

航天高光谱遥感应用研究进展(特邀)

李盛阳^{1,2}, 刘志文^{1,2}, 刘康^{1,2}, 赵子飞^{1,2,3}

- (1. 中国科学院太空应用重点实验室, 北京 100094;
2. 中国科学院空间应用工程与技术中心, 北京 100094; 3. 中国科学院大学, 北京 100049)

摘要:近年来随着高光谱成像技术的快速发展, 航天高光谱遥感数据在各领域应用研究中取得了良好的发展与突破。文中回顾了国内外航天高光谱成像技术的发展历程, 介绍了有代表性的航天高光谱成像仪的主要应用技术指标, 较为系统地总结和分析了近五年来航天高光谱遥感数据在国土资源、农林遥感、海洋湖泊遥感、城市环境、灾害监测及其他方面等各个领域的最新应用研究进展。对基于 AI 技术的高光谱信息提取与应用、基于高光谱遥感的多源数据融合与应用以及面向深空探测领域的高光谱数据分析与应用等发展趋势做了展望, 未来航天高光谱成像仪技术的进一步突破和应用研究需求的牵引将会推动高光谱应用领域更大范围的创新与发展。

关键词: 航天高光谱; 成像光谱仪; 高光谱数据应用

中图分类号: TP79 **文献标志码:** A **DOI:** 10.3788/IRLA201948.0303001

Advances in application of space hyperspectral remote sensing(invited)

Li Shengyang^{1,2}, Liu Zhiwen^{1,2}, Liu Kang^{1,2}, Zhao Zifei^{1,2,3}

- (1. Key Laboratory of Space Utilization, Chinese Academy of Sciences, Beijing 100094, China;
2. Technology and Engineering Center for Space Utilization, Chinese Academy of Sciences, Beijing 100094, China;
3. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: With the rapid development of hyperspectral imaging technology, space hyperspectral remote sensing data have been successfully applied to various fields in recent years. The development of space hyperspectral imaging technology at home and abroad was reviewed, the technical standards of representative space hyperspectral imagers were introduced. The latest applications of hyperspectral data in land resources, agriculture and forestry, ocean and lake remote sensing, urban environment, disaster monitoring and other fields in the past five years were systematically summarized and analysed. The outlook of future hyperspectral remote sensing was provided including hyperspectral information extraction and application based on AI technology, the multi-source data fusion and applications, and the analysis and application of hyperspectral data for deep space exploration. Further developments of space hyperspectral imager technology driven by applications will promote the innovated use of hyperspectral data in a wider range of fields.

Key words: aerospace hyperspectral; imaging spectrometer; application of hyperspectral data

收稿日期: 2018-11-05; 修订日期: 2018-12-03

基金项目: 国家重大专项-载人航天工程空间应用系统“天宫二号任务数据管理平台”项目(Y3140231WN)

作者简介: 李盛阳(1976-), 男, 研究员, 博士生导师, 博士, 主要从事遥感图像智能处理与应用、航天地面数据系统技术等方面的研究。

Email: shyli@csu.ac.cn

0 引言

高光谱成像仪具有成像覆盖区域广、光谱分辨率高、图谱和一等特性,有机融合了图像维与光谱维信息,在各应用领域具有巨大优势。近年来随着航天高光谱成像技术的快速发展,高光谱观测数据在国土资源、农林遥感、海洋湖泊遥感、城市环境、灾害监测及深空探测等社会、经济和科技发展的各个领域取得了良好的突破与进展。

文中梳理与总结了国内外航天高光谱遥感数据的应用研究进展,对2000年以来高光谱遥感数据被较大范围应用的航天高光谱成像仪进行了总结和介绍,重点对近五年来(2013~2018)航天高光谱遥感数据在各应用领域的研究进展和成果进行了总结与分析,最后对航天高光谱遥感数据应用研究的发展趋势进行了分析和展望。

1 航天高光谱成像仪介绍

随着2000年美国“新千年计划第一星”EO-1上的Hyperion成像光谱仪^[1]、2001年欧洲PROBA卫星上的CHRIS成像光谱仪^[2]等相继升空,宣告了航天高光谱时代的来临。对2000年以来的在各应用领域有显著影响力、有代表性的航天高光谱成像仪及其主要应用技术指标综述如下。

1.1 Hyperion 高光谱成像仪

Hyperion是美国国家航空航天局(NASA)2000年11月发射的地球观测卫星(EO-1)搭载的世界上第一台航天民用高光谱成像光谱仪^[1],其光谱覆盖范围为0.4~2.5 μm ,光谱分辨率为10 nm,共有220个连续谱段,空间分辨率为30 m,幅宽为7.5 km。其数据广泛应用于地物波谱测量和成像、海洋水色要素测量、大气水汽/气溶胶/云参数测量等领域,是目前航天高光谱对地观测应用中使用最广的数据源之一。

1.2 HJ-1A 超光谱成像仪

HJ-1A超光谱成像仪是我国于2008年9月发射升空的环境与灾害监测小卫星(HJ-1A)上搭载的国内第一台超光谱成像仪^[3],目前仍然在轨运行,其光谱范围为0.45~0.95 μm ,光谱分辨率为5 nm,共有110~128个谱段,空间分辨率为100 m,幅宽为50 km,其在监测环境生态变化、自然灾害发生和发展过程

等领域发挥了重要作用。

1.3 海岸带高光谱成像仪(HICO)

海岸带高光谱成像仪(Hyperspectral Imager for the Coastal Ocean, HICO)于2009年9月10日由美国海军实验室等联合研制,在国际空间站(ISS)上实现对地观测^[4],设计寿命为1~3年,其光谱范围为0.4~1.0 μm ,光谱分辨率为5 nm,共有128个谱段,空间分辨率为100 m,幅宽为42 km,这是第一颗专门为研究海洋而研制的航天高光谱成像仪,研究内容包括水体光学特性、海底类型、水深和近岸植被分类等。

1.4 天宫一号高光谱成像仪

天宫一号高光谱成像仪是我国于2011年9月发射升空的天宫一号目标飞行器上搭载的高光谱成像仪^[5],在轨运行四年半,是当时在空间分辨率和光谱分辨率综合指标上最高的航天高光谱成像仪,其可见近红外光谱范围为0.4~1.0 μm ,光谱分辨率为10 nm,谱段数64个,空间分辨率为10 m;短波红外1.0~2.5 μm ,光谱分辨率为20 nm,谱段数64个,空间分辨率为20 m。在国土资源、海洋检测、林业遥感、城市环境监测、水文生态监测等方面开展了较大范围的应用研究工作,取得了一批有价值的应用研究成果。

1.5 高分五号可见短波红外高光谱相机

可见短波红外高光谱相机(Visible-shortwave infrared advanced hyperspectral imager, AHSI)是我国于2018年5月发射升空的高分五号上搭载的高光谱成像仪^[6],在0.4~2.5 μm 的光谱范围内细分了330个谱段;0.4~1.0 μm 范围内的光谱分辨率为5 nm;1.0~2.5 μm 范围内的光谱分辨率为10 nm,空间分辨率为30 m,幅宽为60 km,其与Hyperion相比,信噪比更高(约3~4倍),幅宽更宽(约8倍),谱段数更多。作为同时兼顾宽覆盖和宽谱段的高光谱成像光谱仪,将极大地提高对全球陆地环境生态资源的探测能力。

1.6 深空探测任务中的高光谱成像仪

小型火星侦察成像光谱仪(Compact Reconnaissance Imaging Spectrometer for Mars, CRISM)是美国于2005年8月发射的火星侦察轨道器(MRO)上的一个高光谱成像仪^[7],目前仍在轨运行,其光谱范围由可见近红外0.36~1.06 μm 和红外1.00~3.94 μm 两部分组成,共544个谱段,光谱分辨率为6.55 nm,空间

分辨率为 18 m, 在火星矿物填图等方面得到广泛的应用。2007 年 10 月 24 日我国发射的嫦娥一号卫星(CE-1)的干涉成像光谱仪(IIM)^[8], 月表像元分辨率 200 m, 光谱范围 0.48~0.96 μm, 谱段数为 32 个, 是我国第一台航天干涉式成像光谱仪, 2009 年 3 月 1 日完成使命, 在月球探测方面发挥了重要作用。印度空间研究组织(ISRO)2008 年在月船一号上搭载的超光谱图像仪 HySI 获得了月面高光谱图像^[9]。

1.7 规划研制中的高光谱成像仪

随着航天高光谱成像技术的快速发展, 各国均规划研制了性能和指标更加先进的航天高光谱成像探测载荷, 目前可查阅到的主要包括意大利的 PRISMA^[10]、德国的 EnMAP^[11]、美国的 HypSIRI^[12]、法国的 HypXIM^[13]等。

相关典型航天高光谱成像仪的主要信息如表 1 所示。

表 1 典型航天高光谱成像仪
Tab.1 Typical space hyperspectral imagers

Hyperspectral imaging spectrometer	Satellite/Spacecraft	Launch time/Predicted launch time	Country/Organization	Imaging mode	Main applied technical indicators					
					Spectral range/μm	Spectral bands	Spectral resolution /nm	Spatial resolution /m	SNR	Swath width/km
Hyperion	EO-1	2000	USA	Grating	0.4-2.5	242	10	30	144-161(VNIR) 40-110(SWIR)	7.5
FTHSI	MightSat-II	2000	USA	Interference	0.45-1.05	145	-	30	-	10-15
CHRIS	PROBA-1	2001	ESA	Prism	0.4-1.05	62 18	6-33	34 17	-	14
IIM	CE-1	2007	China	Interference	0.48-0.96	32	-	200	-	-
HySI	-	2008	India	-	0.4-0.95	64	10	506	-	129
HSI	HJ-1A	2008	China	Interference	0.45-0.95	110-128	5	100	50-100	50
HICO	ISS	2009	USA	-	0.35-1.08	128	5.7	100	≥ 200	42
HSI	TG-1	2011	China	Prism	0.4-2.5	128	10(VNIR) 23(SWIR)	10 20	≥ 200(VNIR) ≥ 150(SWIR)	10
AHSI	GF-5	2018	China	Grating	0.4-2.5	330	5(VNIR) 10(SWIR)	30	≥ 200(0.4-0.9) ≥ 150(0.9-1.75) ≥ 100(1.75-2.5)	60
PRISMA	PRISMA	-	Italy	Prism	0.4-2.5	249	10	30	200-600(VNIR) 100-400(SWIR)	30
HISUI	ALOS-3	2019	Japan	-	0.4-2.5	185	10(VNIR) 12.5(SWIR)	30	≥ 450(620 nm) ≥ 300(2 100 nm)	30
EnMAP HSI	EnMAP	2019	Germany	Prism	0.42-2.45	244	6.5(VNIR) 10(SWIR)	30	400(VNIR) 180(SWIR)	30
SHALOM	-	2021	Italy	-	0.4-2.5	275	10	10	200-600(VNIR) 100-400(SWIR)	30
HypSIRI	HypSIRI	2023	USA	Grating	0.38-2.5	214	10	30(60)	560(500 nm) 356(1 500 nm) 236(2 200 nm)	150
HypXIM	HypXIM	-	France	-	0.4-2.5	210	10	8	200-250(VNIR) ≥ 100(SWIR)	15

注: VNIR 代表可见近红外, SWIR 代表短波红外

随着近 20 年来航天高光谱成像技术的快速发展, 其主要应用技术呈现出光谱集中在可见近红外和短波红外(0.4~2.5 μm)或者可见近红外光谱(0.4~

1.0 μm) 范围内, 谱段数从大于 100 向 200 多甚至 300 多个发展, 光谱分辨率主要在 10~20 nm 之间, 并在逐步提高到 5 nm; 空间分辨率在从 100 m 量级向 30 m 左右及以内发展, 信噪比大幅提升等特点, 以满

足各领域应用与科学研究的需求。

2 高光谱遥感应用研究

文中重点对近五年来(2013~2018年)的航天高光谱遥感数据在国土资源调查、农林遥感、海洋湖泊遥感、城市环境监测、灾害监测及其他等多个领域的应用研究成果进行了总结与分析,阐释了近年来高光谱遥感的应用进展情况。

2.1 国土资源遥感应用

2.1.1 矿产资源勘查

高光谱遥感因其高光谱分辨率特性,可实现对不同矿物元素的精细化探测和分类,定性或定量地反演矿物种类和含量,开展矿物填图和找矿预测等研究。目前,常用的研究方法主要包括基于地物光谱的吸收特征、混合光谱分解和多元统计分析方法等。Chen 等人^[14]提出了一种耦合(SVSCD)的矿物提取方法,主要是利用土壤与植物的光谱吸收特性的谱段差值,计算组合成新的数据集,对其进行光谱特征拟合(SFF)来识别蚀变矿物。该方法应用 Hyperion 高光谱数据有效地检测植被覆盖区域的蚀变矿物,解决了植被覆盖区矿物鉴别的难题。Liu 等人^[15]利用天宫一号高光谱数据,研究光谱角度映射算法(Spectral Angle Mapper, SAM)对甘肃北山金坛子地区的蚀变矿物进行识别,检测到褐云母、高岭石、绿泥石、绿帘石、方解石、白云岩等,并利用现场测试的矿物信息对地质图进行定性评估,结果表明,天宫一号高光谱数据正确地捕捉到了 6 个矿床和至少 20 个野外位置的观测结果,结果如图 1 所示。

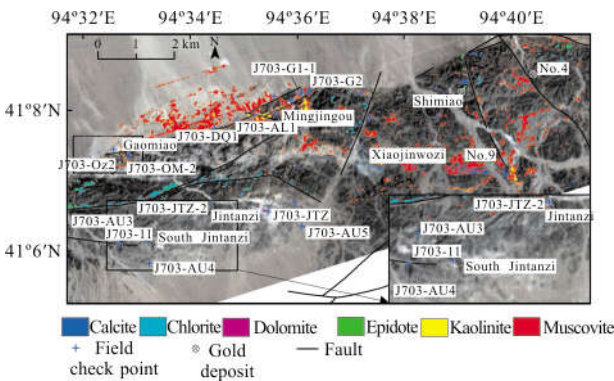


图 1 天宫一号高光谱数据甘肃北山金坛子地区矿物分布图^[15]

Fig.1 Mineral map of Tiangong-1 hyperspectral data in part of Jintanzi area, Beishan, Gansu province, northwest China

林健和闫柏琨等人^[16]结合地面实测光谱数据、HyMap 航空成像数据,对天宫一号成像光谱数据质量在矿物识别方面的应用价值进行定量评价,研究结果表明,矿物识别主要采用短波红外谱段数据,天宫一号高光谱数据的信噪比明显优于 Hyperion 数据。此外,采用 2 190~2 230 nm、2 310~2 355 nm 两个谱段的吸收深度初步对天宫一号高光谱短波红外数据的真实性进行了评价,经过校正后,天宫一号高光谱数据 Al-OH、Mg-OH/CO₃2-矿物大类的漏提率从 71%、67%降低至 29%、28%,有效提高了弱信息的检出率。

2.1.2 土地利用监测

高光谱成像探测能够提供连续的地物波谱信息,获得丰富的精细化光谱特征,提高地物识别能力。传统的土地分类方法包括光谱特征提取与定量分析、决策树分类、智能自动化分类等。近年来基于深度学习的方法来学习光谱特征与对应标签之间的复杂联系,为高光谱数据处理提供了新的工具,逐步成为了高光谱图像分类研究的新热点。

Elatawneh 等人^[17]利用 Hyperion 数据评估了多种分类技术在典型地中海环境中进行土地使用/覆盖分类的效果,结果表明,面向对象分类方法的总体精度优于其他分类技术,分类精度为 83%,较其他方法提高 30%以上。Xing^[18]利用 Hyperion、AVIRIS 和 ROSIS 高光谱数据,采用深度学习对数据进行特征提取,利用多层降噪自动编码器(Stacked Denoise Auto encoder)中的修正线性单元(ReLU)作为激活函数来提取稀疏特征。结果表明,结合逻辑回归分析法(Logistic Regression)微调和多层降噪自动编码器预训练可以达到比支持向量机(SVM)更高的分类精度。李竺强等人^[19]结合高光谱影像中的空间特征与光谱信息,提出一种适合于高光谱像素级分类的深度学习三维卷积神经网络模型(3D-CNN),分别选取三个通用高光谱数据集(Indian Pines 数据集、Pavia University 数据集、Pavia Center 数据集)进行测试,分类精度得到很大提升,总体精度达 98%。

同时,研究融合多源数据弥补单一数据源信息不足的缺点,综合利用数据集的时间、光谱和地形特性可以实现土地利用更好的分类精度^[20]。Chen 等人^[21]提出了通过融合多源遥感特征提高土地覆盖分类精

度,并进一步研究了不同特征对分类性能的影响。利用 Landsat-8、MODIS、HJ-1A 和 ASTER DEM 的融合结果表明,可以实现更好的土地覆盖分类精度,总体精度提高了 4.53%,达 92.31%,如图 2 所示。

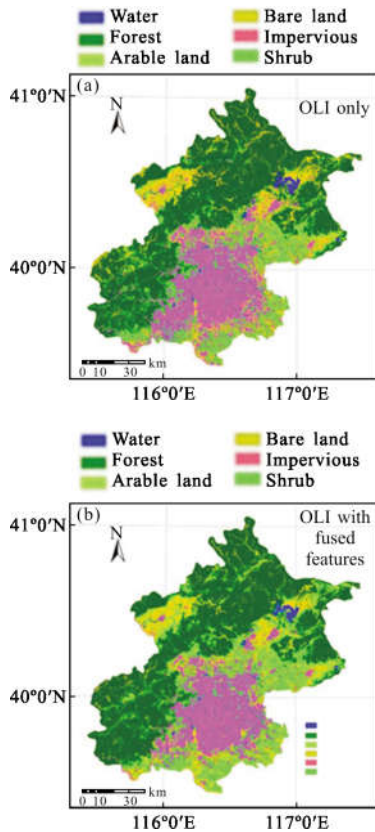


图 2 基于 Landsat-8 OLI 数据和融合 HJ-1A 等数据的北京市土地覆盖分类图(a)仅 Landsat-8 OLI 的分类结果(b)融合了时间 EVI 剖面、多角度观测和地形特性的 OLI 数据的分类结果^[21]

Fig.2 Comparison of land cover classification maps of Beijing by using onlyLandsat-8 OLI, and fused with HJ-1A data. (a) is the classification result derived from the Landsat-8 OLI data only, and (b) is that derived from OLI data integrated with fused temporal EVI profiles, multi -angular observations, and topographic features

2.1.3 土壤资源监测

航天高光谱遥感主要用于获取土壤有机质的反射光谱特征、土壤水分与土壤反射光谱关系、土壤氧化铁的光谱反射特性等土壤质量信息,进而对土壤的特性参数进行评价。目前,已有许多高光谱数据研究致力于建立各种土壤属性(如纹理、有机物、氧化铁含量、土壤养分、土壤含水率等)与地表反射率的关系。

Lu 等人^[22]用 Hyperion 高光谱数据开展了土壤有机碳(SOC)、总磷(TP)等含量分布反演研究,SOC 和 TP 模型的精度中等($R^2>0.6$, $RPD>1.5$),结果如图 3 所示,并将反演精度低的原因归因于数据的空间分辨率。Steinberg 等人^[23]利用模拟的 EnMAP 数据绘制了其他土壤性质,如粘土和氧化铁的含量等,结果显示由于空间分辨率的原因,导致反演的土壤参数精度不高,适合于区域尺度的土壤预测等应用。Castaldi 等人^[24]用 Hyperion、HyspIRI、EnMAP、PRISMA、Landsat-8、ALI 和 Sentinel-2 MSI 等多源数据分别分析了土壤质地(即粘土、沙子、淤泥)和土壤有机碳(Soil Organic Carbon, SOC)含量,结果表明,利用即将发射的高光谱成像仪(即 HyspIRI、EnMAP 和 PRISMA)得到的反演结果非常相似,并且由于其具有较多的谱段和精细的光谱信息,得到比其他成像仪(即 Hyperion、Landsat-8 和 Sentinel-2 MSI)更高的反演精度。




图 3 利用 Hyperion 数据反演土壤参数有机碳 SOC、总磷 TP 含量的空间分布^[22]

Fig.3 Spatial distributions of the predicted SOC and TP content using Hyperion data

航天高光谱成像仪也用于土壤侵蚀测绘应用研究。然而,EnMAP 的空间分辨率成为绘制与土壤侵蚀(如 PV、NPV 和裸土)有关的土地利用覆盖图的限制因素^[25]。尽管如此,这种光谱成像仪足以进行区域尺度的侵蚀研究。空间分辨率成为航天高光谱成像仪在精细尺度上开展土壤参数反演的致命弱点,需要成像技术的进一步突破和发展。

2.2 农林遥感应

航天高光谱成像仪能够获取地物准确的精细光谱曲线,便于提取出叶面积指数、生物量、叶绿素含量等农林作物的生理生化属性,在精确监测农作物的类别、种植面积、产量估计和作物分类等方面有广泛的应用,为精细农、林业管理提供强大的数据技术支持。

2.2.1 生长长势监测

叶面积指数是指单位土地面积上植物叶片总面积占土地面积的倍数,反映了植被叶片含量在整个区域的疏密程度,是一个重要的植被生化物理参数。目前,采用遥感数据反演植被叶面积指数的方法主要为经验模型、物理模型和混合模型 3 类。

Liang^[26]利用曲线拟合、人工神经网络(ANN)和随机森林回归 (RFR) 等建模算法确定植被指数 (Vegetation Indices)最优反演模拟,并且利用反演模型对 CHRIS 图像进行遥感填图,验证叶面积指数(Leaf Area Index) 达到 $R^2=0.928$ 和 $RMSE=0.485$ 的估算精度,结果如图 4 所示,证明了使用高光谱植被指数(VI)




图 4 利用 CHRIS 图像反演农作物叶面积指数分布^[26]

Fig.4 Spatial distribution map of crop LAI estimated from CHRIS images

和混合反演方法对作物 LAI 进行高精度估计的可行性。Heiskanen^[27]使用 Hyperion 图像和同步测量数据,利用窄谱段植被指数、近红外谱段和短波红外谱段与有效叶面积指数(Leaf Area Index)的线性关系来估算森林地区有效叶面积指数(Leaf Area Index)。

生物量是与叶面积指数和作物产量密切相关的重要属性参数,其估算方法与估算叶面积指数的方法类似^[28]。Kattenborn^[29]综合利用 Hyperion、Tandem-X、WorldView-2 等多源遥感数据,使用 4 种不同的机器学习算法反演了德国卡尔斯鲁厄附近温带森林中的生物量,最高达到了 $R^2=0.73$, $RMSE=14.9\%$ 的反演精度。生物量是对作物估产的一个重要参数,Michael Marshall 等人^[30]分别比较了高光谱(Hyperion)和多光谱数据 (GeoEye-1, Landsat ETM+, MODIS, WorldView-2) 在捕获作物生物量变异性的能力,结果表明,高光谱比多光谱在捕获作物生物量变异性的能力提高 5-31%。

2.2.2 生理生化状态监测

植被光合作用是进行有机物积累的重要过程,通过反演叶绿素含量能够有效地监测植被光合作用动态变化。蒙继华等人^[31]综合分析了农作物叶绿素含量遥感估算的研究进展与展望,认为在遥感数据源方面,农作物叶绿素估算模型大都采用高光谱数

据。Liang^[32]比较了 CHRIS 50 种植被指数,选择出一些最合适的植被指数,利用曲线拟合、最小二乘支持向量机、随机森林回归(Random Forest Regression)等不同建模方法,反演了叶片和冠层叶绿素含量,如图 5 所示。Yang^[33]利用 Hyperion 数据的 25 个光谱参数,通过逐步回归和几何光学模型反演叶绿素含量。其他常用的方法有人工神经网络^[34]等。




图 5 作物叶绿素含量的空间分布图((a)叶片叶绿素含量, (b)冠层叶绿素含量)^[32]

Fig.5 Spatial distribution map of the crop chlorophyll content predicted (a) LCC, (b) CCC

作物通过光合作用积累有机物辅助生长,研究光合作用强度有利于分析植被利用光能的能力和敏感程度。目前主要是利用叶面的反射光谱计算反射光谱指数,再根据反射光谱指数之间的差异性对作物的光合过程以及状态进行监测。Stagakis^[35]从 CHRIS 高光谱和叶片测量中得到归一化差异光谱指

数(NDSI),跟踪地中海沙棘灌木生态系统叶片和冠层光利用效率的季节性变化。

在作物生长周期内准确地监测氮含量,有利于合理施肥,节约肥料,提高作物产量的同时降低对环境的压力。目前,碳含量监测的主要算法是根据氮素参数的变化形成的光谱参数,建立起不同品种的估算模型,达到碳含量监督的目的。Castaldi^[36]综合利用高光谱(CHRS)和多光谱(SPOT4 和 SPOT5)数据,通过逐步回归分析法选择最优的光谱段组合,分析了小麦不同生长阶段的氮吸收谱段的变化情况。

2.2.3 分类与估产

航天高光谱遥感能够快速有效地采集地物精细特征参数,有利于地表类型的分类和识别提取,在植被精细分类、草地分类、森林树种分类等方面有着广泛的应用。

李强子等人^[37]综合分析了农作物遥感分类中使用的各种特征,认为高光谱数据的光谱分辨率很高,能探测到农作物在光谱特征上的微小差异,从而精确识别不同的农作物。Thenkabail^[38]利用 Hyperion 和实地观测高光谱数据对占全球 70%农田面积 6 个不同生长阶段的 8 种主要作物(小麦、玉米、水稻、大麦、大豆、豆类、棉花和苜蓿)进行了研究,选取 20 个最优的高光谱植被指数和高光谱谱段,描述、分类、建模和绘制世界主要农作物的地图,总体识别精度达到 95%。Pan^[39]利用 Hyperion 数据,采用多范围光谱特征拟合(MRSFF),对目标光谱特征进行分类,在不影响光谱剖面完整性的前提下对目标光谱特征进行表征,提取油菜种植面积。

Awad^[40]利用 Hyperion、ALI 等多源数据,采用改进的光谱角度映射器(SAM)方法开展了黎巴嫩地区森林分类效果研究,研究结果表明,在相同条件下,改进后的 SAM 比传统 SAM 分类精确高约 9%,在石松覆盖提取中,Hyperion 分类精度为 91%,而 ALI 分类精度仅为 52%,结果如图 6 所示。张康等人^[41]为了实现地物精准分类,提出一种适用于高光谱遥感图像分类的变异系数与卷积神经网络相结合(CV-CNN)的方法,这种新方法引入变异系数的思想来衡量高光谱遥感图像不同波段之间的相似性和差异性,从而提出类间变异系数(CVIE)和类内变异系数(CVIA)的概念。利用 Indian Pines 和 Pavia University 两组数据的实验结果表明,该方法在两种数据集下的总体精度分别达到 98.69%和 99.66%,有效地改

善了高光谱遥感图像的分类精度。

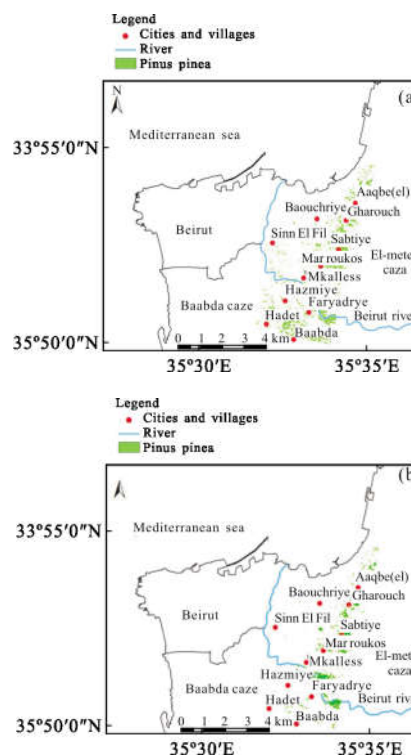


图 6 基于 Hyperion 和 ALI 的分类图^[40]
Fig.6 Classified images of (a) Hyperion and (b) ALI

航天高光谱的作物产量预测主要是通过采集作物各个生长时期的光谱特征,对其产量进行预测与估产。Mariotto 等人^[42]利用高光谱(Hyperion 高光谱成像仪和 ASD 光谱仪)和多光谱(ETM+、ALI、IRS、IKONOS 和 QuickBird)反射率数据,在中亚地区收集了世界上 5 种主要农作物(棉花、小麦、玉米、水稻和紫花苜蓿)在 2006~2007 年生长期间的大量田间光谱和生物物理变量,在给定作物变量的线性回归模型中,利用 3 到 7 个高光谱谱段数据进行产量估产研究,总体精度可达到 93%以上。Zhang^[43]选择美国农业部位于马里兰州的一块试验田作为研究对象,利用 Hyperion 图像和现场光谱测量数据,采用先进的辐射传输模型 PROSAIL2 和蒙特卡罗马尔可夫估计方法来预测玉米田的植被总生产力(vegetation gross primary productivity, GPP),结果表明估算值与实测值之间显著相关($R^2=0.93$, $RMSE=1.71$)。

2.3 海洋湖泊遥感应用

高光谱遥感已成为当前海洋及湖泊遥感前沿领域,不仅可以监测水质,还便于进行长期动态监测。目前,利用高光谱遥感数据可以反演叶绿素、悬浮

物、黄色物质、透明度、浑浊度等水色参数,可以对远洋、近岸和内陆水体的藻类组成进行分析,监测蓝藻水华,探测海冰及海岸带等。

2.3.1 水色参数遥感反演

随着海洋环境监测需求的迫切发展,高光谱水色遥感,为研究海洋环境的物理化学特征和生物化学特征提供了条件。

邓实权等人^[44]利用鄱阳湖实测高光谱数据,结合 GF-5 卫星高光谱传感器的波段设置,开展光谱模拟、异常剔除、归一化、一阶差分、二阶差分处理,并建立了叶绿素 a 浓度跨阶分多波段反演模型。结果表明,进行光学分区有利于提高了反演精度,非高浑浊水体的反演模型判定系数的 R2 达 0.82,而不进行光学分区反演建模 R2 仅为 0.37,GF-5 卫星高光谱成像仪在浑浊水体叶绿素 a 反演研究中具有一定潜力。潘邦龙等人^[45]利用 HJ-1A 高光谱数据,建立了基于协同克里格遗传算法的湖泊水质总磷浓度高光谱遥感反演模型,对巢湖水质总磷浓度进行反演,结果比传统遗传模拟平均误差(ME)和均方根误差(RMSE)分别降低了 128.2%、53%,有效提高反演的精度。利用高光谱数据可以实现远洋、近岸以及内陆水体的叶绿素、悬浮泥沙、黄色物质等光学要素的反演,此外有研究用于营养盐、碳组分等非光学活性水质参数的反演。Giardino 等人^[46]利用 Hyperion 数据对意大利加尔达湖水质进行评价,其中叶绿素 a 的监测结果较好,沉积在湖中的非生物性悬浮物的监测结果较为一般,有色溶解性有机物因其湖泊中的浓度很低无法对其进行评价,评价结果如图 7 所示。

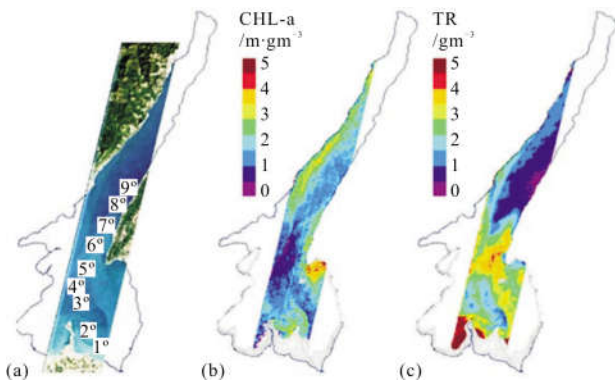


图 7 基于 Hyperion 数据反演 CHL-a 和 TR 分布图 (2003 年 7 月 22 日)^[46]

Fig.7 Distribution maps of CHL-a and TR based on Hyperion data on July 22nd, 2003

2.3.2 蓝藻水华遥感监测

高光谱数据具有更精细的光谱,可实现藻类类型监测、海草生物特征参数反演、蓝藻水华监测及预警等。房旭等人基于多源卫星数据对小型水体的蓝藻水华进行联合监测,HJ-1A/B CCD、GF-1 WFV 和 Landsat-8 OLI 的监测结果一致性良好,一致性精度达到 99.5%^[47]。Casey 等人用 Hyperion 数据反演海草生物特征参数,包括水下水生植被盖度、LAI 和生物量等。此外,Hyperion 数据还用于 1~25 m 水深的高精度探测^[48]。多项研究采用 HypSIIRI 数据进行叶绿素 a、藻蓝蛋白反演以及巨型海藻或马尾藻的动态监测^[49-50]。Bell 等人^[50]利用卫星、机载和野外数据来评估 HypSIIRI 高光谱数据的空间分辨率、时间分辨率和光谱分辨率对捕获巨藻生物量和生理状态变化的适用性,结果表明 HypSIIRI 数据的空间、时间和光谱覆盖能力将为巨藻生态学和生物物理提供新的见解,结果如图 8 所示。

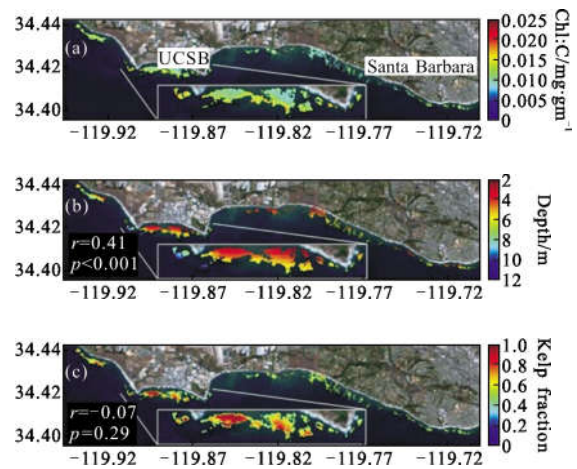


图 8 2013 年 4 月 11 日,圣巴巴拉地区海带表面冠层 Chl:C 分布图(a)深度(b)和海带像素分数(c)^[50]

Fig.8 Map of the distribution of estimated Chl:C in the surface canopy (a) depth (b) and kelp pixel fraction (c) of Santa Barbara area kelp forests on April 11th, 2013

2.3.3 海冰监测

海冰在海洋表面辐射、能量和质量的平衡中起着关键作用。高光谱遥感为海冰探测提供了重要的数据资源。Han 等采用 Hyperion 高光谱数据,基于海冰的光谱特征,提出了一种基于线性预测的海冰相似性测量方法(ISMLP)对格陵兰巴芬湾和渤海湾的海冰进行分类,精度达 91.18%^[51],结果如图 9 所示。

同时, Han 等人于 2018 年又提出了一个结合主动学习(AL)和半监督学习(SSL)的海冰探测分类, 精度进一步提高达 97.49%^[52]。Wang 等人提出了一种新的基于自步态增强学习(SPBL)的海冰分类框架, 精度达 97.01%。各项研究成果都验证了高光谱遥感数据在海冰检测中的可行性。

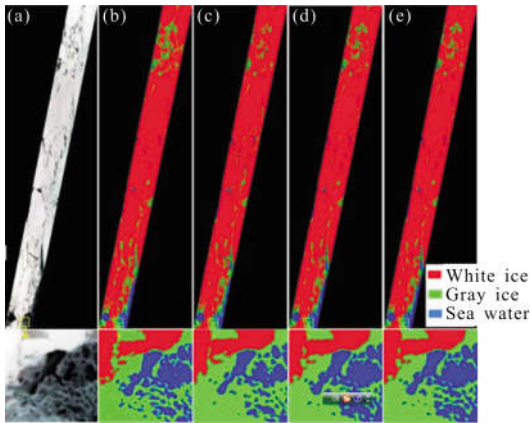


图 9 格陵兰巴芬湾海冰分类结果(a)真彩色合成图像;(b)基于 Landsat-8 数据的分类结果;(c)采用 ISMLP 方法选择 Hyperion 数据的两个谱段的分类结果;(d)采用 ISMLP 方法选择 Hyperion 数据的 3 个谱段的分类结果;(e)采用 ISMLP 方法选择 Hyperion 数据的 4 个谱段的分类结果^[51]

Fig.9 Classification of sea ice in Baffin Bay, Greenland: (a) true color composite image; (b) classification results of Landsat-8; (c) classification results using two bands selected with the proposed ISMLP method; (d) classification results using three bands selected with the proposed ISMLP method; (e) classification results using four bands selected with the proposed ISMLP method

2.4 城市环境遥感应用

目前航天高光谱数据的城市应用主要涉及土地分类与利用、不透水表面监测等方面, 但较低的空间分辨率常常带来混合像元问题, 影响高光谱数据在城市环境监测中的应用。

2.4.1 城市土地分类与利用

城市土地分类与利用是高光谱在城市环境的主要应用之一, 分类方法采用面向对象分类、支持向量机(SVM)、人工神经网络(ANNS)等常规土地利用分类法。Petropoulos 和 Kalivas 等人^[53]采用 Hyperion 数据利用光谱角度映射器(SAM)和支持向量机(SVM)分类器对雅典市城市植被覆盖分类, 总体分类精度

分别为 86.53%(SVM)、75.13%(SAM), 客观评估了 Hyperion 在检测和绘制城市植被覆盖方面的作用, 结果如图 10 所示。Okujeni 等^[54]用模拟的 EnMAP 数据对城市的土地覆盖应用进行了评估, 认为其在城市土地利用分类上有较大应用潜力。

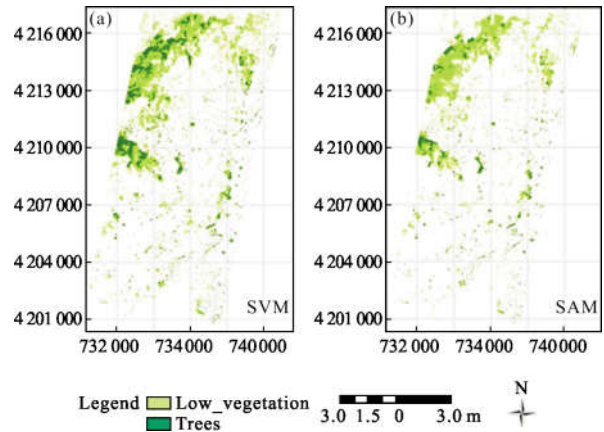


图 10 利用 SVMs 分类器(a)和 SAM 分类器(b)的 Hyperion 数据分类^[51]

Fig.10 Hyperion classification using SVMs classifier(a) and SAM classifier(b)

Li 等人^[55]利用北京地区天宫一号高光谱数据, 选用用于区分城市区域的最佳高光谱谱段, 采用最大似然分类器(PMLC)、基于像素的支持向量机(PSVM)等分类方法, 对城市土地覆被类型进行分类, 获得平均总体准确率为 88.43%, 91.94%的分类精度。结果表明, 天宫一号高光谱数据在复杂城市场景分类方面具有较高的应用潜力。

Zhang 等人^[56]利用 Urban 高光谱数据集, 提出了一种基于 CNN 架构的卷积神经网络(CNN)的高光谱混合像元的分离(HU)方法, 对城区的沥青、绿地、树木、房屋、金属、泥土等目标进行混合像元处理, 最小均方差分别为 0.048、0.047、0.037、0.026、0.034、0.044。与 LSU、AANN、eSVM 等现有方法相比, 所提算法显示出更高的准确性。

2.4.2 不透水表面分类与识别

由于全球城市化的快速发展, 不透水表面越来越多, 会引发一系列严重的生态和环境问题, 及时确定不透水面分布信息对环境和自然资源保护具有重要意义。目前, 利用高光谱数据进行不透水表面提取方法主要包括: (1) 光谱混合分析; (2) 不透水面指数; (3) 多元回归等。

Tang 等人^[57]利用 Hyperion 高光谱数据,采用线性光谱混合分析法,提取了中国的广州、福州、杭州等城市的不透水表面信息,并使用 IKONOS 等高分辨率图像验证不透水表面的提取信息,结果表明提

取的准确性和覆盖率在三个测试区域的准确度和覆盖率都很高,如图 11 所示。Weng 等人^[58]研究表明,在相同空间分辨率下,EnMAP 等高光谱数据比多光谱数据 (Landsat, ALI) 有更好的不透水表面识别能

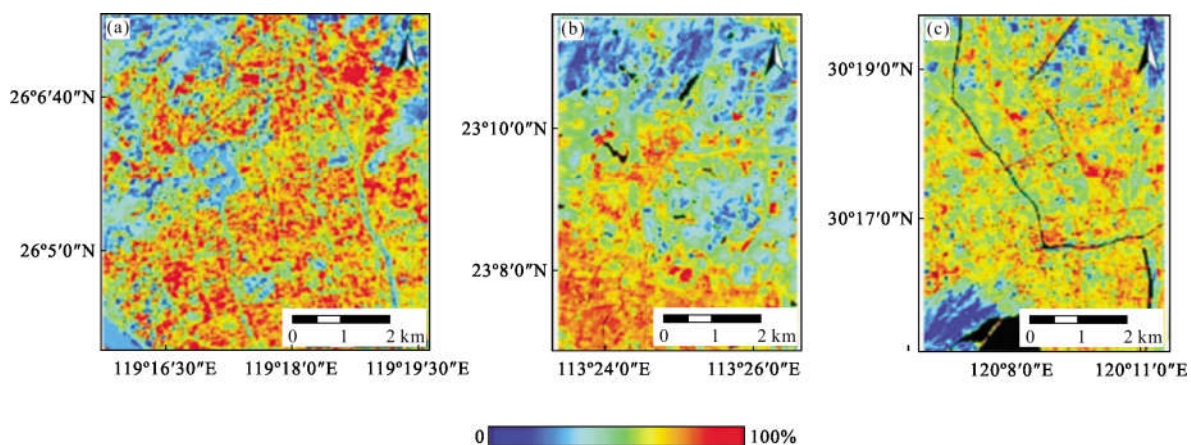


图 11 城市不透水表面(福州,广州,杭州)^[57]

Fig.11 Impervious surface images(Fuzhou, Guangzhou, Hangzhou)

力,然而,与机载 HyMAP(9 m GSD)相比,EnMAP 中等空间分辨率导致细节丢失和混合像元更多,降低了异构和复杂区域的映射精度。

2.5 灾害监测应用

2.5.1 火灾与火山监测

在火灾监测的应用主要集中在火灾预防和灾后评估与恢复等方面,但是重访周期是航天高光谱遥感在火灾监测中的重要影响因素。

在火灾预防方面,主要是识别燃料类型、覆盖情况及植被含水量等参数。燃料类型和覆盖监测主要通过光谱混合物分析法(SMA)确定^[59],燃料水分含量可以从具有高吸水性的光谱区域中的高光谱中推导出^[60]。GiorgosMallinis 等人利用 Hyperion 高光谱数据,采用支持向量机分类方法^[61],区分和绘制地中海燃料类型,达到 70%的总体准确度。然而,Roberts 等^[62]通过检测木质纤维素带达到检测火灾危险区域的目的,一定程度上避免了 Hyperion 数据 SNR 较低带来的影响。

灾后评估与恢复方面主要是开展植被退化、灾害恢复等方面研究。Numata 利用 Hyperion 数据监测火灾后植被退化^[63],获得了较高的总体准确度。Zhang 等人^[64]采用 HJ-1A 高光谱数据研究了黑龙江逊克县森林大火后植被恢复情况,利用支持向量机分类法进行表面特征识别,在此基础上将图像区域

分为七类,并对分类类型进行统计分析。结果表明,HJ-1A 高光谱数据在表面特征精细分类方面具有很大的潜力,分类准确率为 91.8%,分类结果如图 12 所示,轻度和严重的火灾影响区域提取为灾后恢复监测提供了有用的参考。




图 12 黑龙江省逊克县森林大火灾后恢复监测评估^[64] (a) RGB 图像(波段 75/100/40);(b) 分类图

Fig.12 Monitoring and evaluation of forest restoration after the fire in Xunke County, Heilongjiang Province (a) RGB image (band 75/100/40); (b) classification map

航天高光谱也应用在火山喷发规律分析、火山分类、火山监测等方面开展研究。Abrams^[65]等人利用涵盖 2001~2010 年间的 6 个火山喷发期的 28 个

Hyperion 数据和 12 个 ASTER 数据,提取了火山气体和表面温度,研究了埃特纳火山喷发的时间序列的规律。Amici^[66]利用 Hyperion 高光谱数据、多光谱数据和实测光谱对泰德火山进行多特征表达,并进行了分类测绘,获得较好分类结果。DAVIES 等人^[67]在 EO-1 平台上安装一个高级软件应用程序 ASE (Autonomous Sciencecraft Experiment),在轨控制 Hyperion 成像仪对火山活动进行远程检测与反应,可以自动识别有效活跃的熔岩湖、明渠流动和熔岩穹顶等各种类型的火山。

2.5.2 其他灾害监测

航天高光谱也应用在其他灾害监测上,水灾监测是航天高光谱数据的又一类重要应用。美国国家航空航天局(NASA)利用 HICO 高光谱数据在水灾监测方面发挥了重要作用^[68],比如 2013 年 10 月 16 日由于热带气旋引起的印度洪水监测、2014 年 7 月越南洪水监测、2014 年 8 月巴拿马洪水和山体滑坡等。

Crowley 等人^[69]利用 Hyperion 数据和航空可见光/红外数据 AVIRIS,在检测导致雪崩的水热蚀变岩石方面取得了令人满意的结果,确定了最具风险的岩石区域。

2.6 其他应用

航天高光谱影像应用潜力巨大,远远不仅限于上述应用领域,在其他方面诸如遥感考古、气溶胶/水汽估算等众多领域也有广泛的应用。

航天高光谱遥感具有识别文物遗微弱信息和定量探测的优势,在考古应用中也发挥着其积极作用。Savage 等人^[70]在约旦 WAG 地区的一个古老的铜冶炼场地(Khirbaten-Nahas, KEN),利用 Hyperion 数据定位其他矿石加工点和不同矿区,识别可能有助于阐明与 KEN 生产组织相关的沉积物差异等。

Davies 等人^[71]利用 CHRIS 和模拟的 Sentinel-3 数据提出了一种仅使用角度检索估算气溶胶光学厚度(AOD)的方法,旨在提高 AOD 的估算,探索通过耦合表面/大气辐射传输模型的反演估算陆地表面上的精细模式分数(FMF)和单次散射反照率(SSA)。试验结果显示,估算的气溶胶光学厚度的 RMSE 达到 0.06。

3 应用发展趋势分析

3.1 高光谱遥感数据智能化处理与分析能力增强

随着深度学习等 AI 智能化技术的发展,越来越

多研究人员将此技术应在高光谱遥感应用中。如李竺强等人^[72]提出了一种像素级分类的深度学习三维卷积神经网络(3D-CNN),对通用高光谱数据集进行分类测试,总体精度达到 98%;Zhang 等人^[56]利用提出一种卷积神经网络(CNN)进行高光谱混合像元的分离(HU),对 Urban 高光谱数据集的沥青、绿地、树木、房屋等目标进行混合像元分解;张康等人^[41]提出一种适用于高光谱遥感图像分类的变异系数与卷积神经网络相结合(CV-CNN)的方法,有效地改善了高光谱遥感图像的分类精度等。纵观近 5 年发展,基于深度学习等 AI 智能化技术增强了信息提取的精度和应用分析的准确度,在矿产资源勘探、土地利用监测、分类与估产、城市土地分类与利用等遥感领域应用发展显著,将在高光谱应用中发挥越来越重要的发展推动作用。

3.2 高光谱与其他多源遥感数据的融合应用逐步提升

在越来越多的高光谱遥感应用中,结合其他数据源能够提供地物目标更多的精细信息,如融合高空间分辨率的多光谱数据、地面实测的典型目标光谱信息、高程信息、城市建筑模型等等,减少混合像元等现象。例如,Castaldi^[36]利用高光谱(CHRIS)和多光谱(SPOT4 和 SPOT5)遥感数据,通过逐步回归分析法选择最优的光谱段组合,分析小麦不同生长阶段的氮吸收谱段的变化情况;Koppe^[73]利用 Hyperion 数据和 Envisat ASAR 微波数据,建立了小麦地表反射率、地表后向散射和小麦立地生物量之间的线性回归模型来估算生物量等。基于高光谱遥感数据与其他多源数据的融合广泛应用在矿产资源勘探、土地利用监测、土壤资源监测、生长长势监测、城市土地分类与利用、火灾与火山监测等遥感应用领域,并将在更广泛的领域发挥作用。

3.3 高光谱遥感应用不断向深空探测应用领域迈进

随着高光谱成像仪技术的不断进步,航天任务的快速发展,深空探测逐渐成为重要的应用之一。

紧凑型侦查成像光谱仪(CRISM)经过长期绕火星飞行后,于 2006 年开始陆续传回大量的火星表面高光谱图像,进一步揭示了火星表面存在水等物质的证据^[73]。嫦娥一号卫星(CE-1)的干涉成像光谱仪(IIM),开展铁钛元素、FeO、Al₂O₃ 反演及月球岩石类型填图等研究,在月球探测方面发挥了重要作用^[81]。印度空间研究组织(ISRO)2008 年在月船一号上搭载

的超光谱图像仪 HySI 获得了大量月球表面矿物分布图像数据^[9]。未来,随着美国重返月球计划、中国载人登月及其他深空探测计划的推进与发展,航空高光谱遥感将在矿物识别、行星找矿等方面将会发挥越来越大的作用与价值。

3.4 高光谱成像仪技术的进一步突破,将更好地推动高光谱应用领域的发展

目前,高光谱成像仪的光谱分辨率越来越精细,达到纳米级,谱段数越来越多,增至数百个,极大的增强了遥感信息获取能力;随着大面阵高分辨率探测器技术的进步,在光谱分辨率提高的同时空间分辨率也逐渐提高;并且通过多卫星组网等技术,提高航天高光谱的重访周期等。高光谱分辨率、高空间分辨率、高时间分辨率的“三高”新特征已经越来越明显,满足未来各领域应用与科学研究的迫切需求。

随着航天高光谱成像仪在光谱分辨率、空间分辨率、重访周期等指标的进一步优化与提高,必将促进航天高光谱遥感在各领域应用与成果产出的广度与深度。

4 结论

随着航天高光谱成像技术的快速发展,新型高光谱成像仪不断涌现,其应用技术指标逐渐提高不断满足遥感应用的发展需求。航天高光谱遥感在国土资源、农林遥感、海洋湖泊遥感、城市环境、灾害监测及其他等各领域应用研究中取得了良好的发展与突破。光谱分辨率、空间分辨率、信噪比、幅宽及在轨道精度等航天高光谱成像仪应用技术指标的进一步发展将会有力地提升遥感应用的分析精度。目前,航天高光谱遥感应用呈现出基于 AI 技术的高光谱数据处理与分析、基于高光谱遥感的多源数据融合与应用和面向深空探测领域的高光谱数据分析与应用等趋势,高光谱成像仪技术的进一步突破与应用研究需求的牵引将会更好地推动高光谱应用领域的创新与发展。

参考文献:

- [1] Folkman M, Pearlman J, Liao L, et al. EO-1/Hyperion hyperspectral imager design, development, characterization, and calibration[C]//SPIE, 2001, 4151: 40-51.
- [2] Bamsley M J, Settle J J, Cutter M A, et al. The PROBA/CHRIS mission: A low-cost smallsat for hyperspectral multiangle observations of the earth surface and atmosphere [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(7): 1512-1520.
- [3] Yuan Yan, Li Liying, Xiong Wang'e, et al. Mechanical structure design for hyperspectral imager of HJ-1A satellite [J]. *Spacecraft Engineering*, 2009, 18(6): 97-105.
- [4] Lucke R L, Corson M, McGlathlin N R, et al. Hyperspectral imager for the coastal ocean: instrument description and first images[J]. *Applied Optics*, 2011, 50(11): 1501-1516.
- [5] Gao Ming, Zhang Shancong, Li Shengyang. Tiangong-1 hyperspectral remote sensing and application [J]. *Journal of Remote Sensing*, 2014, 18(s1): 2-10. (in Chinese)
- [6] Liu Yinnian. Visible-shortwave infrared hyperspectral imager of GF-5 satellite [J]. *Spacecraft Recovery & Remote Sensing*, 2018, 39(3): 25-28. (in Chinese)
- [7] Murchie S, Arvidson R, Bedini P, et al. Compact Reconnaissance Imaging Spectrometer for Mars (CRISM) on Mars Reconnaissance Orbiter (MRO) [J]. *Journal of Geophysical Research Atmospheres*, 2007, 112(E5): 431-433.
- [8] Li Xiaopeng, Chen Jianpeng, Wang Xiang. Inversion of lunar nearside FeO and Al₂O₃ based on Chang'e-1 reflectance data [J]. *China Mining Magazine*, 2018, 27 (7): 150-156. (in Chinese)
- [9] Staenz K, Held A. Summary of current and future terrestrial civilian hyperspectral spaceborne systems [C]//2012 IEEE International Geoscience and Remote Sensing Symposium, 2012: 123-126.
- [10] Stefano P, Angelo P, Simone P, et al. The PRISMA hyperspectral mission: science activities and opportunities for agriculture and land monitoring [C]//2013 IEEE International Geoscience and Remote Sensing Symposium, 2013: 4558-4561.
- [11] Guanter L, Kaufmann H, Segl K, et al. The EnMAP spaceborne imaging spectroscopy mission for earth observation[J]. *Remote Sensing*, 2015, 7(7): 8830-8857.
- [12] Lee C M, Cable M L, Hook S J, et al. An introduction to the NASA Hyperspectral InfraRed Imager (HypIRI) mission and preparatory activities [J]. *Remote Sensing of Environment*, 2015, 167: 6-19.
- [13] Lefevre-Fonollosa M-J, Fratter I, Manda M. HYPXIM: an innovative hyperspectral satellite for science, security and defence[J]. *Egu General Assembly*, 2013, 15: 10129.
- [14] Chen S, Huang S, Liu Y, et al. Soil and vegetation spectral coupling difference (SVSCD) for minerals extraction from hyperion data in vegetation covered area [J]. *Chinese*

- Geographical Science*, 2018, 28(6): 957–972.
- [15] Lei L, Feng J, Rivard B, et al. Mapping alteration using imagery from the Tiangong-1 hyperspectral spaceborne system: Example for the Jintanzi gold province, China [J]. *International Journal of Applied Earth Observation & Geoinformation*, 2017, 64: 31–41.
- [16] Lin Jian, Yan Baikun, Dong Xinfeng, et al. Evaluating of Tiangong-1 imaging spectrometer data oriented to geological applications [J]. *Journal of Remote Sensing*, 2014, 18(s1): 74–83. (in Chinese)
- [17] Elatawneh A, Kalaitzidis C, Petropoulos G P, et al. Evaluation of diverse classification approaches for land use/cover mapping in a Mediterranean region utilizing Hyperion data [J]. *International Journal of Digital Earth*, 2014, 7(3): 194–216.
- [18] Xing C, Ma L, Yang X Q. Stacked denoise autoencoder based feature extraction and classification for hyperspectral images [J]. *Journal of Sensors*, 2016, 2016: 3632943.
- [19] Li Zhuqiang, Zhu Ruifei, Gao Fang, et al. Hyperspectral remote sensing image classification based on three-dimensional convolution neural network combined with conditional random field optimization [J]. *Acta Optica Sinica*, 2018, 38(8): 404–413. (in Chinese)
- [20] Chen B, Huang B, Xu B. Multi-source remotely sensed data fusion for improving land cover classification [J]. *Isprs Journal of Photogrammetry and Remote Sensing*, 2017, 124: 27–39.
- [21] Chen Bin, Huang Bo, Xu Bing. Multi-source remotely sensed data fusion for improving land cover classification [J]. *Isprs Journal of Photogrammetry & Remote Sensing*, 2017, 124: 27–39.
- [22] Lu P, Wang L, Niu Z, et al. Prediction of soil properties using laboratory VIS–NIR spectroscopy and Hyperion imagery [J]. *Journal of Geochemical Exploration*, 2013, 132: 26–33.
- [23] Steinberg A, Chabrilat S, Stevens A, et al. Prediction of common surface soil properties based on Vis–NIR airborne and simulated EnMAP imaging spectroscopy data: prediction accuracy and influence of spatial resolution [J]. *Remote Sensing*, 2016, 8(8): 613.
- [24] Castaldi F, Palombo A, Santini F, et al. Evaluation of the potential of the current and forthcoming multispectral and hyperspectral imagers to estimate soil texture and organic carbon [J]. *Remote Sensing of Environment*, 2016, 179: 54–65.
- [25] Malec S, Rogge D, Heiden U, et al. Capability of spaceborne hyperspectral EnMAP mission for mapping fractional cover for soil erosion modeling [J]. *Remote Sensing*, 2015, 7(9): 11776–11800.
- [26] Liang Liang, Di Liping, Zhang Lianpeng, et al. Estimation of crop LAI using hyperspectral vegetation indices and a hybrid inversion method [J]. *Remote Sensing of Environment*, 2015, 165: 123–134.
- [27] Heiskanen J, Rautiainen M, Stenberg P, et al. Sensitivity of narrowband vegetation indices to boreal forest LAI, reflectance seasonality and species composition [J]. *Isprs Journal of Photogrammetry and Remote Sensing*, 2013, 78: 1–14.
- [28] Ali I, Greifeneder F, Stamenkovic J, et al. Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data [J]. *Remote Sensing*, 2015, 7(12): 16398–16421.
- [29] Kattenborn T, Maack J, Fassnacht F, et al. Mapping forest biomass from space – Fusion of hyperspectral EO1–hyperion data and Tandem–X and WorldView–2 canopy height models [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2015, 35: 359–367.
- [30] Marshall M, Thenkabail P. Advantage of hyperspectral EO–1 Hyperion over multispectral IKONOS, GeoEye–1, WorldView–2, Landsat ETM plus, and MODIS vegetation indices in crop biomass estimation [J]. *Isprs Journal of Photogrammetry and Remote Sensing*, 2015, 108: 205–218.
- [31] Xu Jin, Meng Jihua. Overview on estimating crop chlorophyll content with remote sensing [J]. *Remote Sensing Technology and Application*, 2016, 31(1): 74–85. (in Chinese)
- [32] Liang L, Qin Z H, Zhao S H, et al. Estimating crop chlorophyll content with hyperspectral vegetation indices and the hybrid inversion method [J]. *International Journal of Remote Sensing*, 2016, 37(13): 2923–2949.
- [33] Yang X G, Yu Y, Fan W Y. Chlorophyll content retrieval from hyperspectral remote sensing imagery [J]. *Environmental Monitoring and Assessment*, 2015, 187(7): 13.
- [34] Delloye C, Weiss M, Defourny P. Retrieval of the canopy chlorophyll content from Sentinel–2 spectral bands to estimate nitrogen uptake in intensive winter wheat cropping systems [J]. *Remote Sensing of Environment*, 2018, 216: 245–261.
- [35] Stagakis S, Markos N, Sykioti O, et al. Tracking seasonal changes of leaf and canopy light use efficiency in a *Phlomis fruticosa* Mediterranean ecosystem using field measurements and multi-angular satellite hyperspectral imagery [J]. *Isprs*

- Journal of Photogrammetry and Remote Sensing*, 2014, 97: 138–151.
- [36] Castaldi F, Castrignano A, Casa R. A data fusion and spatial data analysis approach for the estimation of wheat grain nitrogen uptake from satellite data [J]. *International Journal of Remote Sensing*, 2016, 37(18): 4317–4336.
- [37] Jia Kun, Li Qiangzi. Review of features selection in crop classification using remote sensing data [J]. *Resources Science*, 2013, 35(12): 2507–2516. (in Chinese)
- [38] Thenkabail P S, Mariotto I, Gumma M K, et al. Selection of hyperspectral narrowbands (HNBS) and composition of hyperspectral twoband vegetation indices (HVIs) for biophysical characterization and discrimination of crop types using field reflectance and Hyperion/EO-1 data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(2): 427–439.
- [39] Pan Z K, Huang J F, Wang F M. Multi range spectral feature fitting for hyperspectral imagery in extracting oilseed rape planting area [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2013, 25: 21–29.
- [40] Awad M M. Forest mapping: a comparison between hyperspectral and multispectral images and technologies [J]. *Journal of Forestry Research*, 2018, 29(5): 1395–1405.
- [41] Zhang Kang, Hei Baoqin, Zhou Zhuang, et al. CNN with coefficient of variation-based dimensionality reduction for hyperspectral remote sensing images classification [J]. *Journal of Remote Sensing*, 2018, 22(1): 87–96. (in Chinese)
- [42] Mariotto I, Thenkabail P S, Huete A, et al. Hyperspectral versus multispectral crop-productivity modeling and type discrimination for the HypsIRI mission [J]. *Remote Sensing of Environment*, 2013, 139: 291–305.
- [43] Zhang Q, Middleton E M, Cheng Y B, et al. Integrating chlorophyll fAPAR and nadir photochemical reflectance index from EO-1/Hyperion to predict cornfield daily gross primary production [J]. *Remote Sensing of Environment*, 2016, 186: 311–321.
- [44] Deng Shiquan, Tian Liqiao, Li Jian, et al. A novel chlorophyll-a inversion model in turbid water for GF-5 satellite hyperspectral sensor dir photochemical refle [J]. *Journal of Huazhong Normal University(Natural Sciences)*, 2018, 52(3): 409–415. (in Chinese)
- [45] Pan Banglong, Yi Weining, Wang Xianhua, et al. Geostatistics algorithm design on hyperspectral inversion of total phosphorus of lake [J]. *Infrared and Laser Engineering*, 2012, 41(5): 1255–1260. (in Chinese)
- [46] Giardino C, Brando V E, Dekker A G, et al. Assessment of water quality in Lake Garda (Italy) using Hyperion [J]. *Remote Sensing of Environment*, 2007, 109(2): 183–195.
- [47] Fang Xu, Duan Hongtao, Cao Zhigang, et al. Remote monitoring of cyanobacterial blooms using multi-source satellite data: A case of Yuqiao Reservoir, Tianjin [J]. *Journal of Lake Sciences*, 2018, 30(4): 967–978. (in Chinese)
- [48] Casey B. Water and bottom properties of a coastal environment derived from Hyperion data measured from the EO-1 spacecraft platform [J]. *Journal of Applied Remote Sensing*, 2007, 1(1): 011502.
- [49] Hu C, Feng L, Hardy R F, et al. Spectral and spatial requirements of remote measurements of pelagic Sargassum macroalgae [J]. *Remote Sensing of Environment*, 2015, 167: 229–246.
- [50] Bell T W, Cavanaugh K C, Siegel D A. Remote monitoring of giant kelp biomass and physiological condition: An evaluation of the potential for the Hyperspectral Infrared Imager (HyspIRI) mission [J]. *Remote Sensing of Environment*, 2015, 167: 218–228.
- [51] Han Y, Li J, Zhang Y, et al. Sea ice detection based on an improved similarity measurement method using hyperspectral data [J]. *Sensors*, 2017, 17(5): 1124.
- [52] Han Y, Li P, Zhang Y, et al. Combining active learning and transductive support vector machines for sea ice detection [J]. *Journal of Applied Remote Sensing*, 2018, 12(2): 026016.
- [53] Wang Dong, Gao Feng, Dong Junyu, et al. Sea ice classification from hyperspectral images based on self-paced boost learning [C]//Igarss 2018 –2018 IEEE International Geoscience and Remote Sensing Symposium, 2018: 7324–7327.
- [54] Petropoulos G P, Kalivas D P, Georgopoulou I A, et al. Urban vegetation cover extraction from hyperspectral imagery and geographic information system spatial analysis techniques: case of Athens, Greece [J]. *Journal of Applied Remote Sensing*, 2015, 9(1): 096088.
- [55] Okujeni A, Linden S V D, Hostert P. Extending the vegetation-impervious-soil model using simulated EnMAP data and machine learning [J]. *Remote Sensing of Environment*, 2015, 158(10): 69–80.
- [56] Li X K, Wu T X, Liu K, et al. Evaluation of the chinese fine spatial resolution hyperspectral satellite TianGong-1 in urban land-cover classification [J]. *Remote Sensing*, 2016, 8(5): 17.

- [57] Zhang X R, Sun Y J, Zhang J Y, et al. Hyperspectral unmixing via deep convolutional neural networks [J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15 (11): 1755–1759.
- [58] Tang F H, Xu Q. Impervious surface information extraction based on hyperspectral remote sensing imagery [J]. *Remote Sensing*, 2017, 9(6): 550.
- [59] Weng Q, Hu X, Lu D. Extracting impervious surfaces from medium spatial resolution multispectral and hyperspectral imagery: a comparison [J]. *International Journal of Remote Sensing*, 2008, 29(11): 3209–3232.
- [60] Jia G J, Burke I C, Goetz A F H, et al. Assessing spatial patterns of forest fuel using AVIRIS data [J]. *Remote Sensing of Environment*, 2006, 102(3–4): 318–327.
- [61] Yebra M, Quan X, Riano D, et al. A fuel moisture content and flammability monitoring methodology for continental Australia based on optical remote sensing[J].*Remote Sensing of Environment*, 2018, 212: 260–272.
- [62] Mallinis G, Galidaki G, Gitas I. A comparative analysis of EO–1 hyperion, quickbird and landsat TM imagery for fuel type mapping of a typical mediterranean landscape [J]. *Remote Sensing*, 2014, 6(2): 1684–1704.
- [63] Roberts D A, Dennison P E, Gardner M E, et al. Evaluation of the potential of hyperion for fire danger assessment by comparison to the airborne visible/infrared imaging spectrometer [J]. *Geoscience & Remote Sensing IEEE Transactions on*, 2015, 41(6): 1297–1310.
- [64] Numata I, Cochrane M A, Galvao L S. Analyzing the impacts of frequency and severity of forest fire on the recovery of disturbed forest using landsat time series and EO–1 hyperion in the southern brazilian amazon [J]. *Earth Interactions*, 2011, 15(13): 1–17.
- [65] Zhang C, Ye F W, He H X, et al. Study on the forest vegetation restoration monitoring using HJ–1A hyperspectral data [C]//35th International Symposium on Remote Sensing of Environment, 2014.
- [66] Abrams M, Pieri D, Realmuto V, et al. Using EO –1 Hyperion data as HyspIRI preparatory data sets for volcanology applied to Mt Etna, Italy [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(2): 375–385.
- [67] Amici S, Piscini A, Buongiorno M F, et al. Geological classification of Volcano Teide by hyperspectral and multispectral satellite data [J]. *International Journal of Remote Sensing*, 2013, 34(9–10): 3356–3375.
- [68] Davies G A, Chien S, Baker V, et al. Monitoring active volcanism with the Autonomous Sciencecraft Experiment on EO–1 [J]. *Remote Sensing of Environment*, 2006, 101(4): 427–446.
- [69] Stefanov W L, Evans C A. Data collection for disaster response from the international space station [C]//36th International Symposium on Remote Sensing of Environment, 2015: 851–855.
- [70] Crowley J K, Hubbard B E, Mars J C. Analysis of potential debris flow source areas on Mount Shasta, California, by using airborne and satellite remote sensing data [J]. *Remote Sensing of Environment*, 2003, 87(2–3): 345–358.
- [71] Savage S H, Levy T E, Jones I W. Prospects and problems in the use of hyperspectral imagery for archaeological remote sensing: a case study from the Faynan copper mining district, Jordan[J]. *Journal of Archaeological Science*, 2012, 39(2): 407–420.
- [72] Davies W H, North P R J. Synergistic angular and spectral estimation of aerosol properties using CHRIS/PROBA–1 and simulated Sentinel–3 data [J]. *Atmospheric Measurement Techniques*, 2015, 8(4): 1719–1731.
- [73] Koppe W, Gnyp M L, Hennig S D, et al. Multi-temporal hyperspectral and radar remote sensing for estimating winter wheat biomass in the North China Plain[J]. *Photogrammetrie Fernerkundung Geoinformation*, 2012, 3(3): 281–298.
- [74] Loizeau D, Mangold N, Poulet F, et al. History of the clay-rich unit at Mawrth Vallis, Mars: High-resolution mapping of a candidate landing site [J]. *Journal of Geophysical Research-Planets*, 2015, 120(11): 1820–1846.