱遥感影像分类的研究发展迅速, 吸引了多学科研究人员的兴趣, 新算法层出不穷, 精度不断提高。但一个非常明显的趋势是: 在高光谱影像分类方法方面, 占据主导地位的是模式识别、电子信息、人工智能等领域的研究成果, 重点是将高光谱遥感影像作为一种典型的高维数据集, 研究和构建高维数据集、小样本情况下能够获得高精度的分类算法, 而对于分类结果是否具有地学解释、分类过程中采用的特征是否有地学意义、分类算法是否有可能得到实际应用, 却缺少足够的重视。特征提取算法越来越复杂、数学模型越来越高深、分类模型越来越先进、分类精度越来越高, 但仅仅是在数据处理层次的提升和进步, 在信息提取、知识提供方面却明显不够, 导致相对应用需求来讲, 高光谱遥感影像分类(甚至其他处理)方法高深而不实用。当分类理论、方法非常先进的时候, 理应重新回归高光谱遥感的本质特征和核心优势: 即以连续的窄波段反映地面目标的精细光谱特征及与其关联的

物理化学特性, 重视高光谱遥感影像处理的地质解释和意义, 逐步跳出单纯的数据处理和影像分类, 走向信息提取和知识提供, 为高光谱遥感的高水平、深入应用提供支持。

(2)在研究通用分类方法的同时, 应该重点研发针对特定应用相关的分类算法, 以保持高光谱遥感的应用竞争力。高光谱遥感来源于应用需求, 特别是在岩性识别、地质填图、精细农业等方面的成功应用极大地促进了其发展, 但如果单单从用户的角度审视, 目前得到广泛应用并取得良好效果的分类型算法, 却仍然是经典的光谱角制图模型SAM或者简单的二值编码分类等。一些新型的分类器中, 基于不同岩石、矿物光谱精细特征分层识别谱系构建决策树取得了较好的效果, 先进的分类器甚至包括近十年来最为热门的支持向量机成功应用的实例还比较少。毫无疑问, 其中一个关键的问题就是多数分类算法仅仅是从高维数据的角度考虑, 而没有从应用需求出发, 在具有大量先进算法的背景下, 以“解决问题”为需求的“应用驱动”高光谱影像分类, 应该逐步成为一个关注的热点。例如, 在岩性识别和矿化蚀变信息提取方面, 大量研究表明主要的敏感波段集中在近红外波长区间, 因此在降维和分类中应该考虑如何充分发挥这一波长范围内波段的特性而抑制其他波段的影响, 同样针对典型矿物或蚀变信息的区分, 应该充分考虑这些波段和特征, 发展具有针对性的分类算法。又如在农业高光谱遥感中, 重点关注的波段主要集中在与植被光谱特性密切相关的绿光、红光和近红外波长范围, 这些在多光谱遥感中仅用3—5个波段记录的信息在高光谱遥感中具有几十个波段, 分类中应充分体现这些波长范围内的光谱特征和通过相应波段提取的空间特征, 突出主要信息, 避免其他应用效果不明显的波段在其中的影响甚至是干扰。将先类算法与特定的应用需求结合, 充分发挥先验知识、精细光谱特征等的作用, 实现应用驱动、知识引导的处理, 应该得到高度的重视。

(3)什么情况下选用高光谱遥感数据, 需要进一步思考, 应该选择最“适用”的分辨率而非最“高”的分辨率。现在有些研究工作陷入了过分追求“高分辨率、精度突出、尖端仪器(数据)”的“高精尖”目标, 分辨率越高越好, 在光谱分辨率方面也是过分强调高光谱遥感。对于涉及高光谱遥感的研

究同样如此, 要从目标任务和应用需求出发, 确定使用的数据源, 如果能够用同样空间分辨率(甚至更优)的多光谱影像实现目标, 是否还有必要追求价格更昂贵、获取更困难、处理更复杂的机载、星载高光谱影像? 答案显然是否定的, 因此结合高光谱遥感影像处理研究、遥感应用实践中存在的“鸿沟”, 选择合适的数据、明确应用的目标、研发适应的算法, 以较低的成本、简单的方式解决面对的问题, 值得进一步探索和推动。

(4)在高光谱遥感影像分类中, 往往是以一个像素作为分类单元, 但实际应用需要的信息往往是由对象组成的, 为了实现对象的分类, 首先必须合理表达这一对象, 即必须抽取一些特征来表达对象。同时, 在大数据时代, 可否可以通过海量数据挖掘对象的特征让其为我们所用? 近年来发展迅速的深度学习将特征和分类器结合到一个框架中, 自动地从大量数据中学习特征, 在使用中减少了手工设计特征的巨大工作量(Deng 和 Yu, 2014)。深度学习(即所谓“深度”)和大数据(即所谓“广度”)结合, 提供了一个深度思考的大脑, 而高光谱(可称“高度”)给了智能地学分析一个强健的躯体, 三者协同, 将引发“大数据+深度模型+高光谱”的融合与集成。

(5)结合智能化高光谱对地观测系统的发展, 分类算法的智能化、高效化仍是需要重点解决的问题。智能化高光谱遥感对地观测系统(张兵, 2011)是链接高光谱数据自适应采集、星上处理、智能信息提取的重要体系, 如何将各种分类技术与智能观测系统结合, 结合半监督学习、迁移学习等先进学习方法, 实现已有样本的重用, 提高自动分类精度, 是一个重要的发展方向。另一方面, 目前一些先进的智能分类算法往往效率较低, 难以适应大数据量的要求, 高性能计算、并行处理等是实现海量高光谱遥感数据高效处理的重要支持(Plaza等, 2011), 因此发展新型高效分类算法、实现已有分类算法的并行化也是重要的发展方向。

总之, 过去20多年来高光谱遥感影像分类的研究取得了非常显著的进步, 成为遥感影像处理最为热门的研究方向之一。随着未来几年多个星载高光谱传感器投入运行, 用户将获得越来越多的高光谱遥感数据, 因此一方面要继续引入模式识别与机器学习领域的新理论、新模型, 发展更

先进、更有效的高光谱影像分类方法, 另一方面要关注不同应用方向的需求, 充分发挥高光谱数据的优势, 发展在特定应用领域中具有良好效果的影像分类和信息提取方法, 从而推进高光谱遥感的广泛、深入应用。

## 参考文献(References)

- Abdallah A C B, Frigui H and Gader P. 2012. Adaptive local fusion with fuzzy integrals. *IEEE Transactions on Fuzzy Systems*, 20(5): 849 – 864 [DOI: 10.1109/TFUZZ.2012.2187062]
- Bajcsy P and Groves P. 2004. Methodology for hyperspectral band selection. *Photogrammetric Engineering and Remote Sensing*, 70(7): 793 – 802 [DOI: 10.14358/PERS.70.7.793]
- Bakos K L and Gamba P. 2011. Hierarchical hybrid decision tree fusion of multiple hyperspectral data processing chains. *IEEE Transactions on Geoscience and Remote Sensing*, 49(1): 388 – 394 [DOI: 10.1109/TGRS.2010.2051554]
- Baudat G and Anouar F E. 2000. Generalized discriminant analysis using a kernel approach. *Neural Computation*, 12(10): 2385 – 2404 [DOI: 10.1162/089976600300014980]
- Benediktsson J A, Chanussot J and Fauvel M. 2007. Multiple classifier systems in remote sensing: from basics to recent developments. *Multiple Classifier Systems*, 4472: 501 – 512 [DOI: 10.1007/978-3-540-72523-7\_50]
- Benediktsson J A, Palmason J A and Sveinsson J R. 2005. Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3): 480 – 491 [DOI: 10.1109/TGRS.2004.842478]
- Benediktsson J A, Pesaresi M and Amason K. 2003. Classification and feature extraction for remote sensing images from urban areas based on morphological transformations. *IEEE Transactions on Geoscience and Remote Sensing*, 41(9): 1940 – 1949 [DOI: 10.1109/TGRS.2003.814625]
- Benediktsson J A, Sveinsson J R and Amason K. 1995. Classification and feature extraction of AVIRIS data. *IEEE Transactions on Geoscience and Remote Sensing*, 33(5): 1194 – 1205 [DOI: 10.1109/36.469483]
- Benediktsson J A and Swain P H. 1992. Consensus theoretic classification methods. *IEEE Transactions on Systems, Man, and Cybernetics*, 22(4): 688 – 704 [DOI: 10.1109/21.156582]
- Bernard K, Tarabalka Y, Angulo J, Chanussot J and Benediktsson J A. 2012. Spectral-spatial classification of hyperspectral data based on a stochastic minimum spanning forest approach. *IEEE Transactions on Image Processing*, 21(4): 2008 – 2021 [DOI: 10.1109/TIP.2011.2175741]
- Bioucas-Dias J M, Plaza A, Camps-Valls G, Scheunders P, Nasrabadi N and Chanussot J. 2013. Hyperspectral remote sensing data analysis and future challenges. *IEEE Geoscience and Remote Sensing Magazine*, 1(2): 6 – 36 [DOI: 10.1109/MGRS.2013.2244672]
- Blaschke T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1): 2 – 16 [DOI: 10.1016/J.ISPRSJPRS.2009.06.004]
- Borges J S, Bioucas-Dias J M and Marçal A R S. 2006. Fast sparse multinomial regression applied to hyperspectral data. *Image Analysis and Recognition*, 4142: 700 – 709 [DOI: 10.1007/11867661\_63]
- Breiman L. 1996. Bagging predictors. *Machine Learning*, 24(2): 123 – 140
- Breiman L. 2001. Random forests. *Machine Learning*, 45(1): 5 – 32
- Camps-Valls G, Bandos M T and Zhou D Y. 2007. Semi-supervised graph-based hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 45(10): 3044-3054 [DOI: 10.1109/TGRS.2007.895416]
- Camps-Valls G and Bruzzone L. 2005. Kernel-based methods for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 43(6): 1351 – 1362 [DOI: 10.1109/TGRS.2005.846154]
- Camps-Valls G, Gomez-Chova L, Muñoz-Mari J, Vila-Francés J and Calpe-Maravilla J. 2006. Composite kernels for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 3(1): 93-97 [DOI: 10.1109/TGRS.2005.857031]
- Camps-Valls G, Tuia D, Bruzzone L and Benediktsson J A. 2014. Advances in hyperspectral image classification: earth monitoring with statistical learning methods. *IEEE Signal Processing Magazine*, 31(1): 45 – 54 [DOI: 10.1109/MSP.2013.2279179]
- Ceamanos X, Waske B, Benediktsson J A, Chanussot J, Fauvel M and Sveinsson J R. 2010. A classifier ensemble based on fusion of support vector machines for classifying hyperspectral data. *International Journal of Image and Data Fusion*, 1(4): 293-307 [DOI: 10.1080/19479832.2010.485935]
- Chan J C W and Paelinckx D. 2008. Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment*, 112(6): 2999 – 3011 [DOI: 10.1016/J.RSE.2008.02.011]
- Chang C I. 2000. An information-theoretic approach to spectral variability, similarity, and discrimination for hyperspectral image analysis. *IEEE Transactions on Information Theory*, 46(5): 1927 – 1932 [DOI: 10.1109/18.857802]
- Chang C I. 2003. *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*. New York: Kluwer Academic
- Chen C, Li W, Su H J and Liu K. 2014. Spectral-Spatial classification of hyperspectral image based on kernel extreme learning machine. *Remote Sensing*, 6(6): 5795 – 5814 [DOI: 10.3390/RS6065795]
- Chen G, Chen X M, Li T, Ni G Q. 2010. Research on spectral data feature extraction based on wavelet decomposition. *Spectroscopy and Spectral Analysis*, 11: 3027 – 3030. (陈刚, 陈小梅, 李婷, 倪国强. 2010. 基于小波分解的光谱特征提取算法研究. *光谱学与光谱分析*, 11: 3027 – 3030)

- Chen S G and Zhang D Q. 2011. Semisupervised dimensionality reduction with pairwise constraints for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 8(2): 369 – 373 [DOI: 10.1109/LGRS.2010.2076407]
- Chen S J, Hu Y H, Shi L, Wang L, Sun D J and Xu S L. 2013. Classification of hyperspectral imagery based on ant colony compositionally optimizing SVM in spatial and spectral features. *Spectroscopy and Spectral Analysis*, 33(8): 2192 – 2197 (陈善静, 胡以华, 石亮, 王磊, 孙杜娟, 徐世龙. 2013. 空-谱二维蚁群组合优化 SVM 的高光谱图像分类. *光谱学与光谱分析*, 33(8): 2192 – 2197)
- Chen Y, Nasrabadi N M and Tran T D. 2011. Hyperspectral image classification using dictionary-based sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 49(10): 3973 – 3985 [DOI: 10.1109/TGRS.2011.2129595]
- Chen Y, Nasrabadi N M and Tran T D. 2013. Hyperspectral image classification via kernel sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1): 217 – 231 [DOI: 10.1109/TGRS.2012.2201730]
- Chi M M and Bruzzone L. 2007. Semisupervised classification of hyperspectral images by SVMs optimized in the primal. *IEEE Transactions on Geoscience and Remote Sensing*, 45(6): 1870 – 1880 [DOI: 10.1109/TGRS.2007.894550]
- Crawford M M, Tuia D and Yang H L. 2013. Active learning: any value for classification of remotely sensed data? *Proceedings of the IEEE*, 101(3): 593 – 608 [DOI: 10.1109/JPROC.2012.2231951]
- Dalla Mura, M, Villa A, Benediktsson J A, Chanussot J and Bruzzone L. 2011. Classification of hyperspectral images by using extended morphological attribute profiles and independent component analysis. *IEEE Geoscience and Remote Sensing Letters*, 8(3): 542 – 546 [DOI: 10.1109/LGRS.2010.2091253]
- Damodaran B B and Nidamanuri R R. 2014. Dynamic linear classifier system for hyperspectral image classification for land cover mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6): 2080 – 2093 [DOI: 10.1109/JSTARS.2013.2294857]
- Demir B, Persello C and Bruzzone L. 2011. Batch-mode active-learning methods for the interactive classification of remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 49(3): 1014 – 1031 [DOI: 10.1109/TGRS.2010.2072929]
- Deng L and Yu D. 2014. *Deep Learning: Methods and Applications: Foundations and Trends® in Signal Processing*, Volume 7 Issues 3 – 4. Hanover, MA: Now Publishers Inc.
- Di W and Crawford M M. 2011. Active learning via multi-view and local proximity co-regularization for hyperspectral image classification. *IEEE Journal of Selected Topics in Signal Processing*, 5(3): 618 – 628 [DOI: 10.1109/JSTSP.2011.2123077]
- Di W and Crawford M M. 2012. View generation for multiview maximum disagreement based active learning for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5): 1942 – 1954 [DOI: 10.1109/TGRS.2011.2168566]
- Dopido I, Li J, Marpu P R, Plaza A, Bioucas-Dias J and Benediktsson J A. 2013. Semi-supervised self learning for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 51(7): 4032 – 4044 [DOI: 10.1109/TGRS.2012.6874224]
- Du P J, Wang X M, Tan K and Xia J S. 2011. Dimensionality reduction and feature extraction from hyperspectral remote sensing imagery based on manifold learning. *Geomatics and Information Science of Wuhan University*, 36(2): 148 – 152 (杜培军, 王小美, 谭琨, 夏俊士. 2011. 利用流形学习进行高光谱遥感影像的降维与特征提取. *武汉大学学报(信息科学版)*, 36(2): 148 – 152)
- Du P J, Xia J S, Zhang W, Tan K, Liu Y and Liu S C. 2012. Multiple classifier system for remote sensing image classification: a review. *Sensors*, 12(4): 4764 – 4792 [DOI: 10.3390/S120404764]
- Du P J, Xue Z H, Li J and Plaza A. 2015. Learning discriminative sparse representations for hyperspectral image classification. *IEEE Journal of Selected Topics in Signal Processing*, 9(6): 1089 – 1104 [DOI: 10.1109/JSTSP.2015.2423260]
- Du P J, Zhang W and Xia J S. 2011. Hyperspectral remote sensing image classification based on decision level fusion. *Chinese Optics Letters*, 9(3): 031002 [DOI: 10.3788/Col201109.031002]
- Du Q and Yang H. 2008. Similarity-based unsupervised band selection for hyperspectral image analysis. *IEEE Geoscience and Remote Sensing Letters*, 5(4): 564 – 568 [DOI: 10.1109/LGRS.2008.2000619]
- Dundar M M and Landgrebe D A. 2004. A cost-effective semisupervised classifier approach with kernels. *IEEE Transactions on Geoscience and Remote Sensing*, 42(1): 264 – 270 [DOI: 10.1109/TGRS.2003.817815]
- Fauvel M, Benediktsson J A, Chanussot J and Sveinsson J R. 2008. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 46(11): 3804 – 3814 [DOI: 10.1109/TGRS.2008.922034]
- Fauvel M, Tarabalka Y, Benediktsson J A, Chanussot J and Tilton J C. 2013. Advances in spectral-spatial classification of hyperspectral images. *Proceedings of the IEEE*, 101(3): 652 – 675 [DOI: 10.1109/JPROC.2012.2197589]
- Freund Y and Schapire R E. 1996. Experiments with a new Boosting algorithm // *Machine Learning: Proceedings of the International Conference*. Bari, Italy: [s.n.]: 148 – 156
- Geng X R, Zhang X, Chen Z C, Zhang B, Zheng L F and Tong Q X. 2004. Classification algorithm based on spatial continuity for hyperspectral image. *Journal of Infrared and Millimeter Waves*, 23(4): 299 – 302 (耿修瑞, 张霞, 陈正超, 张兵, 郑兰芬, 童庆禧. 2004. 一种基于空间连续性的高光谱图像分类方法. *红外与毫米波学报*, 23(4): 299 – 302)
- Ghamisi P, Benediktsson J A and Sveinsson J R. 2014a. Automatic spectral-spatial classification framework based on attribute pro-

- files and supervised feature extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 52(9): 5771 – 5782 [DOI: 10.1109/TGRS.2013.2292544]
- Ghamisi P, Benediktsson J A, Cavallaro G and Plaza A. 2014b. Automatic framework for spectral-spatial classification based on supervised feature extraction and morphological attribute profiles. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6): 2147 – 2160 [DOI: 10.1109/JSTARS.2014.2298876]
- Ghamisi P, Benediktsson J A and Ulfarsson M O. 2014c. Spectral-spatial classification of hyperspectral images based on hidden Markov random fields. *IEEE Transactions on Geoscience and Remote Sensing*, 52(5): 2565 – 2574 [DOI: 10.1109/TGRS.2013.2263282]
- Goetz A F H, Vane G, Solomon J E and Rock B N. 1985. Imaging spectrometry for earth remote sensing. *Science*, 228(4704): 1147 – 1153 [DOI: 10.1126/SCIENCE.228.4704.1147]
- Goetz A F H. 2009. Three decades of hyperspectral remote sensing of the Earth: a personal view. *Remote Sensing of Environment*, 113(S1): S5 – S16 [DOI: 10.1016/J.RSE.2007.12.014]
- Groves P and Bajcsy P. 2003. Methodology for hyperspectral band and classification model selection // 2003 IEEE Workshop on Advances in Techniques for Analysis of Remotely Sensed Data. Greenbelt, MD, USA: IEEE: 120 – 128 [DOI: 10.1109/WARSD.2003.1295183]
- Gu Y F, Wang C, You D, Zhang Y H, Wang S Z and Zhang Y. 2012. Representative multiple kernel learning for classification in hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 50(7): 2852 – 2865 [DOI: 10.1109/TGRS.2011.2176341]
- Guo B F, Gunn S R, Damper R I and Nelson J D B. 2006. Band selection for hyperspectral image classification using mutual information. *IEEE Geoscience and Remote Sensing Letters*, 3(4): 522 – 526 [DOI: 10.1109/LGRS.2006.878240]
- Ham J, Chen Y C, Crawford M M and Ghosh J. 2005. Investigation of the random forest framework for classification of hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3): 492 – 501 [DOI: 10.1109/TGRS.2004.842481]
- Ho T K. 1998. The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(8): 832 – 844 [DOI: 10.1109/34.709601]
- Huang G B, Ding X J and Zhou H M. 2010. Optimization method based extreme learning machine for classification. *Neurocomputing*, 74(1/3): 155 – 163 [DOI: 10.1016/j.neucom.2010.02.019]
- Huang G B, Zhou H M, Ding X J and Zhang R. 2012. Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B-Cybernetics*, 42(2): 513 – 529 [DOI: 10.1109/TSMCB.2011.2168604]
- Huang G B, Zhu Q Y and Siew C K. 2006. Extreme learning machine: theory and applications. *Neurocomputing*, 70(1/3): 489 – 501 [DOI: 10.1016/J.NEUCOM.2005.12.126]
- Hughes G F. 1968. On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*, 14(1): 55 – 63
- Ifarraguerri A and Prairie M W. 2004. Visual method for spectral band selection. *IEEE Geoscience and Remote Sensing Letters*, 1(2): 101 – 106 [DOI: 10.1109/LGRS.2003.822879]
- Jackson Q and Landgrebe D A. 2002. Adaptive Bayesian contextual classification based on Markov random fields. *IEEE Transactions on Geoscience and Remote Sensing*, 40(11): 2454 – 2463 [DOI: 10.1109/TGRS.2002.805087]
- Jenatton R, Audibert J Y and Bach F. 2011. Structured variable selection with sparsity-inducing norms. *The Journal of Machine Learning Research*, 12: 2777 – 2824
- Ji R R, Gao Y, Hong R C, Liu Q, Tao D C and Li X L. 2014. Spectral-spatial constraint hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 52(3): 1811 – 1824 [DOI: 10.1109/TGRS.2013.2255297]
- Jia X P, Kuo B C and Crawford M M. 2013. Feature mining for hyperspectral image classification. *Proceedings of the IEEE*, 101(3): 676 – 697 [DOI: 10.1109/JPROC.2012.2229082]
- Jun G and Ghosh J. 2013. Semisupervised learning of hyperspectral data with unknown land-cover classes. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1): 273 – 282 [DOI: 10.1109/TGRS.2012.2198654]
- Karsmakers P, Pelckmans K and Suykens J A K. 2007. Multi-class kernel logistic regression: a fixed-size implementation // 2007 IEEE International Joint Conference on Neural Networks. Orlando, FL: IEEE: 1756 – 1761 [DOI: 10.1109/IJCNN.2007.4371223]
- Kawaguchi S and Nishii R. 2007. Hyperspectral image classification by bootstrap AdaBoost with random decision stumps. *IEEE Transactions on Geoscience and Remote Sensing*, 45(11): 3845 – 3851 [DOI: 10.1109/TGRS.2007.903708]
- Kettig R L and Landgrebe D A. 1976. Classification of multispectral image data by extraction and classification of homogeneous objects. *IEEE Transactions on Electronics*, 14(1): 19 – 26 [DOI: 10.1109/TGE.1976.294460]
- Khodadadzadeh M, Li J, Plaza A, Ghassemian H, Bioucas-Dias J M and Li X. 2014. Spectral-spatial classification of hyperspectral data using local and global probabilities for mixed pixel characterization. *IEEE Transactions on Geoscience and Remote Sensing*, 52(10): 6298 – 6314 [DOI: 10.1109/TGRS.2013.2296031]
- Krishnapuram B, Carin L, Figueiredo M A T and Hartemink A J. 2005. Sparse multinomial logistic regression: fast algorithms and generalization bounds. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(6): 957 – 968 [DOI: 10.1109/TPAMI.2005.127]
- Kuncheva L I. 2007. *Combining Pattern Classifiers: Methods and Algorithms*. New York: Wiley-Interscience
- Kuo B C and Landgrebe D A. 2004. Nonparametric weighted feature extraction for classification. *IEEE Transactions on Geoscience and Remote Sensing*, 42(5): 1096 – 1105 [DOI: 10.1109/TGRS.2004.825578]



- Li J, Bioucas-Dias J M and Plaza A. 2010. Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning. *IEEE Transactions on Geoscience and Remote Sensing*, 48(11): 4085 – 4098 [DOI: 10.1109/TGRS.2010.2060550]
- Li J, Bioucas-Dias J M and Plaza A. 2011a. Hyperspectral image segmentation using a new Bayesian approach with active learning. *IEEE Transactions on Geoscience and Remote Sensing*, 49(10): 3947 – 3960 [DOI: 10.1109/TGRS.2011.2128330]
- Li J, Bioucas-Dias J M and Plaza A. 2012. Spectral-spatial hyperspectral image segmentation using subspace multinomial logistic regression and Markov random fields. *IEEE Transactions on Geoscience and Remote Sensing*, 50(3): 809 – 823 [DOI: 10.1109/TGRS.2011.2162649]
- Li J, Bioucas-Dias J M and Plaza A. 2013a. Spectral-spatial classification of hyperspectral data using loopy belief propagation and active learning. *IEEE Transactions on Geoscience and Remote Sensing*, 51(2): 844 – 856 [DOI: 10.1109/TGRS.2012.2205263]
- Li J, Marpu P R, Plaza A, Bioucas-Dias J M and Benediktsson J A. 2013b. Generalized composite kernel framework for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 51(9): 4816 – 4829 [DOI: 10.1109/TGRS.2012.2230268]
- Li J, Bioucas-Dias J M and Plaza A. 2013c. Semisupervised hyperspectral image classification using soft sparse multinomial logistic regression. *IEEE Geoscience and Remote Sensing Letters*, 10(2): 318 – 322 [DOI: 10.1109/LGRS.2012.2205216]
- Li J Y, Zhang H Y, Huang Y C and Zhang L P. 2014a. Hyperspectral image classification by nonlocal joint collaborative representation with a locally adaptive dictionary. *IEEE Transactions on Geoscience and Remote Sensing*, 52(6): 3707 – 3719 [DOI: 10.1109/TGRS.2013.2274875]
- Li J Y, Zhang H Y, Zhang L P, Huang X and Zhang L F. 2014b. Joint collaborative representation with multitask learning for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 52(9): 5923 – 5936 [DOI: 10.1109/TGRS.2013.2293732]
- Li N, Li Y J, Zhao H J and Cao Y. 2014. An improved classification approach based on spatial and spectral features for hyperspectral data. *Spectroscopy and Spectral Analysis*, 34(2): 526 – 531 (李娜, 李咏洁, 赵慧洁, 曹扬. 2014. 基于光谱与空间特征结合的改进高光谱数据分类算法. *光谱学与光谱分析*, 34(2): 526 – 531)
- Li W, Prasad S, Fowler J E and Bruce L M. 2011b. Locality-preserving discriminant analysis in kernel-induced feature spaces for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 8(5): 894 – 898 [DOI: 10.1109/LGRS.2011.2128854]
- Li Z C, Ma J W, Zhang R and Li L W. 2010. Classifying hyperspectral image based on P-EDMP and spectrum. *Geomatics and Information Science of Wuhan University*, 35(12): 1449 – 1452 (李祖传, 马建文, 张睿, 李利伟. 2010. 利用P-EDMP与光谱进行高光谱遥感影像分类. *武汉大学学报(信息科学版)*, 35(12): 1449 – 1452)
- Liao W Z, Bellens R, Pizurica A, Philips W and Pi Y G. 2012. Classification of hyperspectral data over urban areas using directional morphological profiles and semi-supervised feature extraction. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(4): 1177 – 1190 [DOI: 10.1109/JSTARS.2012.2190045]
- Liao W Z, Pizurica A, Scheunders P, Philips W and Pi Y G. 2013. Semisupervised local discriminant analysis for feature extraction in hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1): 184 – 198 [DOI: 10.1109/TGRS.2012.2200106]
- Liu J J, Wu Z B, Wei Z H, Xiao L and Sun L. 2012. Spatial correlation constrained sparse representation for hyperspectral image classification. *Journal of Electronics & Information Technology*, 34(11): 2666 – 2671 (刘建军, 吴泽彬, 韦志辉, 肖亮, 孙乐. 2012. 基于空间相关性约束稀疏表示的高光谱图像分类. *电子与信息学报*, 34(11): 2666 – 2671)
- Martínez-Usó A, Pla F, Sotoca J M and Garcia-Sevilla P. 2007. Clustering-based hyperspectral band selection using information measures. *IEEE Transactions on Geoscience and Remote Sensing*, 45(12): 4158 – 4171 [DOI: 10.1109/TGRS.2007.904951]
- Melgani F and Bruzzone L. 2004. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8): 1778 – 1790 [DOI: 10.1109/TGRS.2004.831865]
- Mitra P, Murthy C A and Pal S K. 2002. Unsupervised feature selection using feature similarity. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(3): 301 – 312 [DOI: 10.1109/34.990133]
- Moser G and Serpico S B. 2013. Combining support vector machines and Markov random fields in an integrated framework for contextual image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 51(5): 2734 – 2752 [DOI: 10.1109/TGRS.2012.2211882]
- Munoz-Mari J, Tuia D and Camps-Valls G. 2012. Semisupervised classification of remote sensing images with active queries. *IEEE Transactions on Geoscience and Remote Sensing*, 50(10): 3751 – 3763 [DOI: 10.1109/TGRS.2012.2185504]
- Narendra P M and Fukunaga K. 1977. A branch and bound algorithm for feature subset selection. *IEEE Transactions on Computers*, C-26(9): 917 – 922 [DOI: 10.1109/TC.1977.1674939]
- Pal M, Maxwell A E and Warner T A. 2013. Kernel-based extreme learning machine for remote-sensing image classification. *Remote Sensing Letters*, 4(9): 853 – 862 [DOI: 10.1080/2150704x.2013.805279]
- Patra S and Bruzzone L. 2011. A fast cluster-assumption based active-learning technique for classification of remote sensing images.

- IEEE Transactions on Geoscience and Remote Sensing, 49(5): 1617 – 1626 [DOI: 10.1109/TGRS.2010.2083673]
- Patra S and Bruzzone L. 2014. A novel SOM-SVM-based active learning technique for remote sensing image classification. IEEE Transactions on Geoscience and Remote Sensing, 52(11): 6899 – 6910 [DOI: 10.1109/TGRS.2014.2305516]
- Persello C and Bruzzone L. 2012. Active learning for domain adaptation in the supervised classification of remote sensing images. IEEE Transactions on Geoscience and Remote Sensing, 50(11): 4468 – 4483 [DOI: 10.1109/TGRS.2012.2192740]
- Persello C and Bruzzone L. 2014. Active and semisupervised learning for the classification of remote sensing images. IEEE Transactions on Geoscience and Remote Sensing, 52(11): 6937 – 6956 [DOI: 10.1109/TGRS.2014.2305805]
- Plaza A, Benediktsson J A, Boardman J W, Brazile J, Bruzzone L, Camps-Valls G, Chanussot J, Fauvel M, Gamba P, Gualtieri A, Marconcini M, Tilton J C and Trianni G. 2009. Recent advances in techniques for hyperspectral image processing. Remote Sensing of Environment, 113: S110 – S122 [DOI: 10.1016/J.RSE.2007.07.028]
- Plaza A, Du Q, Chang Y L and King R L. 2011. High performance computing for hyperspectral remote sensing. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 4(3): 528 – 544 [DOI: 10.1109/JSTARS.2010.2095495]
- Pu R L and Gong P. 2000. Hyperspectral Remote Sensing and its Applications. Beijing: Higher Education Press (浦瑞良, 宫鹏. 2000. 高光谱遥感及其应用. 北京: 高等教育出版社)
- Qian Y T, Ye M C and Zhou J. 2013. Hyperspectral image classification based on structured sparse logistic regression and three-dimensional wavelet texture features. IEEE Transactions on Geoscience and Remote Sensing, 51(4): 2276 – 2291 [DOI: 10.1109/TGRS.2012.2209657]
- Rajan S, Ghosh J and Crawford M M. 2008. An active learning approach to hyperspectral data classification. IEEE Transactions on Geoscience and Remote Sensing, 46(4): 1231 – 1242 [DOI: 10.1109/TGRS.2007.910220]
- Ratle F, Camps-Valls G and Weston J. 2010. Semisupervised neural networks for efficient hyperspectral image classification. IEEE Transactions on Geoscience and Remote Sensing, 48(5): 2271 – 2282 [DOI: 10.1109/TGRS.2009.2037898]
- Richards J A and Jia X P. 2006. Remote Sensing Digital Image Analysis. 4th ed. Berlin Heidelberg: Springer-Verlag [DOI: 10.1007/3-540-29711-1]
- Rubinstein R, Bruckstein A M and Elad M. 2010. Dictionaries for sparse representation modeling. Proceedings of the IEEE, 98(6): 1045 – 1057 [DOI: 10.1109/JPROC.2010.2040551]
- Samat A, Du P J, Liu S C, Li J and Cheng L. 2014. E<sup>2</sup>LMs: ensemble extreme learning machines for hyperspectral image classification. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7(4): 1060 – 1069 [DOI: 10.1109/JSTARS.2014.2301775]
- Schaepman M E, Ustin S L, Plaza A J, Painter T H, Verrelst J and Liang S L. 2009. Earth system science related imaging spectroscopy—An assessment. Remote Sensing of Environment, 113(S1): S123 – S137 [DOI: 10.1016/J.RSE.2009.03.001]
- Serpico S B and Moser G. 2007. Extraction of spectral channels from hyperspectral images for classification purposes. IEEE Transactions on Geoscience and Remote Sensing, 45(2): 484 – 495 [DOI: 10.1109/TGRS.2006.886177]
- Shahshahani B M and Landgrebe David A. 1994. The effect of unlabeled samples in reducing the small sample size problem and mitigating the Hughes phenomenon. IEEE Transactions on Geoscience and Remote Sensing, 32(5): 1087 – 1095 [DOI: 10.1109/36.312897]
- Smits P C. 2002. Multiple classifier systems for supervised remote sensing image classification based on dynamic classifier selection. IEEE Transactions on Geoscience and Remote Sensing, 40(4): 801 – 813 [DOI: 10.1109/TGRS.2002.1006354]
- Song L, Cheng Y M and Zhao Y Q. 2012. Hyper-spectrum classification based on sparse representation model and auto-regressive model. Acta Optica Sinica, 32(3): 0330003 (宋琳, 程咏梅, 赵永强. 2012. 基于稀疏表示模型和自回归模型的高光谱分类. 光学学报, 32(3): 0330003)
- Song X F. 2013. Study of Classification Problems based on Sparse Representation and Ensemble Learning. Xi'an: Xidian University (宋相法. 2013. 基于稀疏表示和集成学习的若干分类问题研究. 西安: 西安电子科技大学)
- Song X F and Jiao L C. 2012. Classification of hyperspectral remote sensing image based on sparse representation and spectral information. Journal of Electronics & Information Technology, 34(2): 268 – 272 (宋相法, 焦李成. 2012. 基于稀疏表示及光谱信息的高光谱遥感图像分类. 电子与信息学报, 34(2): 268 – 272)
- Su H J, Du Q, Chen G S and Du P J. 2014a. Optimized hyperspectral band selection using particle swarm optimization. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7(6): 2659 – 2670 [DOI: 10.1109/JSTARS.2014.2312539]
- Su H J, Yong B, Du P J, Liu H, Chen C and Liu K. 2014b. Dynamic classifier selection using spectral-spatial information for hyperspectral image classification. Journal of Applied Remote Sensing, 8(1): 085095 [DOI: 10.1117/1.JRS.8.085095]
- Su H J, Yang H, Du Q and Sheng Y H. 2011. Semisupervised band clustering for dimensionality reduction of hyperspectral imagery. IEEE Geoscience and Remote Sensing Letters, 8(6): 1135 – 1139 [DOI: 10.1109/LGRS.2011.2158185]
- Sun K, Geng X R, Ji L Y and Lu Y. 2014a. A new band selection method for hyperspectral image based on data quality. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7(6): 2697 – 2703 [DOI: 10.1109/JSTARS.2014.2320299]
- Sun W W, Liu C, Shi B Q and Li W Y. 2013. Random matrix-based nonnegative sparse representation for hyperspectral image classi-

- fication. *Journal of Tongji University(Natural Science)*, 41(8): 1274 – 1280 (孙伟伟, 刘春, 施蓓琦, 李巍岳. 2013. 基于随机矩阵的高光谱影像非负稀疏表达分类. *同济大学学报(自然科学版)*, 41(8): 1274 – 1280)
- Sun X X, Qu Q, Nasrabadi N M and Tran T D. 2014b. Structured priors for sparse-representation-based hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 11(7): 1235 – 1239 [DOI: 10.1109/LGRS.2013.2290531]
- Tan K, Li E Z, Du Q and Du P J. 2014. An efficient semi-supervised classification approach for hyperspectral imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 97: 36 – 45 [DOI: 10.1016/J.ISPRSJPRS.2014.08.003]
- Tarabalka Y, Benediktsson J A and Chanussot J. 2009. Spectral-spatial classification of hyperspectral imagery based on partitional clustering techniques. *IEEE Transactions on Geoscience and Remote Sensing*, 47(8): 2973 – 2987 [DOI: 10.1109/TGRS.2009.2016214]
- Tarabalka Y, Chanussot J and Benediktsson J A. 2010a. Segmentation and classification of hyperspectral images using watershed transformation. *Pattern Recognition*, 43(7): 2367 – 2379 [DOI: 10.1016/J.PATCOG.2010.01.016]
- Tarabalka Y, Benediktsson J A, Chanussot J and Tilton J C. 2010b. Multiple spectral-spatial classification approach for hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 48(11): 4122 – 4132 [DOI: 10.1109/TGRS.2010.2062526]
- Tarabalka Y, Tilton J C, Benediktsson J A and Chanussot J. 2011. Marker-based hierarchical segmentation and classification approach for hyperspectral imagery // 2011 IEEE International Conference on Acoustics, Speech, and Signal Processing. Prague: IEEE: 1089 – 1092 [DOI: 10.1109/ICASSP.2011.5946597]
- Tarabalka Y, Tilton J C, Benediktsson J A and Chanussot J. 2012. A Marker-based approach for the automated selection of a single segmentation from a hierarchical set of image segmentations. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(1): 262 – 272 [DOI: 10.1109/JSTARS.2011.2173466]
- Tilton J C, Tarabalka Y, Montesano P M and Gofman E. 2012. Best merge region-growing segmentation with integrated nonadjacent region object aggregation. *IEEE Transactions on Geoscience and Remote Sensing*, 50(11): 4454 – 4467 [DOI: 10.1109/TGRS.2012.2190079]
- Tong Q X, Zhang B and Zheng L F. 2006. *Hyperspectral Remote Sensing: the Principle, Technology and Application*. Beijing: Higher Education Press (童庆禧, 张兵, 郑兰芬. 2006. *高光谱遥感: 原理、技术与应用*. 北京: 高等教育出版社)
- Tosic I and Frossard P. 2011. Dictionary learning. *IEEE Signal Processing Magazine*, 28(2): 27 – 38 [DOI: 10.1109/MSP.2010.939537]
- Tuia D and Camps-Valls G. 2011. Urban image classification with semisupervised multiscale cluster kernels. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(1): 65 – 74 [DOI: 10.1109/JSTARS.2010.2069085]
- Tuia D, Matasci G, Camps-Valls G and Kanevski M. 2010. Learning relevant image features with multiple-kernel classification. *IEEE Transactions on Geoscience and Remote Sensing*, 48(10): 3780 – 3791 [DOI: 10.1109/TGRS.2010.2049496]
- Tuia D, Pasolli E and Emery W J. 2011. Using active learning to adapt remote sensing image classifiers. *Remote Sensing of Environment*, 115(9): 2232 – 2242 [DOI: 10.1016/J.RSE.2011.04.022]
- Tuia D, Ratle F, Pacifici F, Kanevski M F and Emery W J. 2009. Active learning methods for remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 47(7): 2218 – 2232 [DOI: 10.1109/TGRS.2008.2010404]
- Ul-Haq Q S, Tao L M, Sun F C and Yang S Q. 2012. A fast and robust sparse approach for hyperspectral data classification using a few labeled samples. *IEEE Transactions on Geoscience and Remote Sensing*, 50(6): 2287 – 2302 [DOI: 10.1109/TGRS.2011.2172617]
- Wang M C, Xing L X, Zhang X M and Song J H. 2005. Study of artificial immune system in remote sensing information extraction. *Journal of Jilin University (Information Science Edition)*, 23(2): 190 – 194 (王明常, 邢立新, 张学明, 宋继红. 2005. 人工免疫系统在遥感信息提取中的应用. *吉林大学学报(信息科学版)*, 23(2): 190 – 194)
- Wang Z W, Nasrabadi N M and Huang T S. 2014. Spatial-spectral classification of hyperspectral images using discriminative dictionary designed by learning vector quantization. *IEEE Transactions on Geoscience and Remote Sensing*, 52(8): 4808 – 4822 [DOI: 10.1109/TGRS.2013.2285049]
- Waske B, Benediktsson J A, Árnason K and Sveinsson J R. 2009. Mapping of hyperspectral AVIRIS data using machine-learning algorithms. *Canadian Journal of Remote Sensing*, 35(S1): S106 – S116 [DOI: 10.5589/m09 – 018]
- Waske B, van der Linden S, Benediktsson J A, Rabe A and Hostert P. 2010. Sensitivity of support vector machines to random feature selection in classification of hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 48(7): 2880 – 2889 [DOI: 10.1109/TGRS.2010.2041784]
- Woźniak M, Graña M and Corchado E. 2014. A survey of multiple classifier systems as hybrid systems. *Information Fusion*, 16: 3 – 17 [DOI: 10.1016/J.INFFUS.2013.04.006]
- Wright J, Ma Y, Mairal J, Sapiro G, Huang T S and Yan S C. 2010. Sparse representation for computer vision and pattern recognition. *Proceedings of the IEEE*, 98(6): 1031 – 1044 [DOI: 10.1109/JPROC.2010.2044470]
- Wright J, Yang A Y, Ganesh A, Sastry S S and Ma Y. 2009. Robust face recognition via sparse representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(2): 210 – 227 [DOI: 10.1109/TPAMI.2008.79]
- Xia J S, Chanussot J, Du P J and He X Y. 2014b. Rotation-based ensemble classifiers for high-dimensional data // Ionescu B, Benoit-Pineau J, Piatrik and Quénot G, eds. *Fusion in Computer Vision*.

- Switzerland: Springer: 135 – 160 [DOI: 10.1007/978-3-319-05696-8\_6]
- Xia J S, Du P J, He X Y and Chanussot J. 2014a. Hyperspectral remote sensing image classification based on rotation forest. *IEEE Geoscience and Remote Sensing Letters*, 11(1): 239 – 243 [DOI: 10.1109/LGRS.2013.2254108]
- Xu L, Krzyzak A and Suen C Y. 1992. Methods of combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on Systems, Man, and Cybernetics*, 22(3): 418 – 435 [DOI: 10.1109/21.155943]
- Xue Z H, Du P J and Su H J. 2014. Harmonic analysis for hyperspectral image classification integrated with PSO optimized SVM. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6): 2131 – 2146 [DOI: 10.1109/JSTARS.2014.2307091]
- Xue Z H, Du P J, Li J and Su H J. 2015a. Simultaneous sparse graph embedding for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 53(11): 6114 – 6133 [DOI: 10.1109/TGRS.2015.2432059]
- Xue Z H, Li J, Cheng L and Du P J. 2015b. Spectral-spatial classification of hyperspectral data via morphological component analysis-based image separation. *IEEE Transactions on Geoscience and Remote Sensing*, 53(1): 70 – 84 [DOI: 10.1109/TGRS.2014.2318332]
- Yang H, Du Q and Chen G S. 2012. Particle swarm optimization-based hyperspectral dimensionality reduction for urban land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2): 544 – 554 [DOI: 10.1109/JSTARS.2012.2185822]
- Yang H, Du Q, and Su H, Sheng Y. 2011. An efficient method for supervised hyperspectral band selection. *IEEE Geoscience and Remote Sensing Letters*, 8(1): 138 – 142 [DOI: 10.1109/LGRS.2010.2053516]
- Yang J M, Kuo B C, Yu P T and Chuang C H. 2010. A dynamic subspace method for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 48(7): 2840 – 2853 [DOI: 10.1109/TGRS.2010.2043533]
- Yang S Y, Jin H H, Yang L X, Xu W H and Jiao L C. 2014a. Compressive sensing-inspired dual-sparse SLFNN for hyperspectral imagery classification. *IEEE Geoscience and Remote Sensing Letters*, 11(1): 220 – 224 [DOI: 10.1109/LGRS.2013.2253443]
- Yang S Y, Jin P L, Li B, Yang L X, Xu W H and Jiao L C. 2014b. Semisupervised dual-geometric subspace projection for dimensionality reduction of hyperspectral image data. *IEEE Transactions on Geoscience and Remote Sensing*, 52(6): 3587 – 3593 [DOI: 10.1109/TGRS.2013.2273798]
- Yao H B and Tian L. 2003. A genetic-algorithm-based selective principal component analysis (GA-SPCA) method for high-dimensional data feature extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 41(6): 1469 – 1478 [DOI: 10.1109/TGRS.2003.811691]
- Zhang B. 2011. Intelligent remote sensing satellite system. *Journal of Remote Sensing*, 15(3): 415 – 431 (张兵. 2011. 智能遥感卫星系统. *遥感学报*, 15(3): 415 – 431)
- Zhang B, Chen Z C, Zheng L F, Tong Q X, Liu Y N, Yang Y D and Xue Y Q. 2004. Object detection based on feature extraction from hyperspectral imagery and convex cone projection transform. *Journal of Infrared and Millimeter Waves*, 23(6): 441 – 445, 450 (张兵, 陈正超, 郑兰芬, 童庆禧, 刘银年, 杨一德, 薛永祺. 2004. 基于高光谱图像特征提取与凸面几何体投影变换的目标探测. *红外与毫米波学报*, 23(6): 441 – 445, 450)
- Zhang B and Gao L R. 2011. *Hyperspectral Image Classification and Target Detection*. Beijing: Science Press (张兵, 高连如. 2011. 高光谱图像分类与目标探测. 北京: 科学出版社)
- Zhang H Y, Li J Y, Huang Y C and Zhang L P. 2014a. A nonlocal weighted joint sparse representation classification method for hyperspectral imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6): 2056 – 2065 [DOI: 10.1109/JSTARS.2013.2264720]
- Zhang L P and Zhang L F. 2005. *Hyperspectral Remote Sensing*. Wuhan: Wuhan University Press (张良培, 张立福. 2005. 高光谱遥感. 武汉: 武汉大学出版社)
- Zhang L P, Zhong Y F, Huang B, Gong J Y and Li P X. 2007. Dimensionality reduction based on clonal selection for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 45(12): 4172 – 4186 [DOI: 10.1109/TGRS.2007.905311]
- Zhang X R, Song Q, Liu R C, Wang W N and Jiao L C. 2014b. Modified co-training with spectral and spatial views for semisupervised hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6): 2044 – 2055 [DOI: 10.1109/JSTARS.2014.2325741]
- Zhong P and Wang R S. 2008. Learning sparse CRFs for feature selection and classification of hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 46(12): 4186 – 4197 [DOI: 10.1109/TGRS.2008.2001921]
- Zhong P and Wang R S. 2011. Modeling and classifying hyperspectral imagery by CRFs with sparse higher order potentials. *IEEE Transactions on Geoscience and Remote Sensing*, 49(2): 688 – 705 [DOI: 10.1109/TGRS.2010.2059706]
- Zhong Y F, Zhang L P, Gong J Y and Li P X. 2005. Classification of multi-spectral remote sensing image based on clonal selection. *Journal of Image and Graphics*, 10(1): 18 – 24 (钟燕飞, 张良培, 龚健雅, 李平湘. 2005. 基于克隆选择的多光谱遥感影像分类算法. *中国图象图形学报*, 10(1): 18 – 24)
- Zhong Y F, Zhang L P, Gong J Y and Li P X. 2006. Classification of multi-spectral remote sensing image based on resource limited artificial immune system. *Geomatics and Information Science of Wuhan University*, 31(1): 47 – 50 (钟燕飞, 张良培, 龚健雅, 李平湘. 2006. 基于资源限制性人工免疫系统的多光谱遥感影像分类方法. *武汉大学学报(信息科学版)*, 31(1): 47 – 50)
- Zhong Y F, Zhang L P, Huang B and Li P X. 2006. An unsupervised

artificial immune classifier for multi/hyperspectral remote sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 44(2): 420 – 431 [DOI: 10.1109/TGRS.2005.861548]  
Zhong Y F, Zhang L P and Li P X. 2007. Classification of multi-spec-

tral remote sensing image based on multiple-valued immune network. *Chinese Journal of Computers*, 30(12): 2181 – 2188(钟燕飞, 张良培, 李平湘. 2007. 基于多值免疫网络的多光谱遥感影像分类. *计算机学报*, 30(12): 2181 – 2188)

## Review of hyperspectral remote sensing image classification

DU Peijun<sup>1,2</sup>, XIA Junshi<sup>1,2</sup>, XUE Zhaohui<sup>1,2</sup>, TAN Kun<sup>3</sup>, SU Hongjun<sup>4</sup>, BAO Rui<sup>1,2</sup>

1. *Key Laboratory for Satellite Mapping Technology and Applications of National Administration of Surveying, Mapping and Geoinformation of China, Nanjing University, Nanjing 210023, China;*
2. *Jiangsu Provincial Key Laboratory of Geographic Information Science and Technology, Nanjing University, Nanjing 210023, China;*
3. *Jiangsu Provincial Key Laboratory of Resources Environment and Information Engineering, China University Of Mining and Technology, Xuzhou 221116, China;*
4. *School of Earth Sciences and Engineering, Hohai University, Nanjing 210098, China*

**Abstract:** Studies on hyperspectral remote sensing image classification have developed rapidly with the progress of related disciplines, including pattern recognition, machine learning, and remote sensing technology. This review generates a systematic summary and conducts a comprehensive evaluation of the advancements in current techniques for hyperspectral remote sensing image classification. Based on an overview of different classification schemes, we examine the recent progress in per-pixel classification algorithms for hyperspectral images from six aspects, namely, new classifier design (e.g., kernel-based methods), feature mining, spectral spatial classification, active and semi-supervised learning, sparse representation for classification, and multiple classifier systems. Future research directions are discussed as well. On the one hand, new theories and methods of machine learning should be introduced continuously into hyperspectral image classification. Moreover, multisource data and multidimensional feature spaces may improve the accuracy, generalization capability, and automation degree of a classifier. On the other hand, new classification methods should be designed in consideration of practical requirements to meet the needs of real applications and to emphasize the advantages of fine spectra in hyperspectral remote sensing.

**Key words:** hyperspectral remote sensing, classification, support vector machine, feature mining, multiple classifier system

**Supported by** National Natural Science Foundation of China(No.41471275); Jiangsu Provincial Natural Science Foundation (No.BK2012018)