

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2024)08-2089-24

论文引用格式: Cao L Q, Wang D, Xiong H Y and Zhong Y F. 2024. Review of information extraction methods from thermal infrared hyperspectral remote sensing images. Journal of Image and Graphics, 29(08):2089-2112(曹丽琴, 汪都, 熊海洋, 钟燕飞. 2024. 热红外高光谱遥感影像信息提取方法综述. 中国图象图形学报, 29(08):2089-2112)[DOI:10.11834/jig.230738]

热红外高光谱遥感影像信息提取方法综述

曹丽琴¹, 汪都², 熊海洋², 钟燕飞^{2*}

1. 武汉大学资源与环境学院, 武汉 430079; 2. 武汉大学测绘遥感信息工程国家重点实验室, 武汉 430079

摘要: 热红外高光谱遥感影像蕴含着丰富的光谱特性和温度信息, 能够反映出地物、气体等特有的诊断特征, 在矿物识别、环境监测和军事等众多领域发挥着重要作用。然而, 由于热红外高光谱观测数据受到地表温度和发射率、大气环境和仪器测量噪声等共同影响, 引起背景噪声与目标信号差异较小、耦合信号无法精确分离等问题, 使得热红外高光谱影像信息提取存在巨大的挑战, 难以有效实施应用。针对热红外高光谱信息提取的研究进展和现存难点, 本文系统梳理了热红外高光谱影像信息提取方法, 主要包括地表温度和发射率地表参量反演、热红外高光谱混合光谱分解、影像分类及目标探测。在此基础上, 总结现有热红外高光谱信息提取的现状和问题, 包括高光谱丰富光谱信息在地气参数反演方面尚未得到充分的利用, 基于深度学习理论实现热红外高光谱地表参量反演及混合像元分解、地物分类、目标探测应用仍处于起步阶段且面临数据集匮乏。如何充分利用热红外高光谱密集通道, 融合物理模型和深度学习理论实现智能化、高精度的地气参数一体化反演, 并在此基础上进行热红外高光谱混合像元分解、地物分类、目标探测是热红外高光谱遥感影像信息提取未来可能的发展趋势和研究方向。

关键词: 热红外高光谱; 地表参量反演; 混合光谱分解; 影像分类; 目标探测

Review of information extraction methods from thermal infrared hyperspectral remote sensing images

Cao Liqin¹, Wang Du², Xiong Haiyang², Zhong Yanfei^{2*}

1. School of Resource and Environmental Sciences, Wuhan University, Wuhan 430079, China; 2. State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan 430079, China

Abstract: Longwave infrared (LWIR) hyperspectral remote sensing images offer a wealth of spectral information alongside land surface temperature (LST) data, which make them invaluable for discerning solid-phase materials and gases. This capability holds significant implications across diverse domains, including mineral identification, environmental monitoring, and military applications. However, the underlying phenomenology and environmental interactions of emissive regions within the LWIR spectrum significantly diverge from those observed in reflective regions. This divergence impacts various facets of thermal infrared (IR) hyperspectral image (HSI) analysis, which span from sensor design considerations to data exploitation methodologies. Compounding this complexity are the intertwined influences of factors such as LST, emissivity, atmospheric profiles, and instrumental noise, which lead to challenges such as subtle distinctions between background noise and target signals, as well as inaccuracies in signal separation within thermal IR hyperspectral observation data. Consequently, the effective extraction of thermal IR HSI information poses formidable challenges for practical application

收稿日期: 2023-10-17; 修回日期: 2024-02-29; 预印本日期: 2024-03-07

* 通信作者: 钟燕飞 zhongyanfei@whu.edu.cn

基金项目: 国家重点研发计划资助(2022YFB3903300); 国家杰出青年科学基金项目(42325105)

Supported by: National Key R&D Program of China(2022YFB3903300); National Natural Science Foundation of China (42325105)

implementation. In this study, we systematically review methods for LWIR HSI information extraction by drawing upon ongoing research progress and addressing prevailing challenges in LWIR hyperspectral remote sensing. Our examination encompasses four primary areas: 1) LST and emissivity inversion: LWIR hyperspectral remote sensing serves as a potent tool for large-scale LST and land surface emissivity (LSE) monitoring. However, the accurate retrieval of LST and LSE is fraught with complexity owing to their intricate coupling with atmospheric components, as delineated by the radiative transfer equation. We discuss two broad approaches, namely, the two-step method and the integration method, for mitigating this ill-posed problem. The former entails atmospheric compensation (AC) and temperature and emissivity separation (TES), where AC filters out atmospheric influences to isolate ground-leaving radiance from at-sensor radiance. Subsequently, TES methods are employed to estimate LST and LSE. Given the propensity for inaccurate AC to introduce accumulation errors and compromise retrieval accuracy, integration methods capable of simultaneous AC and TES are also reviewed, with deep learning-driven methods exemplifying a typical integration approach. 2) LWIR hyperspectral mixed spectral decomposition: spectral mixture analysis (SMA) involves identifying and extracting endmember spectra in a scene to determine the abundance of each endmember within each pixel. Most applications of LWIR SMA focus on mineral detection and classification. Unlike the reflectance of a mixed pixel, which is defined as a linear combination within the pixel, the emissivity of a mixed pixel is not as straightforward to define because the measured radiance depends on the emissivity and temperature of each material. The mixed spectral decomposition methods for isothermal and non-isothermal pixels are discussed. When a pixel is isothermal, the isothermal mixture model is identical to the mixture for reflectance after removing the temperature component. However, as a pixel becomes non-isothermal, unmixing methods are necessary to handle the nonlinearity resulting from temperature variations. This study summarizes all the methods and highlights the challenges associated with SMA. 3) Classification: classification tasks in the LWIR domain involve successfully modeling and classifying background materials, such as minerals and vegetation mapping. However, the scarcity of prominent spectral features in the LWIR spectrum complicates the remote differentiation of natural land surfaces. For instance, various materials such as paints, water, soil, road surfaces, and vegetation exhibit spectral emissivities ranging between 0.8 and 0.95. Moreover, although spectral emissivity variations exist among different materials, they are less conspicuous compared with the reflective region. In addition, the uncertainty associated with retrieved emissivity challenges the classification of different materials. This study reviews traditional machine learning classification methods, including spectral-based, spatial-based, and spectral-spatial integration-based methods, alongside deep learning approaches, by summarizing the advancements in these processing methods. 4) Target detection: target detection encompasses solid- and gas-phase targets. The algorithms employed for LWIR HSI analysis, which is similar to those used for visible-near IR and shortwave IR HIS, have reached a mature stage and are reviewed in this work, including matched filter-type algorithms, among others. Challenges in target detection mirror those encountered in classification tasks, given that spectral emissivities in the LWIR tend to be smaller than the corresponding spectral reflectance variations observed in the reflective region. Consequently, the performance of solid-phase target detection algorithms in real-world applications is impacted, particularly by their sensitivity to target-background model mismatch arising from similar emissivities and other errors. By contrast, gas detection in the LWIR domain relies on selective absorption and emission phenomena, particularly by chemical vapors, which exhibit narrow spectral features. Although gas plumes may span a large number of pixels, their detection depends on factors such as concentration, signature strength, and temperature contrast with the background materials. Consequently, chemical detection applications necessitate rigorous physical processes in airborne (down-looking) and standoff (side-looking) configurations. In addition to employing strict physical and statistical models, gas detection methodologies are increasingly integrating deep learning models. This trend reflects the recognition of the potential of deep learning in enhancing the capabilities of gas detection algorithms. Our discourse concludes with a discussion on the future trajectory and research direction of extracting information from thermal IR hyperspectral remote sensing images. Despite the continual integration of new technical methodologies such as deep learning, the computational intricacies inherent in LWIR hyperspectral remote sensing underscore the necessity of approaches that combine physical mechanisms with machine learning models. These hybrid methodologies hold promise in addressing the multifaceted challenges associated with LWIR HSI analysis, which paves the way for enhanced information extraction and practical application implementations.

Key words: infrared hyperspectral; land surface parameter retrieval; spectral unmixing; classification; target detection

0 引言


近30年来,高光谱成像技术已经成为对地表进行遥感观测、建模和分析的重要手段。目前高光谱成像技术主要集中在 $0.35\ \mu\text{m}\sim 2.5\ \mu\text{m}$ 区间(Kim等,2005;张兵,2017;Veraverbeke等,2018),这个光谱区间的高光谱影像辐射信息主要是反射太阳光能,比较适合对物质电子跃迁层面产生的波谱特征进行探测和识别(Kim等,2005;Tong等,2014)。随着高光谱成像技术的发展,高光谱热红外成像传感器实现了在 $7.5\ \mu\text{m}\sim 14\ \mu\text{m}$ 的热红外波段进行高光谱成像,并用于对地物进行遥感观测(Kuenzer和Dech,2013;王建宇等,2015;吴骅等,2021)。相对于近红外及短波红外的反射波谱区间,热红外高光谱影像记录的是地物自身辐射信息,反映的是物质分子层面的结构和热运动信息,且具有昼夜成像的优势,使其在矿物识别、环境监测和军事等众多领域有着重要的应用(Hulley等,2016;Scafutto等,2018;Lu等,2015;Rankin等,2017)。

热红外高光谱传感器的不断出现,使得相应的热红外高光谱图像处理与信息提取方法也得到了不断的发展(Manolakis等,2019;Li等,2023c)。然而,受限于热红外高光谱采集过程中面阵红外焦平面、低温光学系统等硬件条件的限制,当前暂无星载成像热红外高光谱传感器和数据。机载高光谱热红外传感器能有效地突破这些限制,但由于成像过程的特殊性和复杂性,使得热红外高光谱影像处理技术存在诸多难点和问题。


1)耦合信号难以分离。热红外传感器接收的辐射能量来源于地物发射辐射、反射的大气下行辐射和大气上行辐射(路径辐射),地气参数之间具有高度的耦合性质,使得传感器获得的辐射亮度值无法准确区分地物信息,如图1(a)所示。通过地气参数的解耦(Li等,2023c)实现地表温度和发射率物理属性信息提取是分离耦合信号的关键。与可见光仅需反演反射率不同,热红外高光谱影像要同时反演地表温度和发射率连续波谱,是一个典型的欠定问题。然而,受限于大气补偿的精确性和解耦方法的复杂性,导致热红外高光谱耦合信号难以准确分离,这一不确定结果也为后续混合光谱分解、分类及目标探测带来了挑战(Manolakis等,2019)。

2)背景噪声和目标信号差异较小。首先,相对于可见光高光谱,热红外高光谱在探测器工艺层面更为复杂和特殊,包括其面阵红外焦平面、低温光学系统和精细分光等技术,使得信噪比难以媲美可见光高光谱器件(王建宇等,2015;李春来等,2022);其次,与反射率波谱不同,对于地表主要的覆盖物如水体、土壤和植被等,其发射率差异较小,发射率光谱数值范围大多在 $0.80\sim 0.95$ 之间(Truslow等,2016;Meerdink等,2019),且大部分光谱对比度不高,使得光谱区分度和差异变小,如图1(b)所示。例如,对于植被发射率光谱,由于受到木质素和纤维素的混合影响,加上冠层的散射作用,植被往往具有较高的发射率和较低的对比度,与类黑体近似;而对于土壤和岩石等,颗粒之间或者固态表面的凹坑或者颗粒尺度的粗糙度都会降低光谱的对比度。同时,这部分细微的对比度特征在大气补偿和参数反演过程中难以分离,叠加非同温像元的组分温度带来的误差,最终导致传统的高光谱遥感图像处理和信息提取方法及模型在热红外高光谱图像中的性能下降(Manolakis等,2019)。

针对以上难点,本文详细介绍并梳理了热红外



(a) 辐射度(Cao等, 2022)



(b) 发射率

图1 地物辐射亮度光谱和发射率光谱

Fig. 1 Spectral of radiance and emissivity

((a) radiance (Cao et al., 2022); (b) emissivity)

高光谱影像信息提取方法发展脉络和解决思路,如图2所示,包括热红外高光谱温度发射率反演、混合

光谱分解、影像场景分类及目标探测研究进展,并对今后的研究方向进行了展望。




图2 热红外高光谱遥感图像提取基本框架

Fig. 2 The general workflow of information extraction from thermal infrared hyperspectral remote sensing image

1 热红外高光谱温度发射率反演

热红外遥感是以地物自身的发射辐射光谱特征为主要分析对象,即主要反映地物的热量特征。一切大于绝对零度的物体,均具有对外产生热辐射的能力,因此相较于可见光遥感,热红外遥感不依赖太阳的反射能量,具有昼夜观测的能力。

根据普朗克方程和韦恩位移定律,热红外遥感具有对地球自然地表的热辐射能量的最佳探测能力。同时在热红外遥感常用的8~14 μm 光谱范围内具有相对连续且透明的大气窗口,因此地物的热红外辐射受到大气的干扰相对较小,能有更多能量穿透大气被热红外传感器接收。然而在实际应用中,为准确恢复地面热辐射信息,大气的影

性的热红外辐射传输方程可表示为

$$L_i = \varepsilon_i B(T) \tau_i + (1 - \varepsilon_i) L_{D_i} \tau_i + L_{U_i}$$
 (1)

式中, L_i 表示通道 i 上的入瞳辐亮度, ε_i 表示地表发射率, τ_i 表示大气透射率, L_{D_i} 和 L_{U_i} 分别表示大气下行辐射和上行辐射, $B(T)$ 表示在地表温度 T 下通过普朗克方程计算而来的黑体辐亮度。根据辐射传输方程可知, 传感器接收的地物辐射, 实际上包含了地表参量和大气参量两个部分。其中地表参量的温度和发射率之间的耦合, 会在不同地物的辐亮度波谱

之间产生异物同谱的现象, 即在热红外影像中常见的“鬼影效应”, 极大降低了地物间的光谱区分度, 模糊不同地物间的区分边界 (Bao 等, 2023)。而地气参量的耦合, 又会进一步对地物本征辐射波谱特征产生更大的干扰 (Manolakis 等, 2019)。因此, 为了增强热红外影像中的地物特征差异, 需要从原始的传感器入瞳辐射中提取出地物的本征属性信息, 即进行地表温度和地表发射率的反演。

表 1 汇总了目前主流的热红外高光谱地表温度

表 1 热红外高光谱地表温度和发射率反演方法汇总

Table 1 Temperature and emissivity retrieval methods for thermal infrared hyperspectral

类别	任务	方法	实验数据	精度
	大气 补偿	AAC (Gu 等, 2000)	SEBASS (Hackwell 等, 1996)	0.004 透射率误差; 0.05 W/sr/m ² /μm 上行辐射误差
		ISAC (Young 等, 2002)	SEBASS	0.02 透射率误差; 0.02 W/sr/m ² /μm 上行辐射误差
		SC (Jimenez-Munoz 和 Sobrino, 2010)	ASTER	2 K 地表温度误差
		CSAC (Acito 等, 2019)	TASI-600 (Pignatti 等, 2011)	3% 离地辐射波谱 rSE 误差
分步反 演法		ISSTES (Borel, 1997)	SEBASS	发射率 RMS 误差 0.082; 温度误差 0.021 K
		ASTER-TES (Gillespie 等, 1998)	TIMS (Palluconi 和 Meeks, 1985)	发射率误差 0.015; 温度误差 1.5 K
		ARTEMIS (Borel, 2008)	SEBASS	-
		SRTES (Cheng 等, 2010)	BOMEM (MR250 Serie)	发射率 RMSE 误差 0.01 ~ 0.02; 温度误差 0.04±0.04 K
	温度 发射 率分 离	LSEC (Wang 等, 2011)	BOMEM (MR250 Serie)	发射率误差优于 0.01; 温度误差优于 1 K
		WTES (Zhang 等, 2017)	BOMEM (MR250 Serie)	发射率 RMSE 误差优于 0.02; 温度误差优于 1 K
		MSWTES (Zhou 和 Cheng, 2018)	BOMEM (MR304 Serie)	发射率 RMSE 误差优于 0.01; 温度误差优于 0.05 K
		RDSS (Shao 等, 2020)	模拟数据	发射率 MAD 误差优于 0.31; 温度误差优于 0.75 K
		DSRE (Ma 等, 2023)	BOMEM (MR250 Serie)	发射率 RMSE 误差优于 0.024; 温度误差优于 0.81 K
一体化反演法		FLAASH-IR (Sundberg 等, 2015)	Hyper-Cam LW (Lagueux 等, 2009)	-
		TES-ISAC (Meerdink 等, 2019)	HyTES (Hook 等, 2013)	-
		ANN (Chen 等, 2018)	AIRS	发射率 RMSE 误差优于 0.011; 温度误差优于 0.643 K
		MDK-DL (Wang 等, 2021)	Gaofen MODIS Fengyun	温度误差优于 1 K
		LSTM-CNN (Ye 等, 2022)	TASI-600	发射率 RMSE 误差优于 0.012; 温度误差优于 0.95 K
		FebLihy-DNN (Ren 等, 2022)	TASI-600	发射率 RMSE 误差优于 0.015; 温度误差优于 0.86 K

注:“-”表示所引论文未提供相应数据。

与发射率反演方法及其对应的精度,主要包括分步反演法和一体化反演法。

1.1 分步反演法

分步反演法包括大气补偿和温度发射率分离两个相互独立的环节。大气补偿即从入瞳辐射中去除大气参量的干扰,恢复地表离地辐射信息,实现地气参数的解耦,可用辐射传输方程的变形表示为

$$L_i = \tau_i L_{g_i} + L_{U_i} \quad (2)$$

$$L_{g_i} = \varepsilon_i B(T) + (1 - \varepsilon_i) L_{D_i} \quad (3)$$

式中, L_{g_i} 为大气补偿后的地表离地辐射。从地表离地辐射的表达式中可知, N 个通道的离地辐射, 对应着 N 个通道的地表发射率和 1 个地表温度, 因此该表达式仍是一个不可解的欠定问题, 温度发射率分离法则是在大气补偿的地表离地辐射基础上, 通过减少未知数或增加方程个数的形式, 实现对地表温度和发射率的反演(吴骅等, 2021)。

1.1.1 大气补偿

大气补偿方法可分为基于影像自身的方法、基于经验统计的方法和基于大气模型的方法。其中基于影像自身的方法以 Young 等人(2002)提出的场景纠正法 ISAC (in-scene atmospheric compensation) 和 Gu 等人(2000)提出的自动大气补偿法 AAC (automatic atmospheric compensation) 为代表。ISAC 通过绘制场景内所有像元在各个通道内的入瞳辐射与有效亮温的散点分布图, 构建针对类黑体像元的线性拟合模型, 并以拟合模型的斜率为初始大气透射率, 截距为初始大气上行辐射, 借助 $11.7 \mu\text{m}$ 处的水汽特征对初始的大气透射率和上行辐射波谱进行缩放, 以作为该场景的大气补偿参数。ISAC 仅利用影像自身信息实现大气补偿, 但 O'Keefe 等人(2022)、Jr DiStasio 和 Resmini(2010)的研究实验也表明 ISAC 对场景内类黑体像元数量以及场景的空间范围存在较高要求, 同时该方法以通道亮温作为地表温度的估计容易引入误差, 而特殊的水汽特征缩放波段也难以适用于所有热红外高光谱成像仪(Vaughan 等, 2003; Pieper 等, 2023)。

基于经验统计的方法考虑到实时的大气温湿廓线难以获取, 而根据大气透射率、大气上下行辐射参数间的关联性进行参量求解。Jimenez-Munoz 和 Sobrino(2010)考虑利用近地表的大气水汽含量近似表达场景内的大气透射率, 并将近地表大气均温和

大气透过率相结合, 以近似表达场景内的大气上下行辐射, 实现对场景内像元的大气补偿。但该方法会直接获得地表温度的反演结果, 缺乏对大气参量的求解, 因此无法获得发射率波谱。Acito 等人(2019)提出的基于耦合子空间的大气补偿 CSAC (coupled subspace-based atmospheric compensation) 则利用机器学习方法, 考虑透射率与上行辐射间的相关性, 将大气参量的求解转化为在一个新的低秩空间的估算问题, 以非线性最小二乘估计实现了对大气参量的近似求解。

基于大气模型的方法是日前被广泛认可的主流大气补偿方法, 该方法通过搜集场景范围内的大气廓线信息, 包括温湿廓线、臭氧廓线、二氧化碳廓线等, 结合事先构建的大气参数查找表或大气辐射传输模型, 例如 MODTRAN (moderate resolution atmospheric transmission)、4A/OP (automatized atmospheric absorption atlas)、DART (discrete anisotropic radiative transfer) 等, 获得对应的大气补偿参量(Berk 等, 2014; Tellier 等, 2022; Gastellu-Etchegorry 等, 2015)。该方法的核心是根据相对成熟可靠的分层大气辐射传输模型, 以输入的大气廓线参数为基础模拟出现实观测场景的大气状况, 从而获得对应的大气补偿参数。该方法理论精度高, 但实测的探空廓线往往难以获取, 且同样面临时空一致性的挑战, 而不同再分析廓线的时空分辨率和大气垂直分辨率差异也更容易引入较大的大气补偿误差(Gao 等, 2022)。

1.1.2 温度发射率分离

精细发射率波谱是热红外高光谱相比于热红外多光谱的独特信息优势, 传统的发射率已知的温度发射率分离方法不能充分发挥热红外高光谱的通道优势, 因此温度发射率协同分离法是高光谱热红外的主要处理方式(Li 等, 2013)。为解决 N 个方程对应 $N+1$ 个未知数的欠定问题, 协同分离法以增加约束方程或减少未知数的形式, 实现温度发射率的解耦。

增加约束类型方法中的经验约束代表性方法有 Gillespie 等人(1998)针对 ASTER 热红外载荷提出的温度发射率分离法 ASTER-TES (ASTER temperature and emissivity separation), 该方法围绕发射率波谱最小值和整个发射率波谱的最大最小差值间的经验关系, 构建了从初始发射率波谱到反演发射率波谱的校正模型, 实现对温度的求解。光谱约束法以 Borel

(1997) 提出的迭代光谱平滑法 ISSTES (iterative spectrally smooth temperature-emissivity separation) 为代表, 该方法以地物发射率波谱是平滑的为额外的专家知识约束, 通过温度的迭代查找最平滑的发射率波谱, 作为最终的反演结果。根据光谱平滑的优化方向, Borel (2008) 又提出以辐亮度光谱平滑为约束的光谱平滑度自动检索法 ARTEMISS (automatic retrieval of temperature and emissivity using spectral smoothness)。Shao 等人 (2020) 针对热红外高光谱数据的高噪声高光谱特性, 提出了基于分辨率退化的光谱平滑法 RDSS (resolution-degrade-based spectral smoothness algorithm)。考虑到平滑类算法通常难以处理粗略的发射率特征, 而样条曲线则可以有效保留光谱中的粗略发射率特征, 因此 McElhinney 等人 (2022) 通过在模拟数据和 SEBASS (spatially enhanced broadband array spectrograph system) 真实数据的研究基础上, 建议直接使用样条曲线来拟合不同温度下的发射率反演波谱, 并以此进行发射率粗糙度的评估, 在保证温度精度的同时, 实现对光滑发射率波谱反演结果的优化。

减少未知数的代表方法有 Wang 等人 (2011) 提出的线性发射率光谱约束法 LSEC (linear spectral

emissivity constraint), 该方法在相邻通道发射率变化为线性的假设下, 通过分段线性回归, 重构出每段上的发射率值, 进而减少了发射率的未知数数量, 因此该方法能有效抑制反演发射率波谱奇异值的影响, 但分段区间的设置需要避开波谱的特征峰和特征谷, 不合理的区间分化不仅增大计算开销, 同时引入较大误差并抑制了地物的类间差异。Zhang 等人 (2017) 提出的小波变换温度发射率分离法 WTES (wavelet transform temperature-emissivity separation) 则基于小波变换理论, 将原始发射率波谱分解成低频小波系数, 以更少参数的发射率小波系数求解温度, 再通过小波系数重构恢复反射率波谱。

Gao 等人 (2022) 在真实获取的 Hyper-Cam LW 航空热红外高光谱数据基础上, 根据分步反演法开展了关于地表温度发射率反演制图的研究。如图 3 所示, 在机场区域的温度图反演结果表明, 在相同的基于大气模型 MODTRAN (Berk 等, 2014) 的大气补偿下, 由于实际获取的热红外高光谱的波段信噪比相较于模拟数据存在更强的热噪声, 因此基于经验关系方程的 ASTER-TES 相较于基于物理光谱约束数值解算的 LSEC (Wang 等, 2011) 具有更强的鲁棒性, 表现为温度图上的同温像元分布的类内一致性, 而表 2




图 3 航空热红外高光谱的 3 种温度图反演结果对比

Fig. 3 Three temperature retrievals comparison from airborne thermal infrared hyperspectral
((a) radiance map; (b) MODTRAN-based ASTER-TES; (c) MODTRAN-based LSEC; (d) FLAASH-IR)

的定量评价结果也表明 ASTER-TES 的反演温度也与实际地面测量温度最为接近。针对该 Hyper-Cam LW 传感器设计的 FLAASH-IR (Sundberg 等, 2015) 反演

方法受限于内置大气廓线库种类不足, 未能在温度图上表现出更好的反演效果, 相较于图 3(a) 的 ASTER-TES 显示有更多的噪声和温度的不确定性。

表 2 3 种反演算法的温度精度
Table 2 The temperature accuracy of three retrieval methods

测量样本	地面测量温度	MODTRAN-based ASTER-TES	MODTRAN-based LSEC	FLAASH-IR
石灰路	28.50	26.56	14.17	19.38
石板路	25.80	23.55	20.97	16.41
绿漆板	39.10	36.17	16.81	36.00
铝板	21.60	23.86	70.75	-3.06
水泥路	26.70	24.58	53.90	31.24
沥青路	33.10	30.46	13.71	65.26
黄草地	34.30	31.63	14.74	99.25

1.2 一体化反演法

由于分步反演在不同模块间的误差累积会对温度发射率反演产品产生较大的影响, 而大气补偿算法和温度发射率分离法各自的适用范围限制与假设条件, 在实际的应用环节也存在诸多难以适配问题 (Mushkin 等, 2020; Meerdink 等, 2019; Scafutto 等, 2021)。因此, 将大气和地表参数均作为未知数, 通过一体化的反演模型, 可实现对大气和地表参数进行同时求解。

传统的一体化反演方法通过对原始的辐射传输方程进行变形, 以获得简化表达的形式, 现阶段适用于热红外高光谱的传统一体化反演方法核心思想大多沿用热红外多光谱的思路。日夜双时相法通过结合额外的异温同谱双时相影像, 以丰富数据源的形式首先实现了多参量的一体化反演 (Wan 和 Li, 1997)。部分研究表明辐射传输方程中的大气下行辐射对发射率较高的自然地表的辐亮度光谱干扰较小, 因此后续有学者通过结合基于影像的大气补偿法, 并利用大气下行辐射查找表获得大气下行辐射参量, 最后通过温度发射率分离法实现地表参量反演, 该类型方法已应用于 HyTES (hyperspectral thermal emission spectrometer) 和 Hyper-Cam LW 热红外高光谱成像仪的数据处理 (Meerdink 等, 2019; Sundberg 等, 2015)。但传统的一体化反演方法缺乏对大气参量和地表参量的协同优化, 仅是初步实现了无需大气廓线和地表类型先验知识的自动化反演

过程, 因此分步反演法中的误差累积效应依然存在。

随着深度学习技术的发展, 部分学者指出可利用深度学习强大的非线性拟合能力, 直接从入瞳辐亮度求解出整个大气参量和地表参量, 避免对辐射传输方程的反复调用, 同时实现对大气参量和地表参量的协调优化求解。Chen 等人 (2018) 通过引入人工神经网络 (artificial neural network, ANN), 在热红外超光谱 AIRS (atmospheric infrared sounder) 数据上实现了大气参量和地表参量的同时反演, 其结果也表明该方法可为后续更为准确的物理反演法提供计算初值。Wang 等人 (2021) 通过深度学习网络, 在物理和专家知识的约束下, 实现了在星载热红外多光谱的端到端高精度地表温度反演, 并详细讨论了深度学习在热红外参量定量反演中的应用可行性。Ye 等人 (2022) 通过引入自然语言处理过程中的循环卷积网络, 将高光谱的光谱维视为时间序列, 利用长短期记忆和卷积神经融合的网络 LSTM-CNN (long short-term memory network and convolutional neural network), 实现了大气参量和地表参量的同时反演。Ren 等人 (2022) 提出了一种基于深度学习网络的特征通道线性格式混合算法 FebLiHy-DNN (feature-band linear-format hybrid algorithm combining deep neural network), 该方法将原始辐射传输方程转为线性关系并仅选择了部分通道信息以减少未知数, 通过 DNN 网络获得地表和大气参量的初始值, 最后在物理模型的约束下获得最优的反演结果。

2 热红外高光谱混合光谱分解

当热红外高光谱影像中的一个地表像元包括若干种组分地物时,其表观辐射光谱表现为这些纯净地物辐射光谱的混合,纯净组分地物的辐射光谱通常称之为端元光谱(Manolakis等,2019)。混合像元光谱分解(spectral mixture analysis, SMA)可确定每一个混合像元的光谱端元和组分含量,实现对亚像元尺度的纯净地物光谱和其组分含量的信息提取,其结果可有效地应用于目标探测、分类识别等任务。面向可见光高光谱混合像元光谱分解技术已得到长足的发展(冯如意等,2023)。其中,基于物理模型的光谱解混框架已被广泛引入至热红外高光谱混合像元分解。然而,与可见光高光谱不同,由于热红外辐射信息耦合了地表温度、发射率和大气信息,使得基于反射率光谱特性的解混模型无法直接应用于热红外高光谱数据,大气不确定性也为热红外高光谱数据的解混增加了挑战。

对于热红外高光谱数据,传感器在大气端所观测到的辐射是由几种不同组分构成的综合辐射,扣除上行辐射,地表混合像元辐射亮度是各像元组分辐射亮度之和,每一组分的辐射亮度由反射辐射亮度和发射辐射亮度组成,如图4所示,实线为反射辐射亮度,虚线为发射率辐射亮度,其关系为

$$L_{\text{mix}}(\lambda_k) = \sum_{i=1}^N \alpha_i L_i(\lambda_k) \quad (4)$$

$$\sum_{i=1}^N \alpha_i = 1, 0 \leq \alpha_i \leq 1 \quad (5)$$

$$L_i(\lambda_k) = \varepsilon_i(\lambda_k) B(\lambda_k; T_i) + [1 - \varepsilon_i(\lambda_k)] L_d(\lambda_k) \quad (6)$$

式中,地表辐射混合像元表观辐射强度记为 $L_{\text{mix}}(\lambda_k)$,端元 i 的辐射强度为 $L_i(\lambda_k)$,其丰度为 α_i ,其温度为 T_i , L_d 为下行辐射强度。

从式(4)中可明显看出,混合像元辐射强度大小取决于端元温度、发射率及端元含量(丰度)。而温度 T_i 独立于地物的发射率与丰度信息,也就是说精确的端元温度估算是热红外高光谱混合像元分解的关键。

2.1 同温混合像元分解

同温混合像元分解假设陆地表面物质均一,混合像元中各地物组分温度相同,式(6)的地表混合像




图4 热红外高光谱遥感地表混合像元

Fig. 4 Mixed pixel of thermal infrared hyperspectral remote sensing

元辐射强度可表示为

$$L_{\text{mix}}(\lambda_k) = \varepsilon_{\text{mix}}(\lambda_k) B(\lambda_k; T_c) + [1 - \varepsilon_{\text{mix}}(\lambda_k)] L_d(\lambda_k) \quad (7)$$

$$\varepsilon_{\text{mix}}(\lambda_k) = \sum_{i=1}^N \alpha_i \varepsilon_i(\lambda_k) \quad (8)$$

通过地表温度和发射率反演模型可直接反演同温混合像元温度 T_c 和发射率 ε_{mix} 。扣除地表温度的影响,基于反射率光谱特性的混合像元分解模型可直接用于发射率光谱混合像元分解,通过最小化发射率误差估算端元及端元丰度。典型的如全限制性混合像元分解模型(fully constrained linear squares unmixing, FCLSU)。混合像元发射率与估算端元线性混合发射率的均方根误差为

$$E_e = \sqrt{\frac{1}{K} \sum_{k=1}^K \left(\varepsilon_{\text{mix}}(\lambda_k) - \sum_{i=1}^N \alpha_i \varepsilon_i(\lambda_k) \right)^2} \quad (9)$$

式中, $\varepsilon_{\text{mix}}(\lambda_k)$ 为混合像元在 λ_k 通道的发射率值, K 为通道数, $\varepsilon_i(\lambda_k)$ 为第 i 个端元在 λ_k 通道发射率值, α_i 为第 i 个端元的丰度。

热红外高光谱线性混合像元分解较多应用于矿物填图和目标探测中(Clare, 2006; Vaughan等, 2003)。与近红外中矿物散射和吸收能量使得混合矿物呈现非线性混合关系不同,在长波红外范围内,当矿物粒径大于 $60 \mu\text{m}$ 时,能量散射影响较小,线性混合模型更适用于混合像元分解(Ramsey和Christensen, 1998; Manolakis等, 2019)。Christensen等人(2000)最早利用热红外发射光谱仪(thermal emission spectrometer, TES)进行火星地表成分分析,结合已知矿物光谱库,确定端元光谱,采用线性混合像元分解方法结合最小二乘法求解,实现火星表面矿物填图,这类方法在后续的火星矿物制图中得到了广泛应用。Aslett等人(2018)基于SEBASS热红外高光谱数据,先采用PPI(pure pixel index)方法实

现了29个端元光谱提取,并在此基础上完成了对美国加利福尼亚死亡谷国家公园断层的硅酸盐、碳酸盐基沉积岩、变质沉积岩等矿物混合物的填图。Chen等人(2021)基于混合发射率特性,在确定裸沙、土壤和旱地植被(干枯植被)端元发射率波谱的前提下,利用线性混合模型和最小二乘法进行混合像元分解,并基于分解结果对过渡地带沙土化土地进行了精细监测,实现了2000年—2016年中国沙地的空间分布和动态变化监测。然而,以上方法需要事先已知地表温度和精确端元光谱,针对这一问题,Hamilton(2000)提出利用线性反卷积最小二乘拟合的方法,通过多次迭代并筛选光谱库子集作为纯净端元,拟合与矿石相近最佳光谱组合并确定组合端元的百分比含量,以估算镁铁矿的端元物质及其含量。相较于确定端元数量和发射率光谱带来的丰度估算误差,Goudge等人(2015)提出采用迭代拟合模型,该模型通过在光谱库中随机抽样端元数和端元光谱实现混合像元分解,提升制图精度,并用于确定火星喀什拉陨石坑中存在斜长石和易变辉石等岩相。

然而,受到大气水汽等因子的影响,基于事先大气补偿的混合像元分解结果往往受限于大气补偿精度。为了消除制图过程中大气补偿误差的影响,Ramsey和Christensen(1998)提出将大气辐射和黑体辐射的贡献归一化并作为实测发射率光谱的一部分,利用反卷积的最小二乘拟合方法,同时估算大气参数和像元丰度,该方法成功应用于全火星的矿物分布制图(Bandfield, 2002; Christensen等, 2000; Smith等, 2000)。此外,也有学者基于辐射域模型式(4),在假设像元同温情况下,利用Nelder-Meade数值优化方法结合FCLS和贝叶斯理论同时实现温度、大气廓线以及矿物丰度的估算,并在模拟数据上进行了实验验证(Zelinski, 2018, 2020)。

2.2 非同温混合像元分解

事实上,由于陆地表面不均一,在遥感像元尺度上,像元内部非同温混合像元是一个普遍的自然现象。受到端元温度的影响,热红外高光谱混合像元分解需要在估算端元光谱和丰度的同时估算端元温度,其物理模型可定义为

$$E_L = \sqrt{\frac{1}{K} \sum_{k=1}^K (L_g(\lambda_k) - L_{\text{mix}}(\lambda_k))^2} \quad (10)$$

式中, $L_g(\lambda_k)$ 为离地辐射。利用穷举策略通过在发射率光谱库和一定温度区间范围进行搜索,结合全限制性混合像元分解FCLS方法可实现非同温混合像元分解。但这类方法效率低下,需要完备的发射率光谱库信息。为了提高效率,可通过有效的假设以减少搜索范围,同时利用增加对错误端元搜索惩罚的机制避免模型出现过拟合。

基于这一思路,Cubero-Castan等人(2015)提出一种热红外遥感影像亚像元温度解混模型(thermal remote sensing unmixing for subpixel temperature, THRUST),在大气补偿前提下,事先估计各种成分地物的平均温度作为初始输入,利用可见光高光谱通过地表分类结果确定纯净端元及端元数量,依据泰勒展开将普朗克方程转变为线性方程,采用最佳线性无偏估计(best linear unbiased estimator, BLUE)将温度用丰度来表示,以估算离地辐射和实测离地辐射之间误差均方根最小为目标进行最小二乘估计,从而在反演丰度的同时获取温度信息,这一方法在模拟数据和TASI影像上开展了初步的实验和分析。随后,为了提升亚像元分解模型在多光谱热红外数据中的应用能力,Granero-Belinchon等人(2020)对TRUST方法进行了改进,融合白天和夜晚的热红外数据构建白天—夜间热红外遥感影像亚像元温度解混模型(TRUST day and night synergy, TRUST-DNS),将TRUST模型分别用于白天和夜间红外影像,并利用白天和夜间离地辐射和实测离地辐射之间误差均方根之和最小为目标进行最小二乘估计。这一方法在AHS(airborne hyperspectral scanner)多光谱影像上进行了实验和分析,取得了相对TRUST更优的结果。Rankin等人(2017)将非同温混合像元分解技术应用到亚像元目标检测中,提出了一种结合光谱辐射建模与贝叶斯模型平均的亚像元识别算法,针对亚像元目标,假设场景中背景足够均匀,将背景平均辐射强度用于混合像元背景建模,以减少模型未知数个数,实现亚像元目标温度和丰度的同时求解。Liu等人(2016)结合可见光高光谱和热红外高光谱,利用可见光确定可能的纯净端元,并将其输入辐射域线性混合模型,确定端元丰度,利用丰度实现亚像元温度估算。Miao等人(2017)通过地表分类方式先计算纯净像元和地表温度,并将纯净像元地表温度作为混合像元各组分初始温度,

利用线性混合像元模型通过优化算法实现组分温度和丰度的同时求解。

与同温混合像元分解一样,大气补偿误差往往直接影响非同温混合像元分解精度。然而,由于大气传输复杂性以及非同温像元的不确定性,非线性模型中非同温像元温度、发射率和大气参数的耦合增加了问题求解的维度和复杂性,同时解耦大气参数、非同温像元目标温度、混合像元光谱和丰度目前正处于起步阶段,已有的算法也相对较少。

3 热红外高光谱影像场景分类

基于热红外高光谱影像场景分类方法,可实现对地物地理空间分布及变化特征信息的全天时提

取。由于现有热红外高光谱成像仪均搭载于航空平台,使其通常具有高空间分辨率和高光谱分辨率的“双高”优势,因此基于热红外高光谱影像的场景分类方法与传统可见光高光谱分类方法具有相似的方法体系。然而,受限於热红外光谱中地气参量耦合造成的地物间低可分性和光谱成像过程中较低的信噪比的影响,传统分类方法容易在分类结果中产生大量孤立像元的错分情况,因此如何综合利用场景内的长距离语义信息、光谱信息和温度信息,是实现有效热红外高光谱分类方法的难点和重点。图5为热红外高光谱影像的分类技术发展时间索引图,具体可分为基于光谱的方法、基于空间的方法和基于空间光谱相融合的方法(Li等, 2023a)。




图5 热红外高光谱影像不同分类方法的发展

Fig. 5 The development of different classification methods for thermal infrared hyperspectral image

3.1 基于光谱的分类方法

基于光谱的分类方法是仅考虑不同地物光谱曲线间的相似与差异度,作为分类的评判标准,因此基于光谱的分类方法又可细分为基于光谱差异的方法和基于光谱特征提取的方法。其中基于光谱差异的方法通过将地物光谱与光谱库中的标准光谱进行相似度对比,以相似度的计算结果作为分类的依据。例如光谱相似法(spectral correlation mapper, SCM)(de Carvalho 和 Meneses, 2000)通过评估目标地物发射率波谱与光谱库中标准波谱间的差异,从而对地物像元进行类别划分。光谱信息分解法(spectral information divergence, SID)(Chang, 2000)则是从光谱信息度差异的角度,通过计算光谱曲线间的KL(Kullback-Leibler)散度或其他散度模型来衡量光谱

间的差异,并以信息散度最小的类别作为目标像元的分类类别。基于光谱特征提取的方法往往通过数据降维与变换,将地物光谱中具有决定性特征的信息保留下来作为分类参考依据。基于光谱特征的方法的思想是将原始光谱数据投影到一个新的特征空间当中,并在新的特征空间中保留其识别信息,实际表现为特征提取过程。典型的特征提取算法包含主成分分析法(principle component analysis, PCA)、独立成分分析法(independent component analysis, ICA)、线性判别分析法(linear discriminant analysis, LDA)等(Rodarmel 和 Shan, 2002; Bandos 等, 2009; Villa 等, 2011)。因此,该类方法通常需要分类场景中的地物在热红外区间内具有较显著的发射率或辐射亮度光谱差异特征。

然而在实际应用中,上述基于光谱的分类方法往往受限于发射率反演噪声的误差约束,最终表现为分类结果中的椒盐噪声(Barisione等,2016)。光谱特征提取又势必会造成细节信息的丢失,而高光谱带来的维度灾难同样也会使提取过程变得更为复杂。基于此,Meerdink等人(2019)利用随机森林分类器开展了林地植被分类的研究,利用热红外的温度信息以提高冠层尺度的植被分类效果。因此,结合热红外光谱和温度特征是提升分类精度的重要方向。

3.2 基于空间的分类方法

基于空间的遥感影像分类方法旨在利用图像中像元之间的空间关系来提高分类性能。这些方法通常考虑像元的邻近性、纹理和结构等信息进行分类(Zhang等,2012)。对于热红外高光谱影像,地物分布的空间信息主要以热源的形式予以体现,由于不同地物的比热容存在差异,因此不同地物在相同环境下与外界的能量交换幅度也不同,而相似的地物会表现出更为类似的温度及纹理信号。纹理特征主要可表征像元周围的空间变化模式,常见的纹理特征包括灰度共生矩阵特征(gray-level co-occurrence matrix, GLCM)、局部二值模式特征(local binary pattern, LBP)、Gabor滤波器特征等,利用该类特征可实现对地物的分类(Fauvel等,2008)。空间滤波方法通过将滤波器应用于遥感图像,以强调或减弱像元间的空间变化,从而提取空间分布的结构信息。数学中的形态学也被应用于遥感影像的结构特征提取,形态学轮廓特征(morphological profiles, MP)也在Benediktsson等人(2005)的研究中被有效应用于高光谱影像分类任务。基于空间的方法通过提取影像中地物分布的空间信息,在地理学邻近理论的支撑下实现对像元的分类,但考虑到热红外高光谱在不同波段上的亮度温度图也存在差异,因此根据分类任务的不同,在最具可分性的亮度温度图上进行分类反而会优于在反演的热力学温度图的分类效果。然而,基于空间的方法大多沿用自然图像中的影像分割类技术,没有利用地物的光谱指纹信息,同时自然场景中不同地物表现的热辐射信息差异较小,影像中的纹理信息较弱(Bao等,2023),使得该类方法难以有效区分复杂的地物类别边界,导致分类精度较差。

3.3 基于空间和光谱相结合的分类方法

受温度和发射率反演结果不确定的限制和热红

外高光谱影像本身噪音的影响,空谱结合分类法通过将目标像元与其邻近像元的空间和光谱特征融合到同一特征空间下进行分类判断,以增强分类过程的鲁棒性(赵永强等,2023)。但受限于热红外高光谱影像质量的不确定性干扰,传统的诸如混合核模型CKs(Camps-Valls等,2006)、马尔可夫随机场(Markov random field, MRF)(Tarabalka等,2010)仅利用了影像光谱和空间维度的浅层特征信息,在分类过程中也需要部分专家知识进行引导,因此在热红外高光谱较强的类内异质性的复杂场景分类任务中性能提升有限,而低级的手工特征在不同场景中的分类鲁棒性较弱。

现阶段,具有更强噪声抑制能力和深层特征学习能力的深度学习分类方法已逐步应用于热红外高光谱影像中。Westing等人(2019)首次提出基于光谱维度的1D-CNN(1 dimensional convolutional neural network)的热红外高光谱地表分类方法,对比支持向量机(support vector machine, SVM)和ANN方法,实验结果显示,3类方法的总体精度均大于90%,而深度学习精度更优。除此之外,基于空间区块的方法利用2D CNN或3D CNN可有效实现空谱特征的融合提取,同时条件随机场等后处理方法可消除分类结果中的错分区域,以提升分类精度(Liu等,2021;Zhong等,2020)。同时,通过对光谱和空间特征的单独提取,基于双分支融合网络进行整合是另一种基于空谱特征分类的方式(钟燕飞等,2023)。但该类方法的性能受到最优空间块尺寸设定的影响,不同的尺寸决定着中心像元与周围像元语义信息的关联,而热红外高光谱影像通常具有更低的信噪比,因此仅针对局部像元的分类容易产生孤立的错分区域。针对这一问题,有学者提出无需空间区块的全局影像分类方法,通过直接将全局影像作为模型的输入,提出了快速全卷积深度网络实时分类框架FPGA(fast patch-free global learning),极大提高了特征提取效率和精度(Zheng等,2020)。对于长距离的空谱关系,可利用深层残差网络空洞卷积空间金字塔池化ASPP(atrous spatial pyramid pooling)提取影像中的深层语义特征,极大缓解了影像中空间异质性和分类结果中的孤立点(Hu等,2022)。以上方法初始设计仅针对可见光高光谱影像,并未充分考虑热红外高光谱地表温度特性。Cao等人(2022)利用热红外高光谱图像反演的发射率谱和地

表温度,提出了一种基于温度—发射率残差网络和条件随机场的分类模型(temperature-emissivity residual network and conditional random field model, TERN-CRF),在该方法中,残差网络被设计用于提取和融合深入的光谱和局部空间特征,条件随机场通过使用温度信息并结合空间上下文信息,以改善分类结果

图中的空洞和孤立区域问题。如图6所示,该方法在Hyper-Cam LW 航空数据上表现出了优于传统空谱融合法的分类性能,表现为更强的分类类内一致性。表3的定量评价结果表明,除CNN外,典型的空谱结合深度学习方法的分类准确率均高于90%,表明了深度学习算法在复杂场景中提取深度特征的能力。




图6 热红外高光谱影像分类结果

Fig. 6 Classification results for thermal infrared hyperspectral classification methods

表3 分类算法精度统计表

Table 3 Classification results of different methods

方法	OA/%	AA/%	Kappa	建筑/%	道路/%	沙地/%	水体/%	植被/%	裸地/%
SVM	82.17	80.36	0.74	87.70	80.67	94.45	94.56	64.30	60.50
SVM-CRF	84.66	83.25	0.78	97.54	87.18	97.65	97.25	39.38	80.50
FNEA-OO	86.56	82.22	0.80	89.34	88.09	96.83	91.50	65.83	61.75
Hybrid-SN	90.80	89.23	0.86	94.26	90.00	98.33	98.60	80.57	73.63
AF_3D CNN	90.67	90.11	0.86	98.36	89.05	99.28	98.49	82.24	73.25
CNN	89.06	86.19	0.84	98.36	89.41	98.68	97.77	73.04	59.88
CNN-CRF	91.72	89.65	0.88	98.36	91.27	99.37	98.60	82.94	67.38
TERN	93.95	89.58	0.91	98.36	95.55	99.50	99.90	83.31	60.88
TERN-CRF	94.42	89.59	0.92	96.72	95.99	99.42	99.95	86.19	59.25

4 热红外高光谱影像目标探测

在广义的计算机视觉领域,目标探测要从影像

中提取的关键信息是感兴趣对象的边界框和类别信息(Carion 等,2020)。热红外高光谱遥感影像目标探测是其中一个特殊分支,由于长波热红外辐射受到地气因素的耦合影响(见图1),获得精确的地表

发射率特性成为热红外高光谱遥感影像目标探测的重要前提。此外,与可见光波段范围不同,在长波热红外波段,自然地物的发射率对比度差异更小,使得目标的弱特征问题成为热红外高光谱遥感影像目标探测的另一个难点。依据被探测目标的物态可以从固态目标探测和气态目标探测两个方面来对热红外高光谱遥感影像目标探测作进一步阐述。

4.1 固态目标探测方法

现有的针对热红外高光谱影像目标探测方法主要分为发射率域算法和辐射域算法。通过反演发射率数据再进行目标探测的方法称为发射率域目标探测方法,而直接输入辐亮度或者亮温数据来探测固体目标的方法称为辐射域目标探测方法。

发射率域算法首先需要解决的问题在于发射率的反演。具体反演的方法主要见第1节,在发射率反演基础上,采用通用的统计方法如SAM(spectral angle mapper)(Manolakis, 2005), ACE(adaptive coherence estimator)(Kraut 和 Scharf, 1999), ASD(adaptive subspace detectors)(Kraut 等, 2001)等。这类方法以广义似然比假设检验 GLRT(generalized likelihood ratio test)为基础,设测量所得发射率数据为 x , 目标物的发射率特征为 s , 背景等其他物体的发射率特征为 v , 则假设检验可表示为

$$H_0: x = as + v \quad (11)$$

$$H_1: x = v \quad (12)$$

式中,备择假设 H_0 为目标存在,原假设 H_1 为目标不存在,常数 a 为系数,通过计算假设 H_0 成立的显著性来判断目标物是否出现在对应像素位置。在该类方法的实际应用过程中,检测阈值的选择会对探测精度产生较大的影响,因此还需要进一步研究予以确定。若目标物的发射率特征 s 未知,则已知目标探测问题转化为异常目标探测问题。

异常目标探测算法在可见光高光谱遥感领域已有较为完备的方法,并且可以迁移到热红外高光谱领域,如 RXD(reed-X detector)方法(Reed 和 Yu, 1990),后续为了解决复杂背景造成的背景平均光谱向量估计不准确问题,分块 RX 探测器 SegRX(the segmented RX detector)被提出(Matteoli 等, 2010), SegRX 通过将背景分成多个小的同质区域来降低背景的复杂度。为了进一步抑制噪声也即去除高响应值,基于鲁棒性主成分分析的异常探测 LSMAD(low-rank and sparse matrix decomposition based Mahalano-

bis distance method for anomaly detection)方法(Zhang, 2015)直接对原始全局数据矩阵施加低秩稀疏约束,获取了更加准确的背景信息。为了解决影像的背景复杂导致背景估计不准确问题,同时避免复杂的字典构造,Wang 等人(2020)提出了基于局部增强的低秩先验的异常探测方法(the locally enhanced low-rank prior method for anomaly detection, LELRP-AD)。以上方法在可见光谱范围内表现良好,但是在长波热红外波段由于前文中提到的低发射率差异问题而实际应用效果受限。针对此问题,一种联合发射率和低秩分割的异常目标探测方法 EaSLRP(emissivity and segmented low-rank prior)被应用于 Hyper-Cam 热红外高光谱影像数据(朱绪鹤, 2021)。该方法首先利用温度发射率分离得到温度影像并进行区域分割,然后采用协同表示(collaborative representation, CR)和稀疏表示(sparse representation, SR)的原理,该方法融合发射率影像构建局部增强的背景稀疏矩阵,得到低秩背景信息,最后采用马氏距离探测器对异常与背景进行分离。图7为 EaSLRP 方法与主流异常目标探测方法的目标探测结果对比,联合发射率与低秩分割使得异常目标探测及背景噪声抑制效果更佳。图8为6种热红外高光谱异常目标探测方法对比。

辐射域算法避开了发射率反演环节,以避免发射率误差在目标探测过程中的误差传递。这类算法中热红外高光谱辐亮度数据无需进行大气补偿和温度发射率分离预处理,而是将大气参数、地表温度等参量构建到求解模型当中,实现一体化的目标探测。例如, JSD(joint subspace detection)联合子空间高光谱目标探测算法无需目标的温度与发射率特征信息(Schaum, 2004),而是提前对高维空间中数据的分布进行测试,通过贝叶斯重构将高光谱数据分布的经验融入 GLRT 当中,将决策面从原来的球形面拓展到与数据分布更加匹配的双曲决策面,从而在无需获取温度发射率信息前提下逐像元地探测出目标。另外,利用高光谱解混思路将探测目标特征作为热红外辐射传输方程中的一个端元,为辐射域目标探测算法提供了思路(Thai 和 Healey, 2002)。例如,基于线性像元混合模型进行多变量优化,并且使用贝叶斯模型求均方法来进行模型选择,从而实现了目标的丰度与温度联合估计(Rankin 等, 2017),该方法作为一种用于固体材料的新型长波热红外高光




图7 6种热红外高光谱异常目标探测结果

Fig. 7 Results of six thermal infrared hyperspectral anomaly target detection methods

((a) radiance image; (b) ground truth; (c) RXD; (d) SegRX; (e) LRASR; (f) LSMAD; (g) LELRP-AD; (h) EaSLRP)




图8 6种热红外高光谱异常目标探测方法对比

Fig. 8 Comparison of six thermal infrared hyperspectral anomaly target detection methods

谱遥感影像目标探测方法取得了更优的探测精度。除了高光谱解混思路,监督学习方法在训练样本充足的条件下可以直接建立辐射域数据与目标种类之间的映射关系,从而完成目标探测。SIMCA (soft independent modelling of class analogy) 监督分类方法可以对红外高光谱成像仪拍摄沙子样本数据进行目标探测 (Vidal 和 Pasquini, 2021), 研究者通过检测沙子样本中是否出现微塑料成分, 从而为海滩环境保护提供支撑; 生成对抗网络 (generative adversarial network, GAN) 被 Campos 等人 (2023) 应用于基于红外高光谱成像的禽肉异物识别当中, 这种半监督的深度学习方法在数据驱动条件下取得了 96.8% 的 F1 评分。

4.2 气体目标探测方法

将热红外高光谱遥感影像目标探测应用于气体

目标遵循与固体目标探测类似的思路。气体的吸收特征曲线满足特定规律, 即 Beer-Lambert 定律, 可表示为

$$e_g = 1 - e^{-\alpha \times CL} \tag{13}$$

式中, α 为气体的吸收度 (单位是 cm^{-1} 或 $\text{cm}^2/\text{mol}\cdot\text{molecule}$), C 为气体吸收系数, 由气体本身物化属性和环境因素共同决定, L 为光学路径上的气体分布长度, CL 则是气体的柱浓度 (浓度沿成像方向的线积分)。

在热红外光谱区间内, 气体往往具有明显的光谱吸收特征, 因此根据气体的特征吸收光谱可实现异常气体的有效探测和识别, 图 9 为一氧化碳、甲烷、一氧化氮、二氧化硫和氨气的气体吸收率谱。因此, 热红外高光谱遥感通过获取气体吸收特征可为远距离气体目标的泄漏范围、种类、浓度等信息精确测量提供可能。同时, 高空间分辨率热红外影像可




图9 5种典型气体的光谱吸收率

Fig. 9 The absorbance of five typical gases

以通过几何形态和浓度信息来判断排放气体随时间变化情况(Gälfalk 等,2016)。然而,与固态目标探测不同,基于热红外高光谱的气体探测具有其独特的特点,例如气体目标在对应像元处往往是由大气辐射、背景辐射和气体辐射组成的非纯净像元,并且由于气体的吸收率特征往往小于固体的发射率特征,这种更加微弱的光谱异常特征为气体目标探测带来更大的挑战。

基于统计信息的热红外高光谱固态目标探测方法 GLRT 仍然适用于气体目标的探测,该类方法主要是衡量检测像元与气体目标特征曲线的相似性,选择相关性度量值高的像元作为探测结果。目前的 GLRT 检测算子包括匹配滤波检测法(adaptive matched filter, AMF)(DiPietro 等,2012)、杂波匹配滤波检测法(clutter matched filter, CMF)(Farley 等,2007)以及自适应相关估计检测法(adaptive coherence/cosine estimator, ACE)(Manolakis,2005)、自适应子空间检测法(adaptive subspace detector, ASD)(Acito 等,2013)、正交子空间投影检测法(orthogonal subspace projection, OSP)(Manolakis 等,2001)等。SAM(spectral angle mapper)以及相关系数也可以用来探测已知目标的气体(Omruuzun 和 Cetin,2015)。为了对4种应用最为广泛的气体目标线性探测算子 ACE、ASD、AMF 和 CMF 进行对比和评估,在相同的

模拟气体排放场景热红外高光谱数据立方体上进行测试,定量评价指标包括召回率(true positive rate, TPR)、查准率(precision)、虚警率(false positive rate, FPR)、正确率(accuracy, ACC)和马修斯相关系数(Matthews correlation coefficient, MCC),结果如表4所示。可以看出,杂波匹配滤波器 CMF 取得了最佳的探测精度(贾朝阳,2022)。除了算子结构差异需要考虑,气体温度、排放源强度也对探测结果有一定的影响。Hulley 等人(2016)在 HyTES(the hyperspectral thermal emission spectrometer)热红外高光谱遥感影像数据上的实验证明,由于广义似然比假设检验以线性模型描述目标气体的光谱特征组分,大气温度与目标气体温度之间的差距越大,上述线性探测算子探测效果越差(Hulley 等,2016)。图10展示了4种气体探测算法的结果。

表 4 4种气体探测算法的精度

Table 4 The accuracy of four gas detection algorithms

	召回率/%	查准率/%	虚警率/%	正确率	MCC
ACE	22.18	61.71	0.74	0.953	0.352
AMF	7.87	89.84	0.05	0.953	0.258
ASD	4.18	98.39	0	0.951	0.197
CMF	52.84	89.35	0.34	0.973	0.675

注:加粗字体表示各列最优结果。




图10 4种气体探测算法的结果

Fig. 10 Results of four gas detection algorithms ((a) radiance image; (b) ground truth; (c) AMF; (d) ACE; (e) CMF; (f) ASD)

除了基于气体目标特征曲线统计相似性的方法,影像分割的思路也被迁移到热红外高光谱遥感影像气体探测中。该类方法在空间上对热红外高光谱影像进行分割,与目标气体吸收特征相似性高的空间块聚类成为探测到的气体区域。随着深度学习

方法的发展,智能化的数据驱动探测技术成为气体探测的趋势。例如,Mask-RCNN(mask region-based convolutional neural network)方法已应用到热红外高光谱影像气体探测中,H-MRCNN(hyperspectral Mask-RCNN)方法首先在光谱维度设置滑窗并进行

CMF(clutter matched filter)匹配滤波,得到的CMF结果集合输入到Mask-RCNN中进行影像分割,分割结果进一步由集成学习进行融合得到最终的气体探测结果掩膜(Kumar等,2020)。该方法在AVIRIS-NG(airborne visible infrared imaging spectrometer-next generation)成像仪采集到的数据集上表现优于经典的机器学习方法SVM、GMM(Gaussian mixture model)以及分水岭算法,优于Learn to Segment Everything模型,取得了0.87的交并比(intersection over union, IoU)结果。

另外,为进一步解决气体排放场景热红外高光谱遥感成像的非纯净像元难题,提高气体目标探测效果,基于混合像元分解的热红外高光谱气体目标探测方法后续被提出。这类方法仍然需要气体目标的吸收光谱特征,但与相似性统计方法相比而言,其依据辐射传输模型对大气、背景进行更加细致的分解。尽管求解结果不完全等于气体的柱浓度,但是其提取出来的气体端元丰度一定程度上与气体的柱浓度成正相关关系,当气体端元的丰度大于指定阈值(如50%)时即可以认为气体在对应像元处出现。Özdemir和Koz(2023)为热红外高光谱遥感成像式气体探测设计了三维卷积神经网络和自编码器架构,以混合光谱分解的思路提取出每一个像元处各端元的丰度,然后依据目标气体端元的丰度信息分割出目标气体区域。

以上气体探测方法均需要事先已知气体的种类以及光谱特征信息,对于未知气体而言,基于最小绝对收缩和选择算子等异常目标探测方法是解决这类气体探测问题的有效途径。如贝叶斯指标模型选择(Bayesian index model selection, BIMS)被引入到热红外高光谱遥感成像式气体目标探测与识别中,并融合影像的空间信息以及气体探测的非线性模型,在模拟数据上实现了化学气体的探测(Larrieux, 2009);另外,可见光波段范围内常用的RXD高光谱遥感影像异常目标探测方法被引入到热红外领域,其本质是针对未知目标特征情形对广义似然比假设检验GLRT方法进行改进,尽管该类方法在探测精度上稍逊于传统的相似性度量方法,但是其无需事先已知气体的种类和特征曲线,具有更广泛的应用场景(Theiler和Wohlberg, 2013);基于Lasso(least absolute shrinkage and selection operator)方法的污染气体自适应探测算法可较好地消除

背景信息,研究学者通过开展甲烷、氨气、乙烯探测实验,证明该方法具有较强的实用性(崔方晓等,2019)。这些方法都可以完成未知气体的探测,而基于热红外高光谱遥感影像,如何进一步提高异常气体目标探测的精度,是当前的研究热点。

5 结 语

热红外高光谱遥感影像信息提取作为一个新兴前沿研究方向,具有热红外反映的地物自身温度属性、高光谱反映的地物精细光谱指纹特征,以及影像反映的地物空间分布联系这三重属性信息。目前针对热红外高光谱遥感影像的信息提取方法,不仅受到相关信息提取方法理论边界的限制,还受到传感器研制水平和典型行业应用场景的制约,虽然具有广阔的研究和发展前景,但尚有很多问题待解决。

1)地表参量信息高精度反演。从入瞳辐亮度数据中反演获得地表温度与发射率参量始终面临着地气参量有待精确解耦这一挑战。目前主流的分步反演法包括大气补偿法和温度发射率分离法两个前后承接环节,分步反演法中的这两个环节相对独立,存在误差累积效应,同时大气补偿方法都源于多光谱热红外大气补偿法,针对不同传感器数据需要人工专家干预进行修正,不利于热红外高光谱影像温度发射率产品的自动化生成。因此近年来,人工智能开始逐渐被引入地表参量反演,热红外高光谱的丰富光谱特性,结合深度学习强大的拟合求解能力,为地气参数一体化反演提供了新的途径(Wang等, 2021;Ye等, 2022)。然而,由于热红外高光谱影像受到仪器设备昂贵、公开数据源较少等条件限制,深度学习数据样本依然以模拟数据为主,与真实数据之间存在难迁移、模型不稳定等问题。此外,无论是分步反演方法还是一体化反演方法,在反演过程中,精细的光谱信息并未得到充分的应用,因此,如何进一步挖掘高光谱热红外的密集通道信息优势,有效结合物理模型和深度学习技术,在模型和数据双驱动的支持下实现一体化地气参数反演,是热红外高光谱遥感影像定量反演研究的前沿趋势。

2)热红外高光谱混合像元精确解混。热红外传感器观测到的热辐射是若干个组分热辐射的综合,相比较与可见光混合像元,热红外辐射耦合了像元组分温度、发射率、大气信息等多个未知量,为热红

外高光谱遥感影像混合像元分解带来了挑战。当前,热红外高光谱遥感影像混合像元分解往往基于辐射传输物理模型,通过确定端元发射率光谱信息,在大气补偿前提下实现端元组分温度和丰度估算。由于大气参数、端元发射率及其数量等参数需要事先已知,且在实际应用中大气廓线参数存在大气数据与影像数据获取时空不一致、端元数量估算不准确等问题(Gao等,2022;Cao等,2022),热红外高光谱遥感影像混合像元分解结果精度受到相当大的限制。现阶段,深度学习已广泛应用于可见光谱、高光谱空谱特征分析中,部分学者借此确定端元数量及光谱,并提出用于估算丰度的智能化分解模型(Wang等,2017;Cui等,2023)。因此,融合物理模型和深度学习理论,实现热红外高光谱遥感影像混合像元组分温度、发射率和大气信息全自动求解是热红外高光谱研究的重点之一。

3)热红外高光谱精细分类。热红外高光谱影像同时包含了地物的温度、发射率光谱和空间信息。传统的仅依赖于光谱维或空间维的分类方法在矿物填图方面已有一定的应用。然而,在复杂场景中自然地物较小的类间差异和较强的光谱噪声,以及温度发射率反演不确定性影响,成为实现高精度热红外高光谱场景分类的主要挑战。考虑到热红外高光谱影像的数据特性,以空谱融合为基础的深度学习网络在目前的分类方法中具有显著优势。虽然现阶段深度学习模型由于训练数据缺乏并未广泛应用于热红外高光谱遥感影像数据,但现有研究表明,利用影像的全局语义信息,实现长距离像素的语义关联,可望实现更加鲁棒的分类效果。

4)热红外高光谱遥感影像目标探测。针对固态目标探测,现有的热红外高光谱遥感影像探测方法与可见光高光谱遥感影像目标探测方法差异不大,但由于热红外高光谱成像仍然无法有效解决地气参数耦合和光谱噪声大的问题,更精确的目标探测亟需地气参数一体化解耦。特别地,针对热红外高光谱遥感影像气体目标探测,由于气体在热红外高光谱波段范围上有着显著的光谱响应特征,热红外高光谱相较于可见光高光谱具有可识别气体种类、可定量反演浓度等特殊优势。传统的光谱匹配滤波器算法过度依赖专家手工选取探测阈值,然而,气体的实时动态变化,使得单一的基于大规模光谱数据库匹配的算法会造成探测结果产生大量虚警(Scafutto

等,2018),深度学习方法为参数自动化选取提供了可行性。考虑到目前的热红外高光谱目标探测方法均面临大规模测试数据缺乏的挑战,进一步扩充模拟数据集规模并发展零样本推理或者迁移学习方法是有效完成热红外高光谱遥感影像目标探测任务的发展方向。进一步对热红外高光谱遥感影像气体目标探测进行展望,在气体泄漏范围探测结果基础上定量地给予其浓度表达并进一步对泄漏态势进行预测,同样是热红外高光谱气体探测的重点和难点。

参考文献(References)

- Acito N, Diani M and Corsini G. 2013. Hyperspectral signal subspace identification in the presence of rare vectors and signal-dependent noise. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1): 283-299 [DOI: 10.1109/TGRS.2012.2201488]
- Acito N, Diani M and Corsini G. 2019. Coupled subspace-based atmospheric compensation of LWIR hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8): 5224-5238 [DOI: 10.1109/TGRS.2019.2897498]
- Aslett Z, Taranik J V and Riley D N. 2018. Mapping rock forming minerals at Boundary Canyon, Death Valley National Park, California, using aerial SEBASS thermal infrared hyperspectral image data. *International Journal of Applied Earth Observation and Geoinformation*, 64: 326-339 [DOI: 10.1016/j.jag.2017.08.001]
- Baatz M and Schape A. 2000. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation//*Proceedings of the Angewandte Geographische Informations-Verarbeitung*. Karlsruhe, Germany: [s.n.]: 12-23
- Bandfield J L. 2002. Global mineral distributions on Mars. *Journal of Geophysical Research: Planets*, 107(E6): #5042 [DOI: 10.1029/2001JE001510]
- Bandos T V, Bruzzone L and Camps-Valls G. 2009. Classification of hyperspectral images with regularized linear discriminant analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3): 862-873 [DOI: 10.1109/TGRS.2008.2005729]
- Bao F L, Wang X J, Sureshbabu S H, Sreekumar G, Yang L P, Aggarwal V, Boddeti V N and Jacob Z. 2023. Heat-assisted detection and ranging. *Nature*, 619(7971): 743-748 [DOI: 10.1038/s41586-023-06174-6]
- Barisone F, Solarna D, De Giorgi A, Moser G and Serpico S B. 2016. Supervised classification of thermal infrared hyperspectral images through bayesian, markovian, and region-based approaches//2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Beijing, China: IEEE: 937-940 [DOI: 10.1109/IGARSS.2016.7729237]
- 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]
- Berk A, Conforti P, Kennett R, Perkins T, Hawes F and van den Bosch J. 2014. MODTRAN6: a major upgrade of the MODTRAN radiative transfer code//*Proceedings of the Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XX*. Baltimore, USA: SPIE: #90880H [DOI: 10.1117/12.2050433]
- Borel C. 2008. Error analysis for a temperature and emissivity retrieval algorithm for hyperspectral imaging data. *International Journal of Remote Sensing*, 29(17/18): 5029-5045 [DOI: 10.1080/01431160802036540]
- Borel C C. 1997. Iterative retrieval of surface emissivity and temperature for a hyperspectral sensor//*Proceedings of the first JPL Workshop on Remote Sensing of Land Surface Emissivity*. Pasadena, USA: [1. n.]: 1-5
- Campos R L, Yoon S C, Chung S and Bhandarkar S M. 2023. Semisupervised deep learning for the detection of foreign materials on poultry meat with near-infrared hyperspectral imaging. *Sensors*, 23(16): #7014 [DOI: 10.3390/s23167014]
- Camps-Valls G, Gomez-Chova L, Munoz-Mari J, Vila-Frances 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/LGRS.2005.857031]
- Cao L Q, He J N, Gao L Z, Zhong Y F, Hu X and Li Z J. 2022. LWIR hyperspectral image classification based on a temperature-emissivity residual network and conditional random field model. *International Journal of Remote Sensing*, 43(10): 3744-3768 [DOI: 10.1080/01431161.2022.2105667]
- Carion N, Massa F, Synnaeve G, Usunier N, Kirillov A and Zagoruyko S. 2020. End-to-end object detection with Transformers//*Proceedings of the 16th European Conference on Computer Vision*. Glasgow, UK: Springer: 213-229 [DOI: 10.1007/978-3-030-58452-8_13]
- 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]
- Chen M S, Ni L, Jiang X G, Li Z L and Wu H. 2018. Retrieval of atmospheric and land surface parameters from satellite-based thermal infrared hyperspectral data using an artificial neural network technique//*IGARSS, 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*. Valencia, Spain: IEEE: 2745-2748 [DOI: 10.1109/IGARSS.2018.8518131]
- Chen S S, Ren H Z, Liu R Y, Tao Y Z, Zheng Y T and Liu H C. 2021. Mapping sandy land using the new sand differential emissivity index from thermal infrared emissivity data. *IEEE Transactions on Geoscience and Remote Sensing*, 59(7): 5464-5478 [DOI: 10.1109/TGRS.2020.3022772]
- Cheng J, Liang S L, Wang J D and Li X W. 2010. A stepwise refining algorithm of temperature and emissivity separation for hyperspectral thermal infrared data. *IEEE Transactions on Geoscience and Remote Sensing*, 48(3): 1588-1597 [DOI: 10.1109/TGRS.2009.2029852]
- Christensen P R, Bandfield J L, Smith M D, Hamilton V E and Clark R N. 2000. Identification of a basaltic component on the martian surface from thermal emission spectrometer data. *Journal of Geophysical Research: Planets*, 105(E4): 9609-9621 [DOI: 10.1029/1999JE001127]
- Chutia D, Bhattacharyya D. K, Sarma K. K, Kalita R and Sudhakar S. 2016. hyperspectral remote sensing classifications: a perspective survey. *Transactions in GIS*, 20(4): 463-490 [DOI: 10.1111/tgis.12164]
- Clare P. 2006. Design and modeling of spectral-thermal unmixing targets for airborne hyperspectral imagery//*Proceedings of the Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XII*. Orlando, USA: SPIE: 542-553 [DOI: 10.1117/12.665821]
- Cubero-Castan M, Chanussot J, Achard V, Briottet X and Shimoni M. 2015. A physics-based unmixing method to estimate subpixel temperatures on mixed pixels. *IEEE Transactions on Geoscience and Remote Sensing*, 53(4): 1894-1906 [DOI: 10.1109/TGRS.2014.2350771]
- Cui C Y, Wang X Y, Wang S Y, Zhang L P and Zhong Y F. 2023. Unrolling nonnegative matrix factorization with group sparsity for blind hyperspectral unmixing. *IEEE Transactions on Geoscience and Remote Sensing*, 61: #5516712 [DOI: 10.1109/TGRS.2023.3292453]
- Cui F X, Li D C, Wu J, Wang A J and Li Y Y. 2019. Adaptive feature extraction algorithm based on Lasso method for detecting polluted gas. *Acta Optica Sinica*, 39(5): 406-414 (崔方晓, 李大成, 吴军, 王安静, 李扬裕. 2019. 基于Lasso方法的污染气体自适应探测算法. *光学学报*, 39(5): 406-414) [DOI: 10.3788/AOS201939.0530003]
- De Carvalho Jr O A and Meneses P R. 2000. Spectral correlation mapper (SCM): an improvement on the spectral angle mapper (SAM). *Summaries of the 9th JPL Airborne Earth Science Workshop*. Pasadena, USA: JPL Publication: #2
- DiPietro R S, Manolakis D, Lockwood R B, Cooley T and Jacobson J. 2012. Hyperspectral matched filter with false-alarm mitigation. *Optical Engineering*, 51(1): #016202 [DOI: 10.1117/1.OE.51.1.016202]
- Farley V, Chamberland M, Lagueux P, Vallières A, Villemaire A and Giroux J. 2007. Chemical agent detection and identification with a hyperspectral imaging infrared sensor//*Proceedings of the Imaging Spectrometry XII*. San Diego, USA: SPIE: 334-345 [DOI: 10.1117/12.736731]
- 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]
- Feng R Y, Wang L Z and Zeng T Y. 2023. Review of hyperspectral remote sensing image subpixel information extraction. *Acta Geodae-tica et Cartographica Sinica*, 52(7): 1187-1201 (冯如意, 王力哲, 曾铁勇. 2023. 高光谱遥感图像亚像元信息提取方法综述. *测绘学报*, 52(7): 1187-1201) [DOI: 10.11947/j. AGCS. 2023. 20220491]
- Gålfalk M, Olofsson G, Crill P and Bastviken D. 2016. Making methane visible. *Nature Climate Change*, 6(4): 426-430 [DOI: 10.1038/NCLIMATE2877]
- Gao L Z, Zhong Y F, Cao L Q, He J N and Zhu X H. 2022. A practical temperature and emissivity separation framework with reanalysis atmospheric profiles for hyper-cam airborne thermal infrared hyper-spectral imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15: 687-699 [DOI: 10.1109/JSTARS.2021.3136194]
- Gastellu-Etchegorry J P, Yin T G, Lauret N, Cajgfinger T, Gregoire T, Grau E, Feret J B, Lopes M, Guilleux J, Dedieu G, Malenovsky Z, Cook B D, Morton D, Rubio J, Durrieu S, Cazanave G, Martin E and Ristorcelli T. 2015. Discrete anisotropic radiative transfer (DART 5) for modeling airborne and satellite spectroradiometer and LIDAR acquisitions of natural and urban landscapes. *Remote Sensing*, 7(2): 1667-1701 [DOI: 10.3390/rs70201667]
- Gillespie A, Rokugawa S, Matsunaga T, Cothorn J S, Hook S and Kahle A B. 1998. A temperature and emissivity separation algo-rithm for advanced spaceborne thermal emission and reflection radi-ometer (ASTER) images. *IEEE Transactions on Geoscience and Remote Sensing*, 36(4): 1113-1126 [DOI: 10.1109/36.700995]
- Goudge T A, Mustard J F, Head J W, Salvatore M R and Wiseman S M. 2015. Integrating CRISM and TES hyperspectral data to character-ize a halloysite-bearing deposit in Kashira crater, Mars. *Icarus*, 250: 165-187 [DOI: 10.1016/j.icarus.2014.11.034]
- Granero-Belinchon C, Michel A, Achard V and Briottet X. 2020. Spec-tral unmixing for thermal infrared multi-spectral airborne imagery over urban environments: day and night synergy. *Remote Sensing*, 12(11): #1871 [DOI: 10.3390/rs12111871]
- Gu D, Gillespie A R, Kahle A B and Palluconi F D. 2000. Autonomous atmospheric compensation (AAC) of high resolution hyperspectral thermal infrared remote-sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 38(6): 2557-2570 [DOI: 10.1109/36.885203]
- Hackwell J A, Warren D W, Bongiovi R P, Hansel S J, Hayhurst T L, Mabry D J, Sivjee M G and Skinner J W. 1996. LWIR/MWIR imag-ing hyperspectral sensor for airborne and ground-based remote sens-ing//*Proceedings of the Imaging Spectrometry II*. Denver, USA: SPIE: 102-107 [DOI: 10.1117/12.258057]
- Hamilton V E. 2000. Thermal infrared emission spectroscopy of the pyroxene mineral series. *Journal of Geophysical Research*, 105: 9701 - 9716 [DOI: 10.1029/1999JE001112]
- Hook S J, Johnson W R and Abrams M J. 2013. NASA's hyperspectral thermal emission spectrometer (HyTES)//Kuenzer C and Dech S, eds. *Thermal Infrared Remote Sensing: Sensors, Methods, Appli-cations*. Dordrecht, the Netherlands: Springer: 93-115 [DOI: 10.1007/978-94-007-6639-6_5]
- Hu X, Zhong Y F, Wang X Y, Luo C, Zhao J, Lei L and Zhang L P. 2022. SPNet: spectral patching end-to-end classification network for UAV-borne hyperspectral imagery with high spatial and spectral resolutions. *IEEE Transactions on Geoscience and Remote Sens-ing*, 60: #5503417 [DOI: 10.1109/TGRS.2021.3049292]
- Hulley G C, Duren R M, Hopkins F M, Hook S J, Vance N, Guillevic P, Johnson W R, Eng B T, Mihaly J M, Jovanovic V M, Chaza-noff S L, Staniszewski Z K, Kuai L, Worden J, Frankenberg C, Rivera G, Aubrey A D, Miller C E, Malakar N K, Tomás J M S and Holmes K T. 2016. High spatial resolution imaging of methane and other trace gases with the airborne hyperspectral thermal emis-sion spectrometer (HyTES). *Atmospheric Measurement Tech-niques*, 9(5): 2393-2408 [DOI: 10.5194/amt-9-2393-2016]
- Jia Z Y. 2022. Gas Plume Imaging Simulation and Detection Method Based on Fourier Transform Thermal Infrared Hyperspectral. Wuhan University (贾朝阳. 2022. 基于傅立叶变换热红外高光谱的气体成像模拟与探测方法研究. 武汉大学)
- Jimenez-Munoz J C and Sobrino J A. 2010. A single-channel algorithm for land-surface temperature retrieval from ASTER data. *IEEE Geo-science and Remote Sensing Letters*, 7(1): 176-179 [DOI: 10.1109/LGRS.2009.2029534]
- Jr DiStasio R J and Resmini R G. 2010. Atmospheric compensation of thermal infrared hyperspectral imagery with the emissive empirical line method and the in-scene atmospheric compensation algo-rithms: a comparison//*Proceedings of the Algorithms and Technolo-gies for Multispectral, Hyperspectral, and Ultraspectral Imagery XVI*. [s.l.]: SPIE: 805-816 [DOI: 10.1117/12.849898]
- Kim S H, Ma J R, Kook M J and Lee K S. 2005. Current status of hyper-spectral remote sensing: principle, data processing techniques, and applications. *Korean Journal of Remote Sensing*, 21(4): 341-369 [DOI: 10.7780/kjrs.2005.21.4.341]
- Kraut S and Scharf L L. 1999. The CFAR adaptive subspace detector is a scale-invariant GLRT. *IEEE Transactions on Signal Processing*, 47(9): 2538-2541 [DOI: 10.1109/78.782198]
- Kraut S, Scharf L L and McWhorter L T. 2001. Adaptive subspace detec-tors. *IEEE Transactions on Signal Processing*, 49(1): 1-16 [DOI: 10.1109/78.890324]
- Kuenzer C and Dech S. 2013. *Thermal Infrared Remote Sensing: Sen-sors, Methods, Applications*. Dordrecht, the Netherlands: Springer: 978-994
- Kumar S, Torres C, Ulutan O, Ayasse A, Roberts D and Manjunath B

- S. 2020. Deep remote sensing methods for methane detection in overhead hyperspectral imagery//Proceedings of 2020 IEEE Winter Conference on Applications of Computer Vision (WACV). Snowmass, USA: IEEE: 1765-1774 [DOI: 10.1109/WACV45572.2020.9093600]
- Lagueux P, Farley V, Chamberland M, Villemare A, Turcotte C, Puckrin E and TELOPS INC (QUEBEC). 2009. Design and performance of the hyper-cam, an infrared hyperspectral imaging sensor [EB/OL]. [2023-10-02].
<https://apps.dtic.mil/sti/citations/ADA568314>
- Larrieux E R. 2009. Performance Evaluation of Chemical Plume Detection and Quantification Algorithms. Boston, USA: Northeastern University
- Li C L, Liu C Y, Jin J, Xu R, Lyu G, Xie J N, Yuan L Y, Liu S J and Wang J Y. 2022. Development of infrared hyperspectral remote sensing imaging and application of gas detection (invited). *Infrared and Laser Engineering*, 51(7): #20210866 (李春来, 刘成玉, 金健, 徐睿, 吕刚, 谢嘉楠, 袁立银, 刘世界, 王建宇. 2022. 红外高光谱遥感成像的技术发展与气体探测应用(特邀). *红外与激光工程*, 51(7): #20210866) [DOI: 10.3788/IRLA20210866]
- Li S T, Song W W, Fang L Y, Chen Y S, Ghamisi P and Benediktsson J.A. 2019. Deep learning for hyperspectral image classification: An overview. *IEEE Transactions on Geoscience and Remote Sensing*, 57: 6690-6709 [DOI: 10.1109/TGRS.2019.2907932]
- Li X Y, Li Z M, Qiu H M, Hou G L and Fan P P. 2023a. An overview of hyperspectral image feature extraction, classification methods and the methods based on small samples. *Applied Spectroscopy Reviews*, 58(6): 367-400 [DOI: 10.1080/05704928.2021.1999252]
- Li Y T, Li Z L, Wu H, Zhou C H, Liu X Y, Leng P, Yang P, Wu W B, Tang R L, Shang G F and Ma L L. 2023b. Biophysical impacts of earth greening can substantially mitigate regional land surface temperature warming. *Nature Communications*, 14(1): #121 [DOI: 10.1038/s41467-023-35799-4]
- Li Z L, Tang B H, Wu H, Ren H Z, Yan G J, Wan Z M, Trigo I F and Sobrino J A. 2013. Satellite-derived land surface temperature: current status and perspectives. *Remote Sensing of Environment*, 131: 14-37 [DOI: 10.1016/j.rse.2012.12.008]
- Li Z L, Wu H, Duan S B, Zhao W, Ren H Z, Liu X Y, Leng P, Tang R L, Ye X, Zhu J S, Sun Y W, Si M L, Liu M, Li J H, Zhang X, Shang G F, Tang B H, Yan G J and Zhou C H. 2023c. Satellite remote sensing of global land surface temperature: definition, methods, products, and applications. *Reviews of Geophysics*, 61(1): #2022RG000777 [DOI: 10.1029/2022RG000777]
- Liu H Z, Wu K, Xu H G and Xu Y. 2021. Lithology classification using TASI thermal infrared hyperspectral data with convolutional neural networks. *Remote Sensing*, 13(16): #3117 [DOI: 10.3390/rs13163117]
- Liu K, Su H B and Li X K. 2016. Estimating high-resolution urban surface temperature using a hyperspectral thermal mixing (HTM) approach. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(2): 804-815 [DOI: 10.1109/JSTARS.2015.2459375]
- Lu X C, Zhang J P, Li T and Zhang G L. 2015. Synergetic classification of long-wave infrared hyperspectral and visible images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(7): 3546-3557 [DOI: 10.1109/JSTARS.2015.2442594]
- Ma C Y, Qian Y G, Li K, Dou X H, Shen H F, Tang H Z, Qiu S, Zhang L H, Jia Y Y and Ou-Yang G Z. 2023. Temperature and emissivity retrieval from hyperspectral thermal infrared data using dictionary-based sparse representation for emissivity. *IEEE Transactions on Geoscience and Remote Sensing*, 61: #5002016 [DOI: 10.1109/TGRS.2023.3268860]
- Manolakis D, Pieper M, Truslow E, Lockwood R, Weisner A, Jacobson J and Cooley T. 2019. Longwave infrared hyperspectral imaging: principles, progress, and challenges. *IEEE Geoscience and Remote Sensing Magazine*, 7(2): 72-100 [DOI: 10.1109/MGRS.2018.2889610]
- Manolakis D, Siracusa C and Shaw G. 2001. Hyperspectral subpixel target detection using the linear mixing model. *IEEE Transactions on Geoscience and Remote Sensing*, 39(7): 1392-1409 [DOI: 10.1109/36.934072]
- Manolakis D G. 2005. Taxonomy of detection algorithms for hyperspectral imaging applications. *Optical Engineering*, 44(6): #066403 [DOI: 10.1117/1.1930927]
- Matteoli S, Diani M and Corsini G. 2010. Improved estimation of local background covariance matrix for anomaly detection in hyperspectral images. *Optical Engineering*, 49(4): #046201 [DOI: 10.1117/1.3386069]
- McElhinney O, Pieper M L, Manolakis D, Loughlin C, Ingle V, Bostick R and Weisner A. 2022. Spline based emissivity retrieval for LWIR hyperspectral imagery//Proceedings of the Algorithms, Technologies, and Applications for Multispectral and Hyperspectral Imaging XXVIII. Orlando, USA: SPIE: 226-236 [DOI: 10.1117/12.2618553]
- Meerdink S, Roberts D, Hulley G, Gader P, Pisek J, Adamson K, King J and Hook S J. 2019. Plant species' spectral emissivity and temperature using the hyperspectral thermal emission spectrometer (HyTES) sensor. *Remote Sensing of Environment*, 224: 421-435 [DOI: 10.1016/j.rse.2019.02.009]
- Miao X Y, Zhang Y, Zhang J P and Zhong S W. 2017. Object parameters optimization on pure and mixed pixels in thermal hyperspectral imagery//Proceedings of the Infrared Remote Sensing and Instrumentation XXV. [s.l.]: SPIE: 156-163 [DOI: 10.1117/12.2272521]
- Mushkin A, Gillespie A R, Abbott E A, Batbaatar J, Hulley G, Tan H, Tratt D M and Buckland K N. 2020. Validation of ASTER emissivity retrieval using the mako airborne TIR imaging spectrometer at the algodones dune field in Southern California, USA. *Remote Sensing*, 12(5): #815 [DOI: 10.3390/rs12050815]

- O'Keefe D S, Nauyoks S N, Hawks M R, Meola J and Gross K C. 2022. Oblique in-scene atmospheric compensation. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #5533615 [DOI: 10.1109/TGRS.2022.3186676]
- Omrurzun F and Cetin Y Y. 2015. Endmember signature based detection of flammable gases in LWIR hyperspectral images//Proceedings of the Advanced Environmental, Chemical, and Biological Sensing Technologies XII. Baltimore, USA: SPIE: 168-176 [DOI: 10.1117/12.2182060]
- Özdemir O B and Koz A. 2023. 3D-CNN and autoencoder-based gas detection in hyperspectral images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16: 1474-1482 [DOI: 10.1109/JSTARS.2023.3235781]
- Palluconi F D and Meeks G R. 1985. Thermal infrared multispectral scanner (TIMS): an investigator's guide to TIMS data [EB/OL]. [2023-10-02]. <https://ntrs.nasa.gov/citations/19850019974>
- Pieper M L, McElhinney O, Manolakis D, Bostick R and Weisner A. 2023. Concurrent atmospheric retrieval and wavelength calibration correction technique for improved emissivity retrieval//Proceedings of the Algorithms, Technologies, and Applications for Multispectral and Hyperspectral Imaging XXIX. Orlando, USA: SPIE: #PC1251908 [DOI: 10.1117/12.2663931]
- Pignatti S, Lapenna V, Palombo A, Pascucci S, Pergola N and Cuomo V. 2011. An advanced tool of the CNR IMAA EO facilities: overview of the TASI-600 hyperspectral thermal spectrometer//Proceedings of the 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing. Lisbon, Portugal: IEEE: 1-4 [DOI: 10.1109/WHISPERS.2011.6080890]
- Ramsey M S and Christensen P R. 1998. Mineral abundance determination: Quantitative deconvolution of thermal emission spectra. *Journal of Geophysical Research: Solid Earth*, 103 (B1): 577-596 [DOI: 10.1029/97JB02784]
- Rankin B M, Meola J and Eismann M T. 2017. Spectral radiance modeling and Bayesian model averaging for longwave infrared hyperspectral imagery and subpixel target identification. *IEEE Transactions on Geoscience and Remote Sensing*, 55 (12): 6726-6735 [DOI: 10.1109/TGRS.2017.2731955]
- Reed I S and Yu X. 1990. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 38(10): 1760-1770 [DOI: 10.1109/29.60107]
- Ren H Z, Ye X, Nie J, Meng J J, Fan W J, Qin Q M, Liang Y Z and Liu H C. 2022. Retrieval of land surface temperature, emissivity, and atmospheric parameters from hyperspectral thermal infrared image using a feature-band linear-format hybrid algorithm. *IEEE Transactions on Geoscience and Remote Sensing*, 60: #4401015 [DOI: 10.1109/TGRS.2020.3047381]
- Rodarmel C and Shan J. 2002. Principal component analysis for hyperspectral image classification. *Surveying and Land Information Science*, 62(2): 115-123
- Scafutto R D P M, de Souza Filho C R, Riley D N and de Oliveira W J. 2018. Evaluation of thermal infrared hyperspectral imagery for the detection of onshore methane plumes: significance for hydrocarbon exploration and monitoring. *International Journal of Applied Earth Observation and Geoinformation*, 64: 311-325 [DOI: 10.1016/j.jag.2017.07.002]
- Scafutto R D P M, Lievens C, Hecker C, van der Meer F D and de Souza Filho C R. 2021. Detection of petroleum hydrocarbons in continental areas using airborne hyperspectral thermal infrared data (SEBASS). *Remote Sensing of Environment*, 256: #112323 [DOI: 10.1016/j.rse.2021.112323]
- Schaum A. 2004. Joint subspace detection of hyperspectral targets//Proceedings of IEEE Aerospace Conference Proceedings. SkyBig, USA: IEEE: #1824 [DOI: 10.1109/AERO.2004.1367963]
- Shao H L, Liu C Y, Xie F, Li C L and Wang J Y. 2020. Noise-sensitivity analysis and improvement of automatic retrieval of temperature and emissivity using spectral smoothness. *Remote Sensing*, 12(14): #2295 [DOI: 10.3390/rs12142295]
- Smith M D, Bandfield J L and Christensen P R. 2000. Separation of atmospheric and surface spectral features in mars global surveyor thermal emission spectrometer (TES) spectra. *Journal of Geophysical Research: Planets*, 105 (E4): 9589-9607 [DOI: 10.1029/1999JE001105]
- Sundberg R, Adler-Golden S and Conforti P. 2015. Long-wavelength infrared hyperspectral data "mining" at cuprite, NV//Proceedings of the Imaging Spectrometry XX. San Diego, USA: SPIE: 12-18 [DOI: 10.1117/12.2187061]
- Tarabalka Y, Fauvel M, Chanussot J and Benediktsson J A. 2010. SVM- and MRF-based method for accurate classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 7(4): 736-740 [DOI: 10.1109/LGRS.2010.2047711]
- Tellier Y, Crevoisier C, Armante R, Dufresne J L and Meilhac N. 2022. Computation of longwave radiative flux and vertical heating rate with 4A-Flux v1.0 as an integral part of the radiative transfer Code 4A/OP v1.5. *Geoscientific Model Development*, 15 (13): 5211-5231 [DOI: 10.5194/gmd-15-5211-2022]
- Thai B and Healey G. 2002. Invariant subpixel material detection in hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 40 (3): 599-608 [DOI: 10.1109/TGRS.2002.1000320]
- Theiler J and Wohlberg B. 2013. Detection of unknown gas-phase chemical plumes in hyperspectral imagery//Proceedings of the Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XIX. Baltimore, USA: SPIE: 346-357 [DOI: 10.1117/12.2016211]
- Tong Q X, Xue Y Q and Zhang L F. 2014. Progress in hyperspectral remote sensing science and technology in China over the past three decades. *IEEE Journal of Selected Topics in Applied Earth Obser-*

- vations and Remote Sensing, 7 (1): 70-91 [DOI: 10.1109/JSTARS.2013.2267204]
- Truslow E, Manolakis D, Cooley T and Meola J. 2016. Statistical modeling of natural backgrounds in hyperspectral LWIR data//Proceedings of the Imaging Spectrometry XXI. San Diego, USA: SPIE: #99760H [DOI: 10.1117/12.2239432]
- Vaughan R G, Calvin W M and Taranik J V. 2003. SEBASS hyperspectral thermal infrared data: surface emissivity measurement and mineral mapping. Remote Sensing of Environment, 85 (1): 48-63 [DOI: 10.1016/S0034-4257(02)00186-4]
- Veraverbeke S, Dennison P, Gitas I, Hulley G, Kalashnikova O, Katagis T, Kuai L, Meng R, Roberts D and Stavros N. 2018. Hyperspectral remote sensing of fire: state-of-the-art and future perspectives. Remote Sensing of Environment, 216: 105-121 [DOI: 10.1016/j.rse.2018.06.020]
- Vidal C and Pasquini C. 2021. A comprehensive and fast microplastics identification based on near-infrared hyperspectral imaging (HSI-NIR) and chemometrics. Environmental Pollution, 285: #117251 [DOI: 10.1016/j.envpol.2021.117251]
- Villa A, Benediktsson J A, Chanussot J and Jutten C. 2011. Hyperspectral image classification with independent component discriminant analysis. IEEE Transactions on Geoscience and Remote Sensing, 49(12): 4865-4876 [DOI: 10.1109/TGRS.2011.2153861]
- Wan Z M and Li Z L. 1997. A physics-based algorithm for retrieving land-surface emissivity and temperature from EOS/MODIS data. IEEE Transactions on Geoscience and Remote Sensing, 35 (4): 980-996 [DOI: 10.1109/36.602541]
- Wang H, Mao K B, Yuan Z J, Shi J C, Cao M M, Qin Z H, Duan S B and Tang B H. 2021. A method for land surface temperature retrieval based on model-data-knowledge-driven and deep learning. Remote Sensing of Environment, 265: #112665 [DOI: 10.1016/j.rse.2021.112665]
- Wang J Y, Li C L, Ji H Z, Yuan L Y, Lyu G, Liu E G and Wang Y M. 2015. Status and prospect of thermal infrared hyperspectral imaging technology. Journal of Infrared and Millimeter Waves, 34(1): 51-59 (王建宇, 李春来, 姬弘桢, 袁立银, 吕刚, 刘恩光, 王跃明. 2015. 热红外高光谱成像技术的研究现状与展望. 红外与毫米波学报, 34(1): 51-59) [DOI: 10.11972/j.issn.1001-9014.2015.01.010]
- Wang N, Wu H, Nerry F, Li C R and Li Z L. 2011. Temperature and emissivity retrievals from hyperspectral thermal infrared data using linear spectral emissivity constraint. IEEE Transactions on Geoscience and Remote Sensing, 49 (4): 1291-1303 [DOI: 10.1109/TGRS.2010.2062527]
- Wang S Y, Wang X Y, Zhong Y F and Zhang L P. 2020. Hyperspectral anomaly detection via locally enhanced low-rank prior. IEEE Transactions on Geoscience and Remote Sensing, 58(10): 6995-7009 [DOI: 10.1109/TGRS.2020.2978510]
- Wang X Y, Zhong Y F, Zhang L P and Xu Y Y. 2017. Spatial group sparsity regularized nonnegative matrix factorization for hyperspectral unmixing. IEEE Transactions on Geoscience and Remote Sensing, 55(11): 6287-6304 [DOI: 10.1109/TGRS.2017.2724944]
- Weng Q H. 2009. Thermal infrared remote sensing for urban climate and environmental studies: methods, applications, and trends. ISPRS Journal of Photogrammetry and Remote Sensing, 64(4): 335-344 [DOI: 10.1016/j.isprsjprs.2009.03.007]
- Westing N M, Borghetti B J, Gross K C and Martin J A. 2019. Analysis of long-wave Infrared hyperspectral classification performance across changing scene illumination//Proceedings of the Algorithms, Technologies, and Applications for Multispectral and Hyperspectral Imagery XXV. Baltimore, USA: SPIE: #109860V [DOI: 10.1117/12.2518109]
- Wu H, Li X J, Li Z L, Duan S B and Qian Y G. 2021. Hyperspectral thermal infrared remote sensing: current status and perspectives. National Remote Sensing Bulletin, 25 (8): 1567-1590 (吴骅, 李秀娟, 李召良, 段四波, 钱永刚. 2021. 高光谱热红外遥感: 现状与展望. 遥感学报, 25(8): 1567-1590) [DOI: 10.11834/jrs.20211306]
- Ye X, Ren H Z, Nie J, Hui J, Jiang C C, Zhu J S, Fan W J, Qian Y G and Liang Y Z. 2022. Simultaneous estimation of land surface and atmospheric parameters from thermal hyperspectral data using a LSTM-CNN combined deep neural network. IEEE Geoscience and Remote Sensing Letters, 19: #5508705 [DOI: 10.1109/LGRS.2021.3104501]
- Young S J, Johnson B R and Hackwell J A. 2002. An in-scene method for atmospheric compensation of thermal hyperspectral data. Journal of Geophysical Research: Atmospheres, 107 (D24): #4774 [DOI: 10.1029/2001JD001266]
- Zelinski M E. 2018. Overhead longwave infrared hyperspectral material identification using radiometric models. Journal of Applied Remote Sensing, 12(2): #025019 [DOI: 10.1117/1.JRS.12.025019]
- Zelinski M E. 2020. Off-nadir longwave infrared hyperspectral material identification using radiometric models//IGARSS, 2020-2020 IEEE International Geoscience and Remote Sensing Symposium. Waikoloa, USA: IEEE: 3963-3966 [DOI: 10.1109/IGARSS39084.2020.9324589]
- Zhang B. 2017. Current status and future prospects of remote sensing. Bulletin of Chinese Academy of Sciences, 32(7): 774-784 (张兵. 2017. 当代遥感科技发展的现状与未来展望. 中国科学院院刊, 32(7): 774-784 [DOI: 10.16418/j.issn.1000-3045.2017.07.012])
- Zhang L F, Zhang L P, Tao D C and Huang X. 2012. On combining multiple features for hyperspectral remote sensing image classification. IEEE Transactions on Geoscience and Remote Sensing, 50 (3): 879-893 [DOI: 10.1109/TGRS.2011.2162339]
- Zhang Y Z, Wu H, Jiang X G, Jiang Y Z, Liu Z X and Nerry F. 2017. Land surface temperature and emissivity retrieval from field-measured hyperspectral thermal infrared data using wavelet transform. Remote Sensing, 9(5): #454 [DOI: 10.3390/rs9050454]

- Zhang Y X, Du B, Zhang L P and Wang S. 2015. A low-rank and sparse matrix decomposition-based mahalanobis distance method for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 54(3): 1376-1389 [DOI: 10.1109/TGRS.2015.2479299]
- Zhao Y Q, Jin Z, Zhang F, Zhao H Y, Tao Z W, Dou C F, Xu X H and Liu D H. 2023. Deep-learning-based image captioning: analysis and prospects. *Journal of Image and Graphics*, 28(9): 2788-2816 (赵永强, 金芝, 张峰, 赵海燕, 陶政为, 豆乘风, 徐新海, 刘东红. 2023. 深度学习图像描述方法分析与展望. *中国图象图形学报*, 28(9): 2788-2816) [DOI: 10.11834/jig.220660]
- Zheng Z, Zhong Y F, Ma A L and Zhang L P. 2020. FPGA: fast patch-free global learning framework for fully end-to-end hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 58(8): 5612-5626 [DOI: 10.1109/TGRS.2020.2967821]
- Zhong Y F, Hu X, Luo C, Wang X Y, Zhao J and Zhang L P. 2020. WHU-Hi: UAV-borne hyperspectral with high spatial resolution (H^2) benchmark datasets and classifier for precise crop identification based on deep convolutional neural network with CRF. *Remote Sensing of Environment*, 250: #112012 [DOI: 10.1016/j.rse.2020.112012]
- Zhong Y F, Wang X Y, H X, Wang S Y, Wan Y T, Tang G and Zhang L P. 2023. Hyperspectral with high-spatial resolution remote sensing from observation, processing to applications. *Acta Geodaetica et Cartographica Sinica*, 52(7): 1212-1226 (钟燕飞, 王心宇, 胡鑫, 王少宇, 万瑜廷, 唐舸, 张良培. 2023. 高光谱高空间分辨率遥感观测、处理与应用. *测绘学报*, 52(7): 1212-1226) [DOI: 10.11947/j.AGCS.2023.20220715]
- Zhou S G and Cheng J. 2018. A multi-scale wavelet-based temperature and emissivity separation algorithm for hyperspectral thermal infrared data. *International Journal of Remote Sensing*, 39(22): 8092-8112 [DOI: 10.1080/01431161.2018.1482019]
- Zhu X H. 2021. Research on Thermal Infrared Hyperspectral Anomaly Detection Method Based on Low-Rank Prior. Wuhan, China: Wuhan University (朱绪鹤. 2021. 基于低秩先验的热红外高光谱异常目标探测方法研究. 武汉: 武汉大学) [DOI: 10.27379/d.cnki.gwhdu.2021.000070]

作者简介

曹丽琴, 女, 副教授, 主要研究方向为热红外遥感定量遥感理论与方法。E-mail: clq@whu.edu.cn

钟燕飞, 通信作者, 男, 教授, 主要研究方向为智能化遥感影像信息处理与应用。E-mail: zhongyanfei@whu.edu.cn

汪都, 男, 博士研究生, 主要研究方向为热红外高光谱遥感影像定量反演与应用。E-mail: rsideawd@whu.edu.cn

熊海洋, 男, 硕士研究生, 主要研究方向为热红外遥感气体目标探测与浓度反演。E-mail: haiyangxiong@whu.edu.cn