

高光谱图像分数域信息提取理论与方法进展

赵旭东,陶 然,李 伟,张蒙蒙

(北京理工大学信息与电子学院,北京 100081)

摘 要: 高光谱传感技术具有光谱、空间、辐射等信息同步获取的优势,促使地物描述呈现多尺度、多角度、多维度的特性,基于高光谱图像实施信息精确提取及解析,是建设先进对地观测系统等国家战略的核心需求。然而,高光谱图像信息提取存在光谱维诊断信息不确定、空间维信息利用不充分、协同维信息表征不全面等问题,导致信息感知与解译效果差,严重制约了其行业应用。高光谱智能感知在对地观测等多元领域中的应用,需要机理清晰、关联合理、协同有效的多域信息提取理论与方法。本文综述了高光谱图像分数域信息提取理论与方法进展,首先给出了现有的高光谱图像信息提取方法及其关键问题,然后从光谱维、空谱维、协同维三方面给出了高光谱图像分数域信息提取理论与方法体系。本文随后从光谱维精确控制、空谱维强化感知、协同维信息联合三方面分别总结了关键理论与应用:在光谱维,针对高光谱图像光谱信息提取易受到光谱不确定性现象影响而难以准确区分微弱点目标与复杂背景的问题,分数域光谱信号表征方法可提升光谱域辨识性能,实施高光谱异常检测;在空谱维,针对高光谱场景中地物空间分布不均衡,标签样本不足导致场景解译困难的问题,分数域空谱特征提取方法在有效训练集合扩充的同时提升网络学习的多样性,实施小样本情况下的场景解译;在协同维,针对高光谱与其他传感源存在异质性,导致地物三维信息表征不全面的问题,分数域多源协同特征提取与融合方法可实现多源多域特征联合,完成高精度地物分类。最后,本文指出了未来高光谱图像分数域信息提取理论与方法面临的挑战和发展趋势:面向高光谱数据体量大、分辨率较差等局限性,开展数据、特征层结合的质量提升方法研究;面向训练样本缺失问题,通过深度特征迁移学习技术,充分挖掘高光谱遥感图像中海量无标签数据的多维度光谱、空间、协同信息;面向广域空天遥感对地观测需求,研究模式缺失情况下的深度样本生成、特征扩充、多源跨场景分类方法。

关键词: 高光谱图像; 分数域信息提取; 特征提取; 异常检测; 高光谱图像分类; 多源遥感

中图分类号: TN911.73

文献标识码: A

文章编号: 0372-2112(2022)12-2874-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20221215

Recent Developments in Fractional Information Extraction Theory and Methods of Hyperspectral Image

ZHAO Xu-dong, TAO Ran, LI Wei, ZHANG Meng-meng

(School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China)

Abstract: Hyperspectral sensing technology can acquire spectral, spatial, radiation and other information synchronously, which provides the multi-scale, multi-angle, and multi-dimensional features of land covers. However, there are significant challenges in hyperspectral information extraction, e.g., spectral uncertainty, insufficient utilization of spatial information, and incomplete representation of collaborative information, resulting in poor information extraction and scene interpretation. The applications of hyperspectral interpretation, e.g., earth observation, requires multi-domain information extraction theories and methods to breakthrough these problems. In this survey, we firstly present the existing methods for hyperspectral information extraction and their main problems, and then introduce the fractional information extraction theory and methods of hyperspectral image, which consists of spectral dimension, spatial-spectral dimension, and collaborative dimension. Then, the main theories and applications are introduced, including spectral information adjustment, spatial-spectral information enhancement, and information fusion and transferring of multisource remote sensing data. For spectral dimension, the spectral uncertainty phenomenon makes it difficult to distinguish small targets from complex backgrounds. Focusing on this problem, the fractional-domain spectral information extraction method can improve the performance of hyper-

spectral anomaly detection. For spatial dimension, the complex spatial distribution of hyperspectral scenes and the lack of labeled samples make the scene interpretation challenging. Focusing on this problem, the fractional-domain spatial-spectral feature extraction methods can effectively generate more discriminative training features and improve the diversity of training sets, which contribute to handling small sample size problems. For the collaborative dimension, the fractional-domain multi-source feature extraction and fusion method can realize the joint use of multi-source and multi-domain features, and achieve high-precision classification. Finally, this survey points out the challenges and development trends of fractional information extraction theory for hyperspectral images. To breakthrough the limitations of hyperspectral data, e.g., high-dimension and low-resolution, it is important to improve the data quality at data- and feature-level. To solve the problem of unavailable training samples, transfer learning techniques are in need to fully exploit the spectral, spatial and collaborative information of the massive unlabeled data in hyperspectral remote sensing images. Targeting the global-scale earth observation by remote sensing, focusing on the condition when some modalities are missing, researches on domain generation and cross-scene classification are in need.

Key words: hyperspectral image; fractional information extraction; feature extraction; anomaly detection; hyperspectral classification; multisource remote sensing

1 引言

高光谱传感技术具有光谱、空间、辐射等信息同步获取优势,促使地物描述呈现多尺度、多角度、多维度的新特性.基于高光谱图像实施信息精确提取及解析,是建设高精度空间信息网络与先进对地观测系统等国家战略应用的核心需求.我国在《国家民用空间基础设施中长期发展规划(2015—2025)》中明确提出发展高光谱观测技术.2019年欧盟委员会发布的《面向未来的100项重大创新突破》中面向未来的100项颠覆性技术创新,高光谱技术位列第八.随着遥感技术与信息科技近年来的巨大发展,高光谱图像处理与智能解译分析技术成功应用于国家建设、社会发展与生活中的方方面面.从航天遥感、军事探测到智慧城市建设、生物医学研究等各个领域,高光谱图像智能解译技术极大地促进了行业的发展.

高光谱数据蕴含着光谱信息、空间信息和联合其他传感源获取的协同信息^[1].

首先,在高光谱数据的光谱信息方面,高光谱数据因其诊断性光谱特征在单像素侦测任务中应用广泛,可根据目标与背景的辨识性光谱特征揭露伪装目标^[2].但在成像距离较远的情况下目标场景的空间分辨率较低,导致依靠空间信息难以揭露伪装目标,只存在点目标的光谱信息可以利用.同时,由于高光谱像元采集过程存在噪声干扰,地物成分存在差异等因素,高光谱数据中产生光谱异变问题及不同材料的光谱混叠现象,加大了目标解译的难度.此外,由于被动遥感的缺点,大气环境、传感器、各种物理或化学效应等环境因素均可导致真实高光谱数据场景中的光谱异变.同类目标的光谱受周边地物成分影响,呈现不同的光谱特征,即“同物异谱”现象.而异常的目标由于成像条件限制,易淹没于点目标周围的背景像素中,光谱难以区分,即“异物同谱”现象.这两种光谱不确定性现象增大了点

目标的识别难度.因此,仅仅依靠原始高光谱数据的像素点光谱特征难以实现异常目标检测的目标和应用^[3].为了缩小同类地物光谱特征之间的差异,增大目标与背景光谱特征之间的区分度,有必要扩充目标的光谱特征,从多域信息提取的角度增加目标的有效光谱信息,进而解决原信号域中光谱信号的混叠问题.

其次,在高光谱图像空间光谱联合信息方面,城市、湿地等大面积地物监测与分类任务通常需要给定一定数量的地物标签样本.但在样本获取过程中需要大量具备专业地物辨识能力的人工考察,耗费大量的时间.由于实际时间和人工成本的制约,标注的样本往往数量较少,可靠性较差,空间分布不均匀.因此,在高光谱地物分类等解译任务中,可以获取到的具备精准光谱与空间特征的数据样本是十分有限的.在标注的样本有限的情况下,仅仅依靠少量样本的光谱特征难以进行精准的地物分类任务,空间上的邻接性质也难以得到良好的利用.为了利用复杂场景中珍贵的带标注样本信息,同时利用大量未标注数据之间的关联性,需要充分利用高光谱数据的空间光谱联合信息^[4].同时,在带有复杂空域面目标信息的分类任务中,场景存在大量细碎边界,容易出现错分漏分情况,需要扩充标注样本的邻域和全局相关特征空间,实现高光谱数据在光谱特征不足、标注样本数量少情况下的地物精准分类.

最后,高光谱联合激光雷达等传感手段进行协同工作,可实现目标的三元多视角观测,是提升林地资源调查等多源遥感数据解译任务效果的主要方式^[5].但在实际应用中,不同传感器的成像机理和参数存在差异,单一传感源只能表征目标地物的部分特征.而高光谱等被动成像方式容易受到云雾、光照等环境因素影响,因此难以全面表征地物.虽然这种多源数据之间空间、光谱、高程信息的互补性有利于地物的完整表达,但不同传感源之间的差异大也会导致多个传感源之间

的信息冗余和信息不一致等问题^[6]。例如,在云雾遮挡情况下的高光谱数据丧失了同类地物的光谱辨识性,而激光雷达的高程数据与空间形态特征则得到完整保留。但是单通道的激光雷达数字表面模型在相似高度不同材质的区域内难以辨识地物类别。因此,针对单传感源表达特征不完整、场景中存在材质相同高程形态不同的情况,需要联合利用空间、光谱、高程等多传感源特征,实现树木等三维地物的完整辨识与复杂空间环境条件下的精准分类。

面对上述挑战,本文综述了高光谱图像分数域信息提取理论与方法进展。首先给出了现有的高光谱图像信息提取方法,然后从光谱维、空谱维、协同维三方面给出了高光谱图像多维度域信息提取理论与方法体系。随后从光谱维精确控制、空谱维强化感知、协同维信息联合三方面出发分别总结了关键理论与应用。最后,本文指出了未来高光谱图像分数域信息提取理论与方法面临的挑战和发展趋势。

2 研究现状分析

高光谱图像具有诊断性光谱特性,基于高光谱图像的单个像元,可以获取特定像素的反射率信息,绘制一元光谱信息曲线图。但高光谱数据一方面存在“同物异谱”“异物同谱”的光谱不确定性问题,另一方面又因具有较大的体量而存在冗余。因此,直接利用原始的高光谱数据特征存在种种问题,需要对光谱特征进行提取和设计。现有的高光谱数据光谱信息提取方法主要包括两大类,即传统特征设计方法和深度学习方^[7]。

然而在光谱信息提取方面,高光谱数据采集及处理过程易引入干扰,使高光谱图像出现光谱不确定现象,现有的光谱信息利用形式存在缺陷。统计学习类的光谱特征提取方法,采用高斯假设等先验信息,存在分布不稳定可分性差的问题^[8]。深度网络类的光谱特征提取方法是数据驱动的,在数据量不足的情况下,更容易受到光谱不确定性问题影响而提取到不准确的信息^[9]。以上述两类方法为代表的现有光谱特征提取方法只在原信号域和简单的变换域分析信号,异常信号与背景信号差异度低,难以从多个变换域分析遥感数据的特征,需要采用分数域光谱信息提取方法研究多样化光谱信息表征,提升方法检测与识别精度。

高光谱图像在具有获取特定像素反射率信息的光谱提取能力的同时,也具备空间信息捕获能力。在特定波段内,不同像元在空间维度上联合,可以形成具备丰富纹理信息的空间图像。结合高光谱图像的光谱信息,该类数据具备空间光谱“两元合一”特性^[10]。传感器可以从相邻像素中获取邻域信息,且场景中出现的同质结构通常比像素的大小要大。例如,农业场景中给定的

像素代表玉米,则其相邻像素属于玉米地的概率很高。这种空间上下文信息有助于准确地进行场景解读。因此,为了提高解译精度,光谱、空间联合信息的提取十分重要,即提取其像素本身的光谱值(光谱信息)和邻域中提取的信息(空间信息)。现有的高光谱数据光谱空间信息提取方法主要包括两大类,即传统特征设计方法和深度学习方^[11]。

然而在空谱联合信息提取方面,空间信息的利用有助于改善数据解析效果,但空谱融合感知与光谱端元精确控制存在矛盾性,需要在保证光谱端元判读力的同时提升高光谱空间利用率。统计学习类的空谱特征提取方法,如变分模型等,存在空间先验假设固定、难以表征复杂空间环境的问题^[11]。深度网络类的空谱特征提取方法仍然受数据驱动影响,样本依赖性强,纹理信息表征难^[12]。现有的空谱特征提取方法使用空间特征和非线性训练结果,其网络解译性能严重依赖训练样本数量和特征维度,需要采用空间-变换域协同方法扩充样本的特征空间,充分利用邻域空间信息、增强广义样本。

虽然结合高光谱图像空间光谱“两元合一”的特性,可以揭示地物的细微差异,但单源遥感数据在物质检测方面存在显著差异和个体局限性,需要从其他传感器平台挖掘有用的补充信息,构建多源遥感协同表达。高光谱联合激光雷达等传感手段,可实现目标的光谱、空间、高程三元多视角观测,以此克服单源数据的不确定性和不可靠性^[13]。高光谱为主的多源遥感协同特征提取方法按照信息协同的层级,可分为像素级融合解译、特征级融合解译与决策级融合解译^[14]。

然而现有的多源协同信息提取方法受标注样本数量制约,难以有效传递异质信息。基于非线性决策的多源遥感融合解译方法,存在多源互补性利用差的问题。深度网络类的空谱特征提取方法由于单源数据的冗余和多源数据的异质性限制,容易遇到过拟合问题,进而导致在实际应用中分类器的效果不佳。现有的多源协同特征提取方法同样依赖充足的特征信息和数据源的边界信息,需要采用分数变换域方法扩充单传感源样本特征空间,实现多源特征的变换域转化。

综合分析图1所示的光谱维、空谱维、多源信息协同维三个方面进行高光谱图像信息处理的代表性方法,高光谱图像信息提取存在光谱维诊断信息不确定、空间维信息利用不充分和协同维异质特征描述不全面等问题,严重制约了其信息感知与解译的效果。常规信息提取方式难以满足多层次处理需求,发展多域信息提取理论与方法成为高光谱数据信息利用的关键。

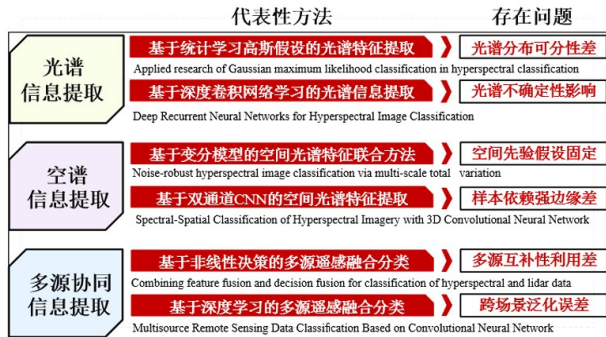


图1 高光谱图像信息提取代表性方法

3 高光谱图像分数域信息提取理论体系

对判别特征进行精准感知是获取高光谱图像中目标本质属性的前提. 针对高光谱图像中光谱诊断信息不确定、空域信息利用不充分、三维信息表征不全面的问题, 本文从高光谱数据的光谱信息调控机制、空谱信息感知规律、协同信息归约机理三个方面开展了系统研究, 建立了高光谱图像分数域信息感知模型, 形成了高光谱多维度特征协同感知方法体系, 在军事目标检测、滨海湿地制图、森林资源监测领域开展应用推广, 支撑了我国高光谱对地观测技术领域的创新发展. 高光谱图像分数域信息提取方法的三个方面总体结构和相互关系具体如图2所示.

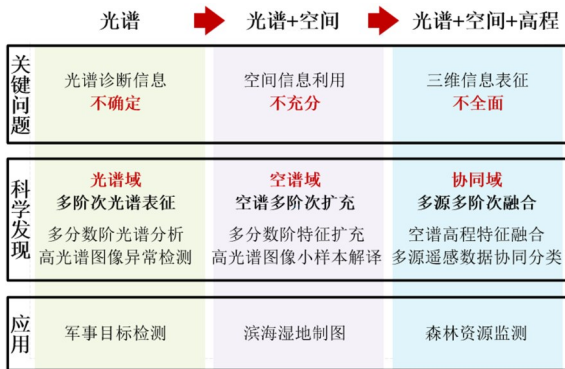


图2 高光谱图像分数域信息提取理论体系

4 分数域光谱特征提取

针对传统光学难以检测的军事伪装隐藏目标, 高光谱图像的诊断性光谱特征对不同材质目标检测识别独具优势. 然而, 受光照、气候条件、拍摄环境等因素影响, 高光谱图像存在严重的“同物异谱”现象, 即光谱不确定性. 传统方法依赖光谱的统计信息, 在目标与背景间的区分明显时性能较好, 但对微弱点目标信号, 目标信息淹没于噪声与背景中, 难以获取满意的检测效果. 针对微弱点目标与复杂背景区分的挑战性问题的挑战性问题, 基于分数域光谱信号表征实施高光谱异常检测的方法^[15]被提出. 该方法通过分数傅里叶变换域中光谱域辨识性

特征分析, 阐明了目标类与背景类的分布调控对光谱信息确定性的影响机制.

4.1 分数域光谱特征提取理论

如图3所示, 分数域光谱特征表现为光谱维反射信息的多分数变换域分析. 高光谱图像单个像元的反射率信息可以绘制为一元光谱信息曲线图, 该曲线具有极强的物质属性鉴别能力. 但由于空间分辨率的缺失, 高光谱单个像元及其邻域像元的光谱曲线经常互相影响. 在面临光谱不确定现象时, 不同类别但空间相邻地物的光谱曲线在原信号域产生混叠, 因此导致大规模观测场景中存在的异常目标淹没于复杂背景端元中. 经过其他变换域分析方法, 如离散傅里叶变换、小波变换等方法^[16, 17], 仍然难以有区分地分离异常目标及其背景. 因此在变换域中, 信号仍然处于混叠状态, 即频域耦合状态. 而在介于时域和频域间的分数傅里叶变换域中, 异常信号与背景像素的光谱曲线分布随分数傅里叶变换阶次的增大呈现出不同的变化率. 若待测像素中包含异常目标信息, 其光谱分布曲线将在特定分数阶次内显著区别于背景像元. 与异常目标相反的, 场景中大量的背景像元由于光谱特征与场景平均值相似而显示出相似的分域光谱分布^[18]. 综合以上异常目标与背景光谱的特点, 在分数傅里叶变换域中进行光谱异常目标检测具有显著的优势.




图3 高光谱数据的分数域光谱特征分析

为了提高在变换域目标与背景的可分性, 笔者提出基于分数傅里叶变换的高光谱图像异常检测方法. 在分数傅里叶变换的多维联合分析理论指导下, 将本征光谱信息变换至介于时域和频域间的分数域, 为高光谱图像的光谱域分析开辟新途径.

4.2 基于分数域光谱特征分析的高光谱图像异常检测

高光谱异常检测方法不需要任何关于目标的先验信息, 通常可应用于军事目标检测与紧急救援等任务中^[19-21]. 经典的高光谱检测方法有基于观测像素点与背景之间的 Mahalanobis 距离的 Reed-Xiaoli (Reed-Xiaoli, RX) 检测方法^[22, 23], 它可以简单、迅速地实现异常检测, 因而成为异常检测中的基准方法. 基于

RX 检测方法,局部RX和全局RX两种扩展方法被提出以应对不同背景条件下的异常检测任务^[24,25],局部RX根据预定义的局部窗口估计背景统计,而全局RX使用整个图像进行背景建模.随后,研究者们提出多种代表性异常检测方法以提升异常检测性能,包括低秩稀疏表征的异常检测^[26-28]和基于图的像素选择方法^[29,30]等.

然而,上述相关方法都是基于高光谱数据的原始反射光谱进行异常检测的.这样在光谱出现“同物异谱”或“异物同谱”等光谱不确定性现象时,异常检测效果就会受到制约.而频域变换则具有噪声抑制和频谱去相关等优点.因此,诸如小波变换和曲波变换等变换域方法已被应用于高光谱图像的压缩和分类等任务中^[31,32].对于高光谱遥感图像,卫星或机载传感器的成像过程受许多因素的影响,如大气条件、物质表面的变化等,这些噪声因素可能是非平稳的.而分数傅里叶变换比传统的变换域方法能更好地处理非平稳信号^[33,34],这促使我们尝试使用分数傅里叶变换进行高光谱异常检测.

因此,针对如何准确区分微弱点目标与复杂背景的挑战性问题,笔者提出了基于分数域光谱信号表征实施高光谱异常检测的方法.首先采用分数傅里叶变换,将本征光谱信息变换至介于时域和频域间的分数域信号表征,以此增大弱目标样本与背景端元的区分度.然后使用分数傅里叶熵值(Fractional Fourier Entropy, FrFE)^[35]来自动确定最佳分数阶次,从而在最优分数傅里叶变换域内进行高光谱异常检测.

5 分数域空间特征提取

在对地观测任务中,地物空间分布不均衡导致高光谱图像边界结构复杂,空谱维联合特征能够准确描述目标边界信息.目前深度学习架构可以实现对高光谱数据驱动性、表征性、分层递阶性的特征学习,提取更多抽象和不变特征,进而增大同类样本之间的相关性和异类样本之间的差异性^[36].然而,将深度学习应用到高光谱图像空谱特征提取中存在新的挑战,其模型训练过程需要大量的有效标注数据而高光谱图像标注样本少^[37],且现有的深度卷积神经网络基于固定尺寸的空间图像块卷积^[38],忽略了变换域特征的提取,适用于具有平稳纹理的数据,而不适用于具有非平稳纹理的数据.传统的小波变换、Gabor变换^[39]本质上是傅里叶变换域中的线性平移不变带通滤波器,难以处理Chirplet原子等图像组成成分.针对小样本情况下神经网络充分训练难的问题,基于分数域空谱特征扩充的高光谱地物分类方法被提出^[40].该方法通过多分数傅里叶变换域中训练样本空间特征的扩充,揭

示了分数域中训练样本空间特征强化对空谱信息感知效能的作用规律.

5.1 分数域空间特征提取理论

分数域空间特征提取的提出,一方面是为了扩充少量高光谱数据的样本特征,另一方面是为了处理图像中的Chirplet原子^[41],例如因成像原因产生的牛顿环和二次相位的条纹图案等.因此需要设计具备提取图4所示的分数域空间特征的深度网络,逐波段分析高光谱图像的二维空间信息.分数域空间特征结合分数域光谱特征的分析,可形成光谱空间二元合一的分数域信息感知方法.其中多阶次分数傅里叶变换可以有效地拓展高光谱图像的多尺度空间特征,增强对邻域范围内Chirplet原子的感知能力.

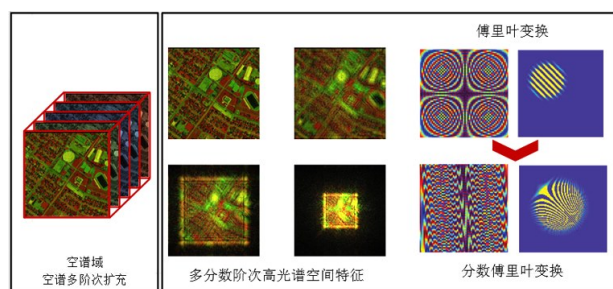


图4 高光谱数据的分数域空间特征分析

为了在保证光谱端元判读力的同时提高空间利用率,笔者采用分数域空间-变换域协同方法扩充样本特征空间,充分利用邻域空间信息来增强广义样本信息,从高光谱数据的空间光谱特征结合方面有效地综合提取全局和局部的上下文信息.

5.2 基于分数域空谱深度特征提取的高光谱地物分类

当前傅里叶变换以及分数傅里叶变换方法已被应用于遥感图像分析.例如利用离散傅里叶变换估计合成孔径雷达图像中的线性调频参数^[42].针对单视复杂SAR图像的分类问题,一种基于傅里叶变换的特征提取方法被提出^[43].此外,二维离散傅里叶变换也被用于多光谱图像的锐化任务^[44].在文献[45]中,研究者提出了一种用分数域相关函数进行高光谱目标检测的方法,分数傅里叶变换被用来度量待测像素与已知目标像素之间的相似度.文献[46]提出了傅里叶Transformer网络(Fourier Image Transformer, FIT),使用简单的线性变换代替自注意力子层,从而加速编码器架构.在FIT中,编码器的实际作用为傅里叶变换和傅里叶逆变换的交替使用.由于频域中的乘法意味着空间域中的卷积操作,因此FIT的实际作用为乘法和卷积操作的交替使用.虽然FIT可以更有效地捕获全局上下文特征,但这种空域和频域之间的交替会导致信息冗余与

部分信息丢失的问题。

空谱融合感知与光谱端元精确控制存在矛盾,现有的空谱信息提取方法难以在保证光谱端元判读力的同时提高高光谱空间利用率,采用分数域空间-变换域协同方法扩充样本特征空间,可以充分利用邻域空间信息来增强广义样本信息。基于视觉注意力机制网络,笔者从高光谱数据的空间光谱特征结合方面提出分数傅里叶 Transformer(Fractional Fourier Image Transformer, FrIT)网络^[40],以有效地综合提取全局和局部的上下文信息。在提出的 FrIT 网络中,首先利用基于卷积层的局部特征提取器来采集数据的局部上下文信息,然后,提出多分数域中的 FrIT,扩充用于深度学习的训练样本特征空间,提升地物空间邻域特征和全局空间光谱关联特性的类别辨识度,从而增强不同地面覆盖类别信息之间的可分性。相比于经典视觉注意力网络^[47],FrIT 能够加速架构并减少网络子层之间的信息丢失。

6 分数域协同特征提取

高光谱数据具备“空谱合一”的物质精准鉴别能力,但难以感知目标高程信息。当前结合激光雷达数据源的多源协同架构可以一定程度上实现高光谱多源数据的互补协同。然而,由于多源遥感探测方式不同,数据表征存在显著差异,基于异构信息源开展高光谱多源协同特征提取面临困难。现有方法缺乏信息源转化归约,在多源异质特征提取与传递协同过程中,存在地物三维信息表征不全面的问题。针对上述问题,基于分数域深度特征提取与融合的多源遥感图像分类被提出^[48,49]。该方法通过多分数域中高光谱数据空间光谱联合特征的扩充与激光雷达单通道数据的维度转换,研究了多源遥感数据的分数域联合方法及其对协同信息归约特性的传递转化机理。

6.1 分数域协同特征提取理论

分数域协同特征提取方法分别针对高光谱与激光雷达数据设计多阶次分数信息提取网络。针对高光谱数据丰富的光谱空间信息,采用前述光谱空间分数特征的采集与联合,在多个分数傅里叶变换域中形成如图 5 所示的多阶次分数域高光谱立方体数据。在保持原有空谱特征的同时,扩充了高光谱数据的分数域多维度特征。另外,针对激光雷达所表征的空间结构信息,采用多阶次分数傅里叶变换增加数据的维度,不仅从特征空间维度上匹配了激光雷达数据与高光谱数据,还整合了激光雷达数据所描述的高程信息与拓扑结构信息。

为了削弱多源遥感数据的异质性导致其观测表征不一致的影响,针对现有方法受标注样本数量制

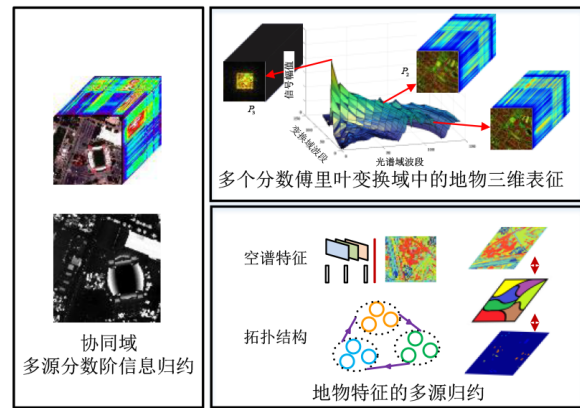


图 5 高光谱数据的分数域协同特征分析

约,难以有效传递异质信息的问题,本文采用分数变换域协同方法扩充多个传感源的样本特征空间,实现多源特征的变换域转化,从高光谱数据与激光雷达数据的空间、光谱、高程特征结合方面提出一种基于分数域深度卷积特征提取与融合的多源遥感图像分类方法。

6.2 基于分数域深度特征提取与融合的多源遥感图像分类

随着对地观测技术的飞速发展,从飞机、卫星、无人机等不同平台获取的多模态数据越来越多,用于不同的遥感应用^[49,50]。使用多传感器平台的遥感已系统地应用于监测土地利用和土地覆盖分类以及环境变化,例如城市蔓延和土地退化^[51-53]。然而,大多数研究只考虑一种成像模式,例如 RGB 图像、高光谱图像、激光雷达图像或红外图像。其中高光谱图像可以为潜在的材料识别提供详细的光谱信息^[54],激光雷达数据则可以在全天时全天候条件下提供研究区域的高程信息^[55,56]。多源遥感中的重要任务之一是多传感器图像的特征提取问题。然而简单的特征拼接或堆叠操作极易受到冗余信息堆叠的影响,有效地融合高光谱和激光雷达信息、减少冗余细节并保留鉴别性特征仍然具有挑战性^[57,58]。同时,多源异质特征往往在所表征的地物特性与特征维度上都存在差异。如何应对此类多源遥感数据的观测表征不一致问题仍具挑战性。

针对现有方法受标注样本数量制约,难以有效传递异质信息的问题,笔者采用分数变换域协同方法扩充单传感源样本特征空间,实现多源特征的变换域转化。提出多传感源空间、光谱、高程信息的特征融合方法,进一步联合多个分数 Gabor 变换域中的纹理和语义特征,提出了一种分数 Gabor 卷积神经网络^[59]。提出的分数 Gabor 卷积神经网络使用 Octave 卷积层将多源遥感数据分解为低频和高频分量以减少冗余信息,随后融合传感源以保留判别特征。然后提

出分数 Gabor 卷积层用于提取多尺度、多方向和多线性调频率的特征以增强多源分类方法在小样本、高噪声、中低分辨条件下的鲁棒性,提升区域纹理特征的分析能力,从而增大多源异质数据中不同地面覆盖类别信息的特征分离度,最终实现高精度的多源遥感地物分类。

7 方法总结与发展趋势

近年来高光谱数据处理技术获得巨大发展,多域信息提取方法突破了单域信息提取的局限性,提升了数据处理的实时性和有效性。但受当前国产遥感数据质量制约,有效的特征提取仍是高光谱图像智能解译及应用发展所需要解决的问题。本文从多域特征提取的视角出发,在光谱维、空谱维和协同维特征提取方面进行了深入研究,提出了高光谱图像的多域特征分析理论与方法。在光谱维,高光谱图像光谱信息提取易受到“同物异谱”或“异物同谱”的光谱不确定性现象影响而难以准确区分微弱目标与复杂背景,针对这一问题,分数域光谱信号表征方法可提升光谱域辨识性能,实施高光谱异常检测。在空谱维,高光谱场景中地物空间分布不均衡导致边界与纹理结构复杂,对应标签样本不足导致场景解译困难,针对这一问题,分数域空谱特征提取方法在有效训练集合扩充的同时提升网络学习的多样性,实施小样本情况下的场景解译。在协同维,单源高光谱数据不能表征高程信息,高光谱与其他传感源存在异质性,导致地物三维信息表征不全面,针对这一问题,分数域多源协同特征提取与融合方法可实现多源多域特征联合,完成高精度地物分类。分数域多域特征分析理论体系为高光谱图像光谱、空间等多域特征的提取做出了创新性贡献。

但在广域大场景高光谱特征分析应用中仍存在低质海量数据的处理难题,如何提升算法模型实时性,进行高速的数据质量提升和特征转化识别,仍是高光谱图像多域信息处理所需要解决的问题。针对实际应用中泛场景、实时化需求,未来将重点探索如何高效快速地利用空、地基高光谱实时平台实现数据解译,推广高光谱技术在无人机、无人车等平台的应用,包括以下几个方面:

(1) 针对高光谱数据体量大、分辨率较差等局限性,开展数据、特征层结合的质量提升方法研究;

(2) 针对训练样本缺失问题,通过深度特征迁移学习技术,充分挖掘高光谱遥感图像中海量无标签数据的多维度光谱、空间、协同信息,开展基于域适应、域生成的高光谱图像跨场景解译任务研究;

(3) 面向广域空天遥感对地观测需求,跨场景任务

中存在数据偏移与异变及模态缺失问题,需要模态缺失情况下的深度样本生成、分数特征匹配扩充、多源跨场景分类方法研究。

参考文献

- [1] LANDGREBE D. Hyperspectral image data analysis[J]. IEEE Signal Processing Magazine, 2002, 19(1): 17-28.
- [2] 童庆禧, 张兵, 郑兰芬. 高光谱遥感: 原理、技术与应用[M]. 北京: 高等教育出版社, 2006.
TONG Q X, ZHANG B, ZHENG L F. Hyperspectral Remote Sensing[M]. Beijing: Higher Education Press, 2006. (in Chinese)
- [3] 张兵, 高连如. 高光谱图像分类与目标探测[M]. 北京: 科学出版社, 2011: 85-101.
ZHANG B, GAO L R. Hyperspectral Image Classification and Target Detection[M]. Beijing: Science Press, 2011: 85-101. (in Chinese)
- [4] CHEN C, LI W, SU H J, et al. Spectral-spatial classification of hyperspectral image based on kernel extreme learning machine[J]. Remote Sensing, 2014, 6(6): 5795-5814.
- [5] DALPONTE M, BRUZZONE L, GIANELLE D. Fusion of hyperspectral and LIDAR remote sensing data for classification of complex forest areas[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(5): 1416-1427.
- [6] XU X D, LI W, RAN Q, et al. Multisource remote sensing data classification based on convolutional neural network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(2): 937-949.
- [7] RAVIKANTH L, JAYAS D S, WHITE N D G, et al. Extraction of spectral information from hyperspectral data and application of hyperspectral imaging for food and agricultural products[J]. Food and Bioprocess Technology, 2017, 10(1): 1-33.
- [8] CAMPS-VALLS G, TUIA D, BRUZZONE L, et al. Advances in hyperspectral image classification: Earth monitoring with statistical learning methods[J]. IEEE Signal Processing Magazine, 2014, 31(1): 45-54.
- [9] DURKEE N, ASH J N, MEOLA J. Longwave infrared hyperspectral emissivity retrieval with robustness to spectral uncertainty[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-13.
- [10] TAO C, PAN H B, LI Y S, et al. Unsupervised spectral-spatial feature learning with stacked sparse autoencoder for hyperspectral imagery classification[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(12): 2438-

- 2442.
- [11] CHEN C, LI W, SU H J, et al. Spectral-spatial classification of hyperspectral image based on kernel extreme learning machine[J]. *Remote Sensing*, 2014, 6(6): 5795-5814.
- [12] MEI X G, PAN E T, MA Y, et al. Spectral-spatial attention networks for hyperspectral image classification[J]. *Remote Sensing*, 2019, 11(8): 963.
- [13] HANG R L, LI Z, GHAMISI P, et al. Classification of hyperspectral and LiDAR data using coupled CNNs[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(7): 4939-4950.
- [14] EHLERS M, KLONUS S, JOHAN ÅSTRAND P, et al. Multi-sensor image fusion for pansharpening in remote sensing[J]. *International Journal of Image and Data Fusion*, 2010, 1(1): 25-45.
- [15] TAO R, ZHAO X D, LI W, et al. Hyperspectral anomaly detection by fractional Fourier entropy[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(12): 4920-4929.
- [16] WINOGRAD S. On computing the discrete Fourier transform[J]. *Mathematics of Computation*, 1978, 32(141): 175-199.
- [17] TANG Y Y, LU Y, YUAN H L. Hyperspectral image classification based on three-dimensional scattering wavelet transform[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(5): 2467-2480.
- [18] LI W, DU Q. Collaborative representation for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(3): 1463-1474.
- [19] MEI S H, YUAN X, JI J Y, et al. Hyperspectral image spatial super-resolution via 3D full convolutional neural network[J]. *Remote Sensing*, 2017, 9(11): 1139.
- [20] DU B, ZHANG L P. A discriminative metric learning based anomaly detection method[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(11): 6844-6857.
- [21] LI W, DU Q. A survey on representation-based classification and detection in hyperspectral remote sensing imagery[J]. *Pattern Recognition Letters*, 2016, 83: 115-123.
- [22] REED I S, YU X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1990, 38(10): 1760-1770.
- [23] CHANG C I, CHIANG S S. Anomaly detection and classification for hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2002, 40(6): 1314-1325.
- [24] LI W, DU Q. Decision fusion for dual-window-based hyperspectral anomaly detector[J]. *Journal of Applied Remote Sensing*, 2015, 9(1): 097297.
- [25] LIU W M, CHANG C I. Multiple-window anomaly detection for hyperspectral imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(2): 644-658.
- [26] XU Y, WU Z B, LI J, et al. Anomaly detection in hyperspectral images based on low-rank and sparse representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(4): 1990-2000.
- [27] SUN W W, TIAN L, XU Y, et al. A randomized subspace learning based anomaly detector for hyperspectral imagery[J]. *Remote Sensing*, 2018, 10(3): 417.
- [28] SUN W W, YANG G, LI J L, et al. Randomized subspace-based robust principal component analysis for hyperspectral anomaly detection[J]. *Journal of Applied Remote Sensing*, 2018, 12(1): 015015.
- [29] YUAN Y, MA D D, WANG Q. Hyperspectral anomaly detection by graph pixel selection[J]. *IEEE Transactions on Cybernetics*, 2016, 46(12): 3123-3134.
- [30] SUN W W, DU Q. Graph-regularized fast and robust principal component analysis for hyperspectral band selection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(6): 3185-3195.
- [31] AMRANI N, SERRA-SAGRISTÀ J, LAPARRA V, et al. Regression wavelet analysis for lossless coding of remote-sensing data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(9): 5616-5627.
- [32] QIAO T, REN J C, WANG Z, et al. Effective denoising and classification of hyperspectral images using curvelet transform and singular spectrum analysis[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(1): 119-133.
- [33] CANDAN C, KUTAY M A, OZAKTAS H M. The discrete fractional Fourier transform[J]. *IEEE Transactions on Signal Processing*, 2000, 48(5): 1329-1337.
- [34] CHEN S, ZHANG S N, ZHAO H C, et al. A new chirp scaling algorithm for highly squinted missile-borne SAR based on FrFT[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(8): 3977-3987.

- [35] WANG S H, ZHANG Y D, YANG X J, et al. Pathological brain detection by a novel image feature—Fractional Fourier entropy[J]. *Entropy*, 2015, 17(12): 8278-8296.
- [36] LIAO W Z, VAN COILLIE F, GAO L R, et al. Deep learning for fusion of APEX hyperspectral and full-waveform LiDAR remote sensing data for tree species mapping [J]. *IEEE Access*, 2018, 6: 68716-68729.
- [37] MATASCI G, VOLPI M, KANEVSKI M, et al. Semisupervised transfer component analysis for domain adaptation in remote sensing image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(7): 3550-3564.
- [38] YU S Q, JIA S, XU C Y. Convolutional neural networks for hyperspectral image classification[J]. *Neurocomputing*, 2017, 219: 88-98.
- [39] LUAN S Z, CHEN C, ZHANG B C, et al. Gabor convolutional networks[J]. *IEEE Transactions on Image Processing*, 2018, 27(9): 4357-4366.
- [40] ZHAO X, ZHANG M, TAO R, et al. Fractional Fourier image transformer for hyperspectral and LiDAR data classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022: 1-13.
- [41] SHI J, ZHAO Y N, XIANG W, et al. Deep scattering network with fractional wavelet transform[J]. *IEEE Transactions on Signal Processing*, 2021, 69: 4740-4757.
- [42] CAMPBELL J B, PÉREZ F, WANG Q, et al. Remote vibration estimation using displaced-phase-center antenna SAR for strong clutter environments[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(5): 2735-2747.
- [43] WANG Y, CHEN X F. 3-D interferometric inverse synthetic aperture radar imaging of ship target with complex motion[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(7): 3693-3708.
- [44] SAXENA N, SHARMA K K. Pansharpening scheme using filtering in two-dimensional discrete fractional Fourier transform[J]. *IET Image Processing*, 2018, 12(6): 1013-1019.
- [45] WANG Q, GUO Q, ZHOU J Y, et al. Nonlinear joint fractional Fourier transform correlation for target detection in hyperspectral image[J]. *Optics & Laser Technology*, 2012, 44(6): 1897-1904.
- [46] LEE-THORP J, AINSLIE J, ECKSTEIN I, et al. FNnet: Mixing tokens with Fourier transforms[EB/OL]. (2021-05-09)[2022-10]. <https://arxiv.org/abs/2105.03824>.
- [47] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[EB/OL]. (2020-10-22)[2022-10]. <https://arxiv.org/abs/2010.11929>.
- [48] ZHAO X D, TAO R, LI W, et al. Joint classification of hyperspectral and LiDAR data using hierarchical random walk and deep CNN architecture[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(10): 7355-7370.
- [49] ZHANG M M, LI W, DU Q. Collaborative classification of hyperspectral and visible images with convolutional neural network[J]. *Journal of Applied Remote Sensing*, 2017, 11(4): 042607.
- [50] SCHMITT M, ZHU X X. Data Fusion and remote sensing: An ever-growing relationship[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2016, 4(4): 6-23.
- [51] KHODADADZADEH M, LI J, PRASAD S, et al. Fusion of hyperspectral and LiDAR remote sensing data using multiple feature learning[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2971-2983.
- [52] HÄNSCH R, HELLWICH O. Fusion of multispectral LiDAR, hyperspectral, and RGB data for urban land cover classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(2): 366-370.
- [53] MATSUKI T, YOKOYA N, IWASAKI A. Hyperspectral tree species classification of Japanese complex mixed forest with the aid of LiDAR data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(5): 2177-2187.
- [54] KHODADADZADEH M, CUARTERO A, LI J, et al. Fusion of hyperspectral and LiDAR data using generalized composite kernels: A case study in Extremadura, Spain [C]//*IEEE International Geoscience and Remote Sensing Symposium*. Milan: IEEE, 2015: 61-64.
- [55] MALLETT C, BRETAR F. Full-waveform topographic lidar: State-of-the-art[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2009, 64(1): 1-16.
- [56] JUNG J, PASOLLI E, PRASAD S, et al. A framework for land cover classification using discrete return LiDAR data: Adopting pseudo-waveform and hierarchical segmentation[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(2): 491-502.
- [57] LIAO W Z, BELLENS R, PIŽURICA A, et al. Graph-

based feature fusion of hyperspectral and LiDAR remote sensing data using morphological features[C]//IEEE International Geoscience and Remote Sensing Symposium. Victoria: IEEE, 2013: 4942-4945.

- [58] LIAO W Z, BELLENS R, PIŽURICA A, et al. Combining feature fusion and decision fusion for classification of hyperspectral and LiDAR data[C]//IEEE Geoscience and Remote Sensing Symposium. Quebec City: IEEE, 2014: 1241-1244.
- [59] ZHAO X D, TAO R, LI W, et al. Fractional Gabor convolutional network for multisource remote sensing data classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-18.

作者简介



赵旭东 男,1993年10月出生于河北省张家口市.北京理工大学信息与电子学院博士研究生.主要研究方向为分数域信号处理.
E-mail: xudongzhao461@gmail.com



陶然(通讯作者) 男,1964年11月出生于安徽省芜湖市.现为北京理工大学信息与电子学院教授.主要研究方向为分数域信号与信息处理及其应用.
E-mail: rantao@bit.edu.cn



李伟 男,1985年2月出生于湖北省随州市.现为北京理工大学信息与电子学院教授.主要研究方向为高光谱图像处理.
E-mail: liw@bit.edu.cn



张蒙蒙 女,1994年6月出生于山东省济宁市.现为北京理工大学信息与电子学院副研究员.主要研究方向为高光谱图像处理.
E-mail: mengmengzhang@bit.edu.cn