

光谱解混技术及其应用研究进展

杨斌^{1*}, 王斌²

¹ 东华大学计算机科学与技术学院, 上海 201620;

² 复旦大学电磁波信息科学教育部重点实验室, 上海 200433

摘要 低空间分辨率和物质异质性等因素造成的图像混合像元问题,使像元级的数据处理和应用难以满足实际需求。光谱解混提取亚像元尺度上的端元和丰度信息,为现实应用的数据精细化定量分析提供技术支持。本文介绍了近些年光谱解混理论方法和应用的相关研究进展,包括线性与非线性混合模型作用,以及几何、正则优化和统计机器学习原理框架下的方法研究成果。此外,分析了光谱解混对分类等其他技术性能的改善作用以及该技术解决从遥感到医学等室内级应用问题的理论和实际价值。最后,总结了光谱解混技术与应用研究中的不足和构建二者协同发展的必要性。

关键词 图像处理; 成像光谱; 混合像元; 光谱解混; 遥感应用; 光谱分析与物质识别

中图分类号 TP751

文献标志码 A

doi: 10.3788/LOP202158.1600004

Research Advances of Spectral Unmixing Technology and Its Applications

Yang Bin^{1*}, Wang Bin²

¹ School of Computer Science and Technology, Donghua University, Shanghai 201620, China;

² Key Laboratory for Information Science of Electromagnetic Waves (MoE), Fudan University, Shanghai 200433, China

Abstract Factors such as low spatial resolution and material heterogeneity result in the issue of mixed pixels in images, which makes pixel-level data processing and applications unable to meet the practical requirements. Spectral unmixing extracts information of endmembers and abundances at the sub-pixel level and offers technical support for fine quantitative analysis of data in real applications. This paper introduces research advances of spectral unmixing theories, methods, and applications in recent years. Technical research results include linear and nonlinear mixture models, and methods under the principle frameworks of geometry, regularized optimization, and statistical machine learning. Moreover, improvements provided by spectral unmixing for other techniques such as classification, and theoretical and practical values of spectral unmixing in handling problems from remote sensing to indoor applications such as medical science are analyzed. Finally, drawbacks in spectral unmixing technical and application researches and the necessity of their synergistic development are summarized.

Key words image processing; imaging spectroscopy; mixed pixels; spectral unmixing; remote sensing applications; spectral analysis and material recognition

OCIS codes 100.4145; 100.2960; 280.4991; 330.6180

1 引言

图像用于可视化记录和存储事物的信息,尽可能准确而真实地呈现物质的本质特征是图像采集的核心主题。伴随多样传感器和数字信息化技术的发展,

形式多样的海量图像层出不穷,早已成为现代文明不可替代的数据媒介。光学图像采集中,各类物质对电磁辐射的吸收和反射响应特性实际随波长显著变化,形成独特的诊断性光谱特征,可揭示它们各自内在物化组分和表面形态结构等^[1-2]。相比图像空间分辨率

收稿日期: 2020-10-16; 修回日期: 2020-11-16; 录用日期: 2020-12-03

基金项目: 国家自然科学基金(61572133, 61971141, 62001098)、中央高校基本科研业务费专项资金(2232020D-33)

通信作者: *yangb19@dhu.edu.cn

提升对物质纹理细节的捕捉,光谱特征的丰富则给予了更精细的物质成分和性状识别前景。

多光谱成像传感器所采集的多光谱图像不仅具有传统图像红绿蓝三通道,还包含近红外和热红外等人眼不可见的光谱域波段数据。然而,多光谱图像依然只能采集少量波段上的离散光谱特征,通道波长间隔大,光谱分辨率较低。为满足高光谱分辨率的需求,高光谱图像采集有从可见光到热红外波长区间数百个窄波段上的详细物质光谱信息,每个像元都对应一条完整而连续的光谱曲线,整幅图像呈“图谱合一”的三维立方体结构。高光谱图像能捕捉到多光谱图像无法识别的、不同物质间微小的光谱差异,使利用物质的电磁波谱特性进行定量分析和研究成为可能,更因其丰富的光谱信息而具备解决光学图像混合像元问题的优势^[3-4]。过去数十年中,多、高光谱成像在对地遥感观测中得到了最为广泛和有效的应用^[5-9]。植被、水体、自然土壤与岩石和人工建筑等是地表主要的物质构成,密切相关生物资源和环境的变化以及人类生产活动的开展。但地物种类繁多、分布形式错综复杂、外界干扰较大等现实因素,严重制约着传统遥感技术对地物的正确识别和区分。多、高光谱遥感图像结合地物的空间与光谱域特征,给精细化的定量遥感观测与分析提供了新途径。

然而,物质空间分布的复杂多样性和像元级数据采集方式等因素,给图像带来常见的混合像元问题。像元对应一定的空间尺度,记录其量度范围内所有物质的综合光谱响应。各物质的空间分布在像元内部是缺失的,但光谱特征却经过整合后保留在像元光谱中。从微观的分子和细胞到宏观的地球与行星表面,这种“混合”总是存在的,且难以因为较高的空间分辨率而消失。因此,虽然高光谱图像的固有采集方式会使混合像元问题更加突出,但仅提升空间分辨率却很难根本解决该问题^[3,10]。混合像元最直接的影响就是令各种像元级应用的结果存在较大的误差,造成深层定量分析开展的困难。

光谱解混,也称光谱混合分析(SMA),旨在将像元光谱分解为亚像元尺度上各类纯物质端元光谱以及它们对应的比例丰度,从而可为高阶的定量应用提供细化的数据支撑,是一个空间降尺度的技术过程^[10-12]。其实质属于盲源信号分离领域的研究分支^[13],目前绝大多数的光谱解混理论和方法均面向遥感应用而被提出,一直是遥感图像处理研究领域的基础内容。光谱解混的技术研究主要涉及:描

述物质光谱混合过程的数学与物理模型的构建;分别从特征空间数据的几何分布以及基础混合模型与图像本征结构的融合出发,构建解混约束优化问题并实现高效求解;结合信号处理、机器学习与人工智能先进技术实现解混性能提升等诸多方面。

光谱解混的技术研究围绕着像元分解的数理问题发展了大量的理论和方法。根据光线与物质的相互作用,光谱解混方法可分为线性与非线性解混两大类;而进一步对应解混流程中的端元提取、丰度估计和非监督解混的不同侧重面,也有相匹配的方法分支。线性解混假设像元光谱为端元按照丰度系数的线性凸组合,其模型在数学上的简单性、求解的易实现性以及在许多应用情景中的良好效果,使其得到广泛采用,而相关的理论和方法也日趋成熟。然而,线性解混却难以摆脱不能解释真实场景中非线性混合效应的固有缺陷,这也愈加促进了近些年非线性解混前沿研究的步伐^[14-15]。设计能合理解释各类特定场景非线性混合效应的模型,以及实现复杂非线性问题精确高效的优化求解是非线性解混研究面临的两个难题。非线性解混由此更形成了基于特定模型和数据驱动的两类非线性解混方法^[11]。虽然目前国内外非线性解混方法的研究尚处于起步阶段,但其对深入理解像元内物质的本质混合机理,将精确解混推广到实际应用中具有重要的理论和现实价值。

另一方面,光谱解混的应用研究应数十年来社会发展的需求,密切关注光谱解混与不同具体应用情景的结合及其所起的关键作用。光谱解混的应用方向整体上可概括为:方法上对其他技术性能的改进,以及在科学研究、国民生产等领域的现实应用。后者按照不同的尺度又可划分为遥感和室内级的现代应用两个方面。光谱解混所提供的端元和丰度可直接用在降噪和图像增强、图像融合、分类和目标探测等技术流程中,以克服混合像元对相关方法性能提升的限制^[12]。围绕着分解混合像元的核心需求,光谱解混在解析如植被与土地变化检测、水质分析、城市发展评估、矿物与行星勘测等遥感应用中的亚像元物理参量上,总表现出非常关键的作用^[8-9]。而对于同样基于光谱数据的医学药物分析、食品检测和化学物质材料识别等小尺度的室内级现代应用,光谱解混则能给这些应用的定量分析带来精确性保障^[16]。

虽然光谱解混的技术和应用研究成果已日渐丰富,但是二者依然具有许多理论与现实问题尚待进


一步探索和攻克,特别是它们的发展之间存在较为明显的不对等性。目前,解混的技术研究比应用研究得到更多的关注,尽管解混的技术体系和新方法在不断扩展,但大多数方法仍直接源于图像与信号处理等理论,与实际应用的需求及具体问题联系不够紧密。另外,现有大多实际应用中又普遍只采用早期的经典解混方法和传统商业软件,往往未能将先进的技术方法用于解决现实问题;为同时提升解混应用发展的广度和深度,也要求明确解混技术处理各类应用问题时的必要性和独特性。本文将从光谱解混的技术及应用研究两个方面,分别介绍相关的研究进展,并通过二者的相互关联展望解混的发展趋势。

2 光谱解混方法

2.1 光谱混合模型

2.1.1 线性光谱混合模型

构建合理的物理数学模型以描述真实混合像元



的形成机制,往往是光谱解混的关键前提。线性混合模型(LMM)给出了一种最直接而简单的解释,即光线与像元空间观测区域内的各类纯物质分别独立作用,而端元反射光谱按照自身丰度比例线性组合成像元光谱。图 1 为物质光谱采集。物理意义上,端元和丰度的数值都非负,而每个像元中的各端元丰度之和等于 1,得到以下的 LMM 数学形式^[3]。

$$\begin{aligned} \mathbf{x}_j &= f_{\text{LMM}}(\mathbf{A}, \mathbf{s}_j) + \boldsymbol{\varepsilon}_j = \sum_{i=1}^r \mathbf{a}_i s_{i,j} + \boldsymbol{\varepsilon}_j, j = 1, 2, \dots, m, \\ \text{s. t. } s_{i,j} &\geq 0, \sum_{i=1}^r s_{i,j} = 1, \end{aligned} \quad (1)$$

式中: $\mathbf{x}_j \in \mathbb{R}^{n \times 1}$ 是含有 n 个波段的像元矢量,由 r 个端元矢量 $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_r] \in \mathbb{R}^{n \times r}$ 线性混合而成; $s_{i,j}$ 是端元 $\mathbf{a}_i \in \mathbb{R}^{n \times 1}$ 在像元 \mathbf{x}_j 中的丰度值; m 个像元构成图像矩阵 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m] \in \mathbb{R}^{n \times m}$, 对应有丰度矩阵 $\mathbf{S} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_m] \in \mathbb{R}^{r \times m}$; $\boldsymbol{\varepsilon}_j$ 是噪声与模型误差。




图 1 物质光谱采集。(a) 连续光谱特征^[2]; (b) 地物光谱混合过程

Fig. 1 Acquisition of material spectrum. (a) Continuous spectral features^[2]; (b) spectral mixing process of ground covers

简单来说,线性解混的目标是利用极少的先验知识,使(1)式的 $f_{\text{LMM}}(\mathbf{A}, \mathbf{s}_j)$ 与像元 \mathbf{x}_j 尽可能地逼近,由此估计端元集 \mathbf{A} 和丰度 \mathbf{s}_j 。该近似过程常衍生出如下的线性解混一般优化问题,

$$\begin{aligned} \operatorname{argmin}_{\mathbf{A}, \mathbf{S}} \frac{1}{2} \|\mathbf{X} - f_{\text{LMM}}(\mathbf{A}, \mathbf{S})\|_{\text{F}}^2 = \\ \frac{1}{2} \sum_{j=1}^m \sum_{k=1}^n (\mathbf{x}_{k,j} - \sum_{i=1}^r a_{k,i} s_{i,j})^2, \\ \text{s. t. } \mathbf{S} \geq 0, \mathbf{1}^T \mathbf{S} = \mathbf{1}_m^T, \end{aligned} \quad (2)$$

式中: $\|\cdot\|_{\text{F}}$ 是 Frobenius 范数, $\mathbf{1}$ 表示元素全为 1 的列矢量。将解混问题(2)式拆分,如图 2 所示,可形成提取端元 \mathbf{A} 、已知端元 \mathbf{A} 估计丰度 \mathbf{S} 、同时估计端元 \mathbf{A} 和丰度 \mathbf{S} 的非监督解混三类方法分支。而特征空间中数据的几何特点、图像的结构与统计特

性以及机器学习优化算法等理论支撑着相关方法的构建^[17-18]。

2.1.2 非线性光谱混合模型

LMM 只考虑光线单次散射,一般仅适用于地物分布呈近似网格状的简单场景。然而,真实场景中的光线与不同物质先后作用所形成的多次散射非线性混合效应,往往使 LMM 的模型误差突显,尤其是在微观上如矿物砂砾等紧密混合场景,以及具有明显层次结构的植被覆盖与城市地区的应用中^[11-15]。因此,非线性混合模型的核心目标常在于建立多次散射的合理数理表达。自 20 世纪 80 年代,以 Hapke^[19] 模型为代表的基于辐射传输理论的物理模型就开始在早期的地物光谱混合分析中被采用。对特定物质的抽象结构化及其与光辐射相互作

用的跟踪,使得该类模型具有较强的物理意义,但同时模型形式和求解也较复杂,对实际场景先验参数的依赖程度高,造成许多应用开展困难。为提升解

混可行性,最近部分基于 Hapke 模型的研究将双向反射率与单次散射反照率间的转换与 LMM 相结合,建立了适用于紧密混合物的简化模型^[20-21]。

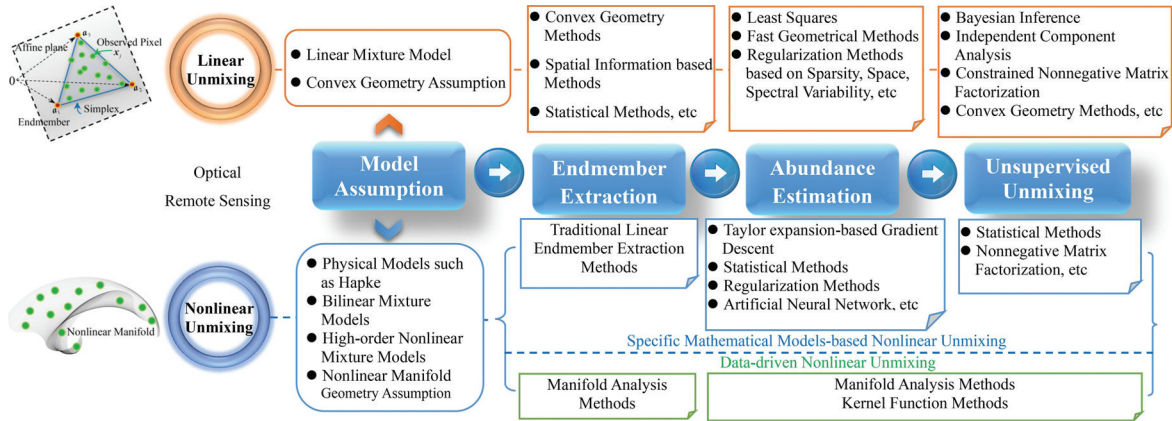


图 2 光谱解混技术的研究现状

Fig. 2 Research status of spectral unmixing technology

另一类典型的非线性混合模型,直接以各端元间逐波段的乘积 $a_1 \odot a_2$ 、 $a_1 \odot a_2 \odot a_3$ 、 $a_1 \odot a_2 \odot a_3 \odot \dots$,明确给出二次及以上多次散射的数学表达,并将这些非线性成分与 LMM 结合^[11]。该思想的雏形在早期对植被冠层与土壤间的多次散射^[22] 研究中就已出现,相关模型在近十年内得到了进一步扩展和改进。随着各种超参和额外约束的引入,模型的泛化能力也得到有效提升,能适用于更多不同的非线性混合场景。相比前一类物理模型,该类形式简化的模型降低了自身复杂度和对场景参数的依赖,使非线性解混的计算易于实现而接轨现实应用。其中,双线性混合模型仅围绕两两端元间的二次散射贡献,较大简化了对非线性的处理过程,成为当前非线性解混研究中流行的模型。如 Nasimento 模型^[23]、Fan 模型 (FM)^[24]、广义双线性模型 (GBM)^[25] 和多项式后验非线性模型 (PPNM)^[26] 等双线性混合模型,虽然种类多但形式大都相近。其中的 GBM 和 PPNM 在以往多次的非线性解混实际研究^[27] 中已经展现了出色的性能。此外,若需处理城市等具有更复杂三维层次结构的地物,则应考虑三次以上的多次散射并构建高阶非线性混合模型,例如描述任意有限整数阶多次散射的 p -linear 模型^[28],以及能解释非线性强度连续变化的多线性混合模型^[29] 等。最近,Uezato 等^[30] 将激光雷达数字表面模型所获取的入射角、天光因子和可见度等参数,代入到基于高光谱遥感图像辐射数据的非线性混合物理模型的构建中,有效克服了入射光源的变化所引起的光谱变异性以及阴影像元对解混的影

响。在高光谱遥感图像解混中,结合激光雷达等^[31] 多元数据所提供的额外先验信息,正逐渐成为国际上极有前景的光谱解混研究新方向。

构建光谱混合模型后,设计并实现精确高效的优化求解方法是光谱解混的核心步骤。从 20 世纪 80、90 年代常用的简单最小二乘 (LS) 回归估计到 21 世纪初典型的几何类方法,快速发展到十年前兴起的基于图像特性正则化与统计机器学习的优化求解等,再到最近以非线性和光谱变异性等难点问题为直接导向、与人工智能和高性能计算等先进技术交叉融合的研究,光谱解混方法的发展正在不断地深入和丰富。虽然线性和非线性解混关注的问题有所差异,但在方法原理上却具有较大的贯通性。根据图 2 中各典型光谱解混方法的构建原理,实际从全局上又可归纳为几何、正则约束优化和统计机器学习三类,下面将从这些方面分别介绍解混技术的研究进展。

2.2 解混的几何方法

如图 2 所示,在不考虑噪声等影响的 LMM 假设下,所有像元点将位于光谱特征空间中以各端元为顶点的单形体内。每个像元的丰度决定了它在单形体上的位置,越靠近某端元顶点的像元一般含越高的端元丰度,也就越纯。上述直观的几何性质给线性解混提供了一条可行的途径。

在几何端元提取中,当图像中存在各类端元物质的纯像元时,基于几何投影、单形体体积最大化等思想,通过寻找特征空间中数据云的端点,可直接确定端元。代表性的纯像元指数 (PPI)^[32]、内部最大

体积法(N-FINDR)^[33]和顶点成分分析(VCA)^[34]等方法也得到了大量使用。而将像元关于各端元顶点的重心坐标与丰度相对应,部分算法^[35-37]利用单形体几何投影和距离比的策略,可快速实现满足物理约束的丰度估计,算法效率高但对噪声和异常等干扰比较敏感。另外,对于高度混合的数据,基于凸分析和单形体体积最小化规则的算法,如最小体积单形分析(MVSA)^[38-39]和分裂增广拉格朗日单形识别(SISAL)^[40]等结合不同的改进策略,可在端元与丰度的交替更新中完成非监督解混。

与之不同的是,非线性解混在几何上需要考虑比线性单形体更贴近真实的,如图 2 所示的复杂非线性流形结构^[41]。非线性混合效应和物质构成的局部异质性等是产生流形变化的重要因素。为利用数据的非线性流形变化实现解混,经常会通过经典的非线性降维方法^[42-43]提取数据特征,然后结合线性方法进行后续处理。部分改进方法利用图像少量标志点描述流形结构以减少解混中非线性降维的计算量^[44]。为避免复杂的降维过程,更准确地抓住数据的非线性流形变化,Heylen 等^[45]和 Yang 等^[46]根据图论思想,直接用普通图或超图构建低维嵌入流形的坐标系统,并以测地线距离作为基本度量获取嵌入在流形上的单形体,最后采用线性几何规则实现非线性解混。此外,在基于特定模型的非线性解混中,需考虑大量与端元相关性较高的虚拟端元,所产生的共线性效应严重影响着解混精度^[47]。针对该问题,最近的研究^[48]根据双线性混合模型的几何特性构建非线性端元,并通过几何投影将非线性解混转换为线性解混处理,有效地提高了非线性解混的精度和效率。

2.3 解混的正则约束优化方法

虽在数学上容易实现对(2)式的模型优化求解,但若不考虑端元和丰度的约束条件,所得结果只能达到计算的近似性,难以满足实际的解混需求。当端元已知时,经典的全约束最小二乘算法(FCLS)^[49]通过迭代更新丰度最小二乘解和正集筛选的方式较好地处理了 LMM 的两个丰度约束,是最为流行的丰度估计算法。迭代误差分析(IEA)^[50]结合约束 LS 估计的丰度迭代地反推解混误差,并以次作为判定规则搜索得到所有端元。然而,类似于 FCLS 等的经典算法实际所考虑的丰度性质是非常有限的,忽略的图像信息使估计的丰度与地物真实存在一定差距。

图像局部空间中分布的像元光谱相似,具有类

似的物质成分;不同物质的空间分布呈平滑变化;每个像元通常只由少量端元子集构成;以及光谱波段间的较强相关性等特征,要求丰度具有数学上的空间相关与平滑性、稀疏性、低秩性等结构性质。为将这些图像特性有效融入到解混的优化过程中,正则约束优化方法在近十多年被大量用于对(2)式解混问题的改进。其核心思路是构建若干关于端元和丰度性质的约束数学表达,乘以正则化系数后与原模型误差项相加,通过对各目标的权衡优化,使解混结果同时具有较好的模型拟合度和正则化特性。模型的改进是这些方法的研究重点,而投影梯度法、交替方向乘子法和统计优化等算法则用于数值求解,其中经常涉及较为复杂的公式推导。常见的正则项包括:令丰度具有足够稀疏性的 l_0 、 l_1 、 $l_{1,2}$ 和 $l_{1/2}$ 等范数,表示低秩性的核范数,反映丰度空间相似性与平滑变化的全变分(TV)约束和图约束^[51-59]。例如,Iordache 等^[51-52]提出 SUnSAL 算法,利用变量分离增广拉格朗日方法实现丰度 l_1 范数正则化的稀疏解混,并进一步与 TV 空间正则项结合使丰度更贴近真实空间分布。另外,以图像空间和形态学信息^[53-54]构建的端元评价测度,也能弥补几何端元提取方法的不足。

非负矩阵分解(NMF)以其对变量非负性的保持,以及与 LMM 数学形式的相似性,自 21 世纪初到现在一直是光谱解混中的热点方向^[8,10,18]。NMF 将一个非负矩阵 \mathbf{X} 分解为两个低阶的非负矩阵 \mathbf{A} 和 \mathbf{S} ,在交替迭代中使 \mathbf{AS} 不断地向 \mathbf{X} 近似逼近且同时保持非负性,完成矩阵分解。因此,NMF 给同时估计端元与丰度的非监督光谱解混指明了可行的道路,但其自身目标函数的非凸性却也给求解带来严重的局部极小问题。所以,将额外的数据特性正则化项 $g(\mathbf{A}, \mathbf{S})$,通过惩罚系数 λ 与 NMF 原拟合目标构成类似于 $(1/2) \|\mathbf{X} - \mathbf{AS}\|_{\text{F}}^2 + \lambda \cdot g(\mathbf{A}, \mathbf{S})$ 的形式,在交替权衡优化中生成满足要求的解,也就成为该类解混方法的主要特点。Miao 等^[55]提出的最小体积约束的 MVC-NMF 是早期最具影响力的该类方法,端元单形体体积正则项的引入使该算法能对高度混合数据实现正确解混并克服噪声等影响。此外,在约束 NMF 框架下,考虑稀疏性、空间相关性和流形特性等构建的正则项^[56-57],以及同时结合多种正则项的算法不断被提出。最近部分非线性解混研究先对具体的非线性混合模型进行数学变形,然后与 NMF 框架结合实现非监督的非线性解混^[58-59]。

此外,正则约束优化方法在处理考虑光谱变异性的扩展线性模型^[60-61],以及非线性解混等复杂问题上的作用明显。在对同物异谱或同谱异物相关的光谱变异性现象和非线性混合效应建模后,往往面对的是待估未知参数量庞大、变量间相关性强、约束条件多和局部极小严重等优化难题。直接对该类模型求解所得的结果偏差通常很大,引入合理的正则化规则可有效缩小搜索的解空间,对提升解混的质量较为关键。其中,Chen 等^[62]将 ℓ_1 范数与核非线性模型结合,在提升非线性解混精度的同时使得到的丰度更具空间稀疏性。Qu 等^[63]提出基于双线性混合模型的改进算法,使丰度同时满足稀疏性和空间低秩性。Yang 等^[64]在分波段非线性解混的多参数优化问题中,通过丰度 ℓ_1 范数的正则化改良了求解过程的可靠性。

2.4 解混的统计机器学习方法

光谱解混的技术研究多与统计机器学习领域中理论与方法紧密关联。贝叶斯统计学方法可利用解混变量的统计特性完成如(2)式约束优化问题的求解。根据线性或非线性混合模型与解混需求,一般给出关于丰度、端元和超参的合理先验分布并同时其中融入约束条件。经过分层贝叶斯推理等得到待估变量的后验分布后,数量庞大的待估参数常会要求用如马尔可夫链蒙特卡罗方法对后验条件分布进行渐进采样,并利用生成的样本估算参数实现解混。丰度和端元的物理约束条件以及非线性变换等,容易构建在所假设的参数先验分布中,这也使得贝叶斯方法能够解决线性和非线性解混中的多种优化问题^[65-70]。例如,Zare 和 Gader^[65]利用端元统计特性在考虑光谱变异性的同时从高度混合数据中提取端元。Altmann 等^[67-69]在贝叶斯统计框架下,结合 PPNM 模型分别实现了丰度估计、非监督解混和非线性像元的探测。然而,此统计学方法的计算复杂度很高,同时也有参数先验分布的选择问题,常对实际应用造成影响。

独立成分分析(ICA)假设构成像元的端元是来自不同独立源、概率统计分布相互独立的信号,ICA 实现的是对像元的线性盲分离。但是,ICA 的独立性假设常与数据中物质的真实分布和丰度的物理特性不相符,使其难以直接用于解混。Xia 等^[71]和 Wang 等^[72]将 ICA 成分互信息项与 LMM 的两个丰度约束条件进行正则化权衡求解,从而在解混中松弛算法对变量独立性的要求。

核函数方法以低维数据空间中的核函数来表征

高维特征空间中的内积运算,可隐式地在高维空间中以线性方法处理原非线性问题。基于此核技巧思想,许多研究尝试通过对原线性解混方法的核化处理,达到非线性解混的目的,包括改进的 Kernel FCLS^[73-74]、核化的单形体体积增长端元提取^[75]和 Kernel NMF^[76]等。而针对简单的核技巧在解混上缺乏物理意义的问题,Chen 等^[77]和 Ammanouil 等^[78]通过核函数实现逐像元和逐波段的多次散射非线性效应拟合建模,使模型能灵活适用于多种不同的非线性混合场景。此外,Gu 等^[79]则采用多核技术缓和了解混中选择核函数及其参数的问题。基于核函数的非线性解混相比特定混合模型驱动的方法,隐式提升了对各类非线性混合情形的鲁棒性,减少了待估参数的数量,但过拟合问题在此类方法中较为常见。

通过群体搜索克服传统梯度方法的不足,进化算法和群智能优化算法近些年开始被用于提升解混的优化效率和精度。此类算法通常对优化目标形式和求导没有要求,多方向随机搜索的特点能缓解非凸和非线性优化中的局部极小影响,同时也容易与多目标及并行优化技术结合^[80],更适合解混中复杂多目标约束优化问题的高效求解。Gong 等^[81]和 Yang 等^[82]分别在遗传算法和粒子群算法框架下,构建模型拟合误差与解混变量约束目标间的多目标优化机制,使算法能生成比传统正则约束优化方法更准确的解。另外,神经网络方法通过学习输入的像元样本和对应丰度标签,来调节网络连接和权重,所形成的网络结构可隐式解析未知的光谱混合模式,在处理非线性解混问题上具有可见的潜力。Zhao 等^[83]采用快速核原型分析实现了基于多层网络的光谱解混,并有效克服了其中的内存问题,在获得相比传统解混方法更优精度的同时减少了解混时间。基于 Hopfield 网络^[84]和极限学习机^[85]等方法在实际的解混应用中,也表现出有效应对非线性混合效应的能力。此外,最新在工业界和学界广泛流行的深度学习方法,以其强大的学习性能也得到了解混研究领域的关注,并开始被用在如考虑光谱变异性等复杂解混问题^[86-87]的前沿研究中。

2.5 解混方法的性能与选择

如图 3(a)所示,光谱解混技术的相关学术论文,在 1980~2020 年间呈现指数式增加的趋势;尤其在近 10 年内,随着对高光谱图像数据结构特性和光谱混合物理过程的深入理解,以及信号处理与机器学习等领域中先进技术的出现,极大地推动了光谱解混的

研究,主要形成了在几何、正则约束优化和统计机器学习三类核心理论框架下的大量解混方法。然而,解混理论和方法的迅速增长也带来了一个显著问题,即

如何科学地定性定量评价这些方法在数据处理时的性能及影响因素,特别是在不同领域的具体应用中,合理选取恰当的解混方法有待进一步探索。

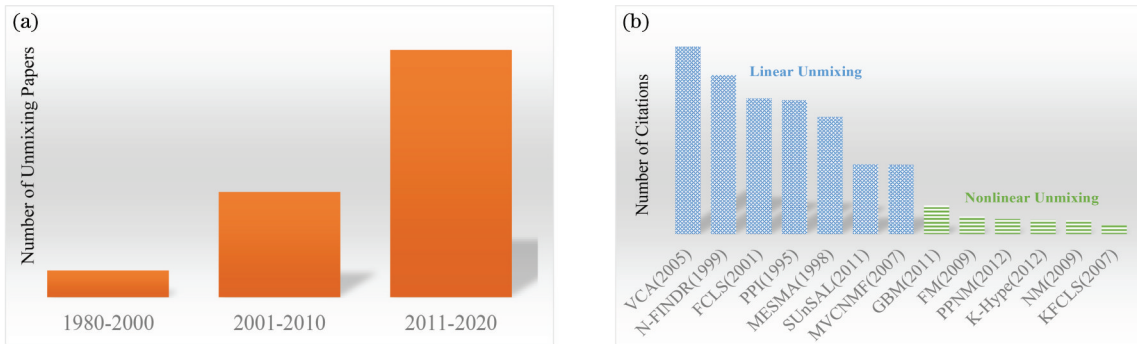


图 3 光谱解混研究统计。(a) IEEE 和 Elsevier 库中发表的解混论文相对数量变化;(b)高被引解混方法
Fig. 3 Spectral unmixing researches statistics. (a) Relative quantity change of unmixing papers published in IEEE and Elsevier; (b) highly cited unmixing methods

成像光谱仪的数据采集过程是除物质分布的自然复杂多样性外,对光谱解混方法的研究和应用带来实质影响的重要因素。一方面,如色散型、干涉型和滤光片型光谱分光技术被广泛用于获取像元高分辨率的连续光谱信息^[4]。这也使得光谱解混在数学上能够直接支持端元物质类别繁多的大面积复杂场景。但是,对应产生的庞大数据计算量,以及各通道探测器件自身的材料性能和光谱响应等参数差异所带来的信号灵敏度与信噪比降低等问题,又限制了解混的效率和精度。另一方面,成像光谱仪通常采用摆扫式、推扫式、框幅式和窗扫式等实现空间成像^[4],与此相关的视场大小和像元凝视时间差异也给解混提出了不同要求。例如,常见的 AVIRIS 等摆扫式成像,虽能获取大观测视场,但较短的凝视时间使图像的像元空间尺寸偏大而信噪比较低,这就需要解混方法能够应对多数像元呈高度混合的情形,并对噪声的影响足够鲁棒。图像空间与光谱分辨率的相互制约,促使着光谱解混技术的开展。

光谱解混方法的性能评价主要涉及仿真数据和真实高光谱图像解混的精确性和效率两个方面。难以精确获取真实高光谱图像的丰度和端元参照,致使解混效果往往依赖于定性评判,而定量验证却存在巨大的困难,这也是当前解混方法研究的主要问题之一。因此,结合公开光谱库和特定的理论光谱混合模型,生成贴近真实的仿真数据,是以往实现解混方法定量评估的预备途径。像元和端元数量、丰度分布模式以及噪声等影响因子常被考虑在数据生成过程中。端元间光谱角距离、丰度的均方根误差和图像的重构误差等是解混精确性的评价指标;而

解混的效率评价需从算法的收敛性、计算复杂度和运行时间等方面进行讨论。

高精度一直是当前多数解混方法的首要目标,但是需要消耗大量的计算资源和运行时间。严重的计算负荷促使着高性能计算技术被用于解混算法的并行优化改进中,部分运算步骤被转移到图形处理单元(GPU)上高效执行,可快速产出解混结果^[88-90]。Wu 等^[88]利用 GPU 上的计算统一设备架构(CUDA)实现了对改进的稀疏约束 NMF 方法的原始串行优化过程,超出 20 倍的加速。Bernabe 等^[89]通过 OpenCL 框架的并行技术同时缩减端元数目估计、端元提取和丰度估计三个阶段的耗时,使解混链的执行实时化。利用现场可编程门阵列技术(FPGAs),Li 等^[90]实现了 MVSA 端元提取的实时处理能力,为星载高光谱数据处理建立了基础。

而为了降低解混问题复杂程度,解混方法的设计往往依赖于某个特定的假设或面向个别具体问题的改进,使得这些方法在不同仿真数据的定量评估中存在一定的适配性与固有性能差异。例如,端元实际是由具体的应用需求而定的,某种应用中的不同端元可能在另一种应用中被划分为同类^[10]。基于 LMM 的线性解混算法难以应对非线性混合的数据;但非线性解混过程相对复杂,求解精度不高,利用高斯径向基核函数和多核改进核函数可改善模型性能,但会存在过拟合等问题。基于纯像元假设的几何端元提取算法,虽速度较快且精度一般较高,但对高度混合的数据表现较差并对噪声和异常敏感;考虑稀疏性、空间相关性等图像结构特性的正则化方法,能比纯数据驱动的方法获得更贴近实际空间

分布的丰度,但也无法同时顾及非线性、高度混合和光谱变异性等影响,并且受调参和泛化局限性制约。

由此可见,在真实光谱图像的实际参照标准缺乏的情况下,仅以简单的模型仿真数据难以合理评估各类解混算法性能。最近, Dobigeon 等^[27]采用物理光线跟踪器,渲染出贴近真实的虚拟柑橘园等场景,并结合传感器和大气辐射传输模型模拟数据采集,给构建统一的光谱解混方法评估的数据框架提供了新思路。然而,光谱解混方法始终是以具体应用为导向的,实际应用需求的差异也往往决定了解混方法的选择。图 4(b)列出了近些年部分高引用率的流行线性和非线性解混算法。虽然非线性解混在近十年受到的关注越来越多,但线性解混算法的研究和引用总体依然显著高于非线性解混算法,而 VCA 和 FCLS 等成熟的经典方法的使用尤为广泛。解混算法的选择应与具体的应用和实际的观测场景数据特点相联系。例如,对于多层植被覆盖和城市地区的遥感数据,以及水体成分分析等精细应用中,采用非线性解混算法一般能获得更好的结果;而对于观测场景平坦宽阔的平原地区,线性解混方法的性能往往能够满足需求。如果数据的空间分辨率高,则可直接采用基于纯像元假设的端元提取算法;而当像元空间尺度较大时,往往需要能克服高度混合问题的解混方法。接下来,将具体介绍在各类大尺度遥感和室内级应用中,不同光谱解混算法的应用情况和作用。

3 光谱解混对其他技术性能的提高

光谱解混技术所提供的亚像元尺度上的丰度与端元信息,给图像降噪与增强、融合、分类和目标探测等其他高光谱图像处理技术的性能提升开辟了更精细的数据信息渠道。

3.1 降噪和重构

高光谱图像采集的过程中,大气与光照条件变化、传感器和采集方式等通常会使数据受到噪声污染,严重影响图像的正确解译和应用。部分信噪比过低的光谱波段会被预移除而常造成信息丢失。针对复杂多样的噪声,结合图像的空谱相关性和统计特征,通过特征变换和噪声模型的优化求解等进行降噪较为常见。虽然降噪和解混是两个不同的主题,但通过解混重建图像主体物质分布来恢复相对纯净的数据,可有效限制噪声并提升图像质量。

Cerra 等^[91]选取各类匀质区域中像元的平均光谱作为端元,并以非负 LS 算法估计丰度,最后将端

元按丰度线性重构得到降噪的高光谱图像。噪声和大气效应等产生的解混残差在图像重建中得到去除,相比传统降噪方法能提高所有波段的信噪比。Ertürk^[92]通过空谱预处理改善提取的端元质量,并引入稀少端元的保留机制,先后两次结合 FCLS 算法完成高光谱图像的重建,在改善降噪效果的同时保持数据的原有特征。Yang 等^[93]将去噪与解混在同一个稀疏表示框架下进行耦合,基于 ℓ_1 范数和光谱库稀疏解混的端元和丰度,用作限制稀疏去噪中光谱扰动的正则项,二者交替执行,同时带来了去噪和解混性能的提升。Zou 等^[94]利用 VCA 算法获取端元,构建以丰度为待估量的泊松噪声分布的去噪优化问题,并同时考虑丰度 TV 分段平滑和 ℓ_1 范数正则化项,求得丰度后便得到去噪重建后的高光谱图像。Wang 等^[95]结合空间和光谱局部采样与端元及丰度的交替优化,实现基于压缩感知的数据重建,提升重建的精度并减少了计算消耗。

3.2 图像融合

图像融合面向数据本身质量的改良,可有效增强高光谱数据的空间分辨率,为实际应用提供更多的物质空间分布细节。经光谱解混得到的物质在亚像元尺度上的空间分布细节,正是实现图像融合的重要基础,而解混结果的质量也对融合性能的影响显著。在基于亚像元匹配的融合中,Yi 等^[96]用 ℓ_1 范数正则化的稀疏解混方法对空间超分辨率增强后的高光谱图像解混,通过丰度的退化映射形成解混与空间分辨率增强的互反馈机制,使空间分辨率与解混精度得到同时提升。Ertürk 等^[97]利用 VCA 和 FCLS 分别估计端元与丰度,并结合改进的离散粒子群算法进行亚像元空间正则化配置,得到空间分辨率增强的数据。

在低空间分辨率高光谱图像与高空间分辨率多光谱图像的融合中,光谱解混能用于生成空间与光谱分辨率同时较高的图像。一般思路是估计高空间分辨率多光谱图像的丰度,而提取低空间分辨率高光谱图像的端元光谱,再将二者融合。但多光谱图像较少的波段常不利于含许多端元的复杂大场景的丰度估计,往往需要在融合中采用图像子区域划分等方法。在将图像分为多个小区域子图像后,Bendoumi 等^[98]结合 VCA 从高光谱图像提取的端元与无约束 LS 估计的多光谱图像丰度实现匹配融合;Zhou 等^[99]结合子图像的局部低秩特性和 SUNSAL 算法估计多光谱图像的丰度,并用最小单形体积正则化优化方法估计高光谱图像的端元,对

解混过程的改进也提高了融合质量。此外,Nezhad 等^[100]和 Vargas 等^[101]以稀疏表示方法改进了融合中解混的丰度估计过程,而 Yokoya 等^[102]提出的简单 NMF 耦合框架,可自动实现多光谱图像的丰度和高光谱图像的端元的交叉融合。

3.3 分类

根据先验知识的利用情况,分类方法可划分为无监督、半监督和有监督分类。图像特征提取等预处理和分类器的构建是分类方法的两个核心组成,而图像光谱、空间和空谱联合信息的合理使用对分类的准确性较为关键。相比直接“离散”标定每个像元为某单一类别的硬分类方法,面向亚像元信息提取的光谱解混可提供“连续”的丰度数值变化,是一种更加精细的软分类技术。端元和丰度的使用直接降低了分类中混合像元的干扰,令像元物质类别的定量划分更为合理准确^[12]。

Villa 等^[103]利用 FCLS 估计经过支持向量机预分类后的混合像元丰度,并通过空间正则化的亚像元匹配方法得到空间分辨率增强后的精细分类结果。Dopido 等^[104]结合匹配滤波与 k -均值聚类估计丰度,并作为特征用在支持向量机分类中,获得了比用传统特征提取方法更好的分类结果。Liu 等^[105]采用多核技术改进线性丰度估计以更有效地利用图像信息,解混结果在分类验证实验中的效果比线性 LS 等传统方法的更好。Ibarrola-Ulzurrun 等^[106]利用多种考虑光谱变异性的线性解混方法,明显提升了场景复杂的高光谱图像分类精度。此外,解混在高光谱图像变化检测中也有重要的价值。遥感中的变化检测能提供地表物质随时间的多时相变化情况,从环境监测到军事勘测中被经常使用;而通过光谱解混,地物亚像元尺度上的丰度改变将被揭示出来。Jafarzadeh 等^[107]用 SISAL 方法提取端元和 FCLS 估计丰度,并构建阈值判定规则获得了地物二值和多重变化检测图。Ertürk 等^[108]提出字典修剪的稀疏解混方法,改善了变化检测中的病态求解与耗时问题。Liu 等^[109]结合 VCA 和非负 LS 通过多时相的光谱解混实现了多重变化检测。

3.4 目标探测

高光谱图像的目标探测是按背景与目标像元对图像进行二分类的方法,目标像元常是其关注的重点。目标探测的研究可根据目标和背景先验知识的有无进行划分,而子空间投影、探测统计特性和稀疏表示等构成目标探测的典型方法。光谱变异性和混合像元问题却常制约着目标探测的精度。例如,亚

像元尺度上的小目标很可能在与其他物质光谱混合成像元光谱后,难以被准确识别出来。因此,光谱解混用于目标探测是直接恰当的。Duran 和 Petrou^[110]以聚类得到的背景像元构建无约束 LS 丰度估计,并根据特征空间中目标和背景像元位置差异所对应的丰度正负性实现目标探测。Altmann 等^[111]和 Nakhostin 等^[112]分别通过贝叶斯统计框架以及单形体与稀疏 NMF 框架实现光谱解混与异常目标探测的融合,在获取异常像元的同时提升了解混精度。Qu 等^[113]利用 MVC-NMF 估计的丰度构建描述背景和异常目标的字典,更具物理意义的丰度不但能克服噪声的影响,而且使异常能更容易地与背景区分,在此基础上以低秩分解方法探测异常目标要比传统方法具有更高的探测率和较低的虚警率。而相比传统基于像元的目标探测,Ziemann^[114]对空间划分后的多个子图像进行局部端元提取,以此构建了可降低虚警率的面向区域块的距离探测器。

4 光谱解混的现实遥感应用

物质混合过程的未知性和复杂性是光谱解混技术研究的重要阻碍,早期方法的缺少更使得解混理论和方法的研究长期成为过去的首要目标。相比而言,解混的应用研究并未得到足够的重视,先进的解混方法往往未能在实际应用得到有效采用,而应用的深度与广度目前依然具有相当的局限性。其中,宏观遥感观测的社会发展需求和战略重要性,使得当前绝大部分的解混理论和方法最初都面向遥感图像处理问题而被提出,相应地,光谱解混的遥感应用也成为相关应用研究的主体内容。

如图 4 所示,光谱解混在数十年内成功用于解决植被、土地、水体和城市等典型地表环境乃至外星场景中的遥感应用问题。该技术得以在不同遥感应用中大量施展,主要在于:1) 遥感图像的低空间分辨率直接导致像元内部的重要地物信息丢失,需要光谱解混挖掘亚像元信息;2) 自然界地物自身的异质性、碎片式与分层式空间分布引起固有混合现象,需要光谱解混对地物光谱进行精确识别和区分;3) 光谱解混能提供具有物理意义的连续丰度值,与植被指数、地表温度、水体浑浊度等典型的地物生态结构物理参量密切联系,为定量遥感应用分析和评估奠定基础。当前较常用的数据是星载或机载观测平台上,如 Landsat-8 TM、MODIS、ASTER 和 AVHRR 等多光谱传感器,以

及如 AVIRIS、Hyperion、HyMap 等高光谱传感器对地表采集的遥感图像。虽然高光谱遥感图像的优势明显,但多光谱遥感图像具备更宽广的空间观测范围和较容易的数据获取渠道,在实际遥感

应用中的使用更频繁。为满足定量评估解混效果的需要,一般会采用同地区的高空间分辨率图像作为丰度的标准参照,或者用实地采集的样本点数据计算对应的误差。

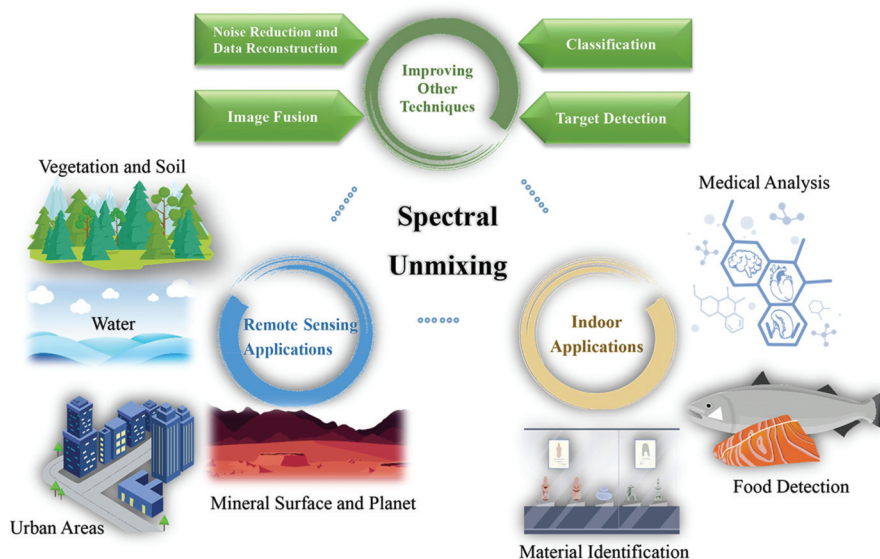


图 4 光谱解混技术的应用领域

Fig. 4 Application fields of spectral unmixing technology

4.1 植被与土地

4.1.1 土地覆盖的变化监测

植被、水和土壤等典型地表土地覆盖类型在如森林砍伐等人类活动,以及气候变化和害虫入侵等自然环境的作用下,它们的比例、构成和性状等不断地变化,影响着不同尺度上的气候和生物地理结构变迁,对于地球监测和合理规划管理具有重要的价值。传统的土地覆盖变化检测方法停留在像元级的分类上,导致难以区分像元中不同的复杂土地覆盖类型。Hlavka 等^[115]采用 LS 方法估计 AVHRR 图像森林砍伐区的裸土、短树龄的森林和原始的成熟森林丰度比例,实现了森林砍伐和再生长变化制图,并与空间分辨率相对高的 Landsat 图像对比验证,类似的方法也被 Kressler 等^[116]用在了对荷兰农村区域的土地覆盖监测中。Kumar 等^[117]以 PPI 算法提取 MODIS 图像端元和约束 LS 估计丰度,用于印度土地覆盖变化分析,结果比分类方法跟接近实际调查数据。另外,如基于最小解混误差确定最优端元组合以剔除不相干端元的方法,也被用在 Landsat 图像植被覆盖度动态变化分析的复杂应用中^[118-119],建立并评估了植被覆盖度与水土保持等的联系。

4.1.2 植被种类辨识和湿地生态保护

胡杨林、红树林、动植物栖息地和泥炭湿地等特殊局部地貌,在维持地球生物多样性、调节生态气候

和保护水土环境等方面至关重要。受到复杂地形和人力物力等因素的限制,遥感技术往往会替代实地勘测成为主要的监测手段。然而,这些地物的分布区域本身呈现的是错综复杂的异质构成,给精确的遥感应用造成显著困难,即便采用高空间分辨率的遥感图像也无法摆脱混合像元问题的影响^[120]。

胡杨林是防风固沙的重要屏障,但是数量稀少、树冠不规则、孤立木较多等问题增加了覆盖度提取的难度^[121]。郭春蕾等^[121]利用几何顶点法和 PPI 算法成功从 Landsat 数据中提取胡杨林端元,并结合线性 LS 估计得到覆盖度。罂粟是生产鸦片及其衍生毒品的重要原料,在世界范围内造成了严重的社会问题,需及时从卫星图像中发现罂粟田。Wang 等^[122]结合 PPI 算法与考虑光谱变异性的多端元光谱混合分析(MESMA)对阿富汗地区的 Hyperion 图像解混,提升了 12% 的罂粟田检测量而更符合真实情况。红树林不但是候鸟的栖息地,而且能保护海堤和阻挡海啸等灾难的侵袭,但天然的红树林常以混合斑块的形式存在,呈现明显线性和非线性交互作用,影响了红树林的遥感监测。Chakravorty 等^[123-124]通过 N-FINDR 算法和基于双线性混合模型 FM 和高阶非线性混合模型对 Hyperion 遥感图像非线性解混,确定的海漆、金盏花、金莲花和凤仙花等红树林物种分布与地面真值匹配度很高。




图 5 MESMA 获取的丰度图及对应的 LAI 图^[125]。(a)光照维管植物;(b)光照水藓;(c)阴影;(d)树木 LAI;(e)灌木 LAI;(f)总体 LAI

Fig. 5 Abundance maps obtained by MESMA and mapped LAI^[125]. (a) Sunlit vascular plant; (b) sunlit sphagnum moss; (c) shadow; (d) tree LAI; (e) shrub LAI; (f) total LAI

全球碳循环中泥炭地的碳汇作用与气候条件密切相关,具有调整水文和气候、提供生物栖息地等功能。以叶面积指数(LAI)量化泥炭地碳动态,对可能的气候变化具有较好的预测价值。但泥炭地具有灌木、不连续的树冠和苔藓地被物等多层冠层特征,降低了冠层与背景之间的对比性,严重的光谱变异性和混合像元问题导致 LAI 不能直接提取。Sonntag 等^[125]采用 MESMA 算法和实地测量的端元光谱估计如图 5(a)~(c)所示的泥炭地 Landsat TM 图像中典型植被的丰度,并进一步利用几何光学辐射传递模型与非线性 LS 回归建立了丰度与 LAI 之间经验关系,从而绘制出图 5(d)~(f)中的 LAI 分布。

在生态栖息地管理中,像元级的栖息地质量指标可确定受保护地质量、栖息地斑块的位置和大小等;而解混所得的丰度能比传统分类提供更有效的信息,适宜评估与生态结构和功能过程有关的连续梯度信息,从而更好地监控大程度上决定栖息地保护状态的草侵蚀情况。Mücher 等^[126]根据实地调查结果从高光谱遥感图像中手动选择了多个端元后以线性 LS 估计丰度,并结合丰度分割图像,提供了比传统的植被结构图更加准确和细化的草侵蚀信息。

4.1.3 作物长势与生产分析制图

人口的不断增长对农作物的供应提出了越来越高的要求,农作物不仅是世界重要的食物来源,更关系着国民经济的建设和社会的健康发展。遥感技术的优势使其在耕地面积的调查与管理,作物不同季节生长状态和产量的估算等方面发挥着关键的作

用^[127]。作物系统通常较为复杂,作物生长状况表现的季节性光谱差异,不同作物的混合与耕种交替,以及如背景土壤、杂草和阴影等非作物的干扰等,往往导致作物种植地区的显著异质性,而要实现精准的作物识别与监测就必须采用光谱解混技术^[128]。

由多光谱图像波段导出的植被指数经常被用来估计作物产量,但依赖于与数据相关的最佳波段组合的确定,难以适用于不同的图像。Yang 等^[129]认为产量与植株粒级呈正相关,与土壤粒级呈负相关。他们利用线性 LS 估计高光谱遥感图像中的高粱和裸露的土壤丰度,并与基于归一化植被指数的结果对比,证实解混可绘制更准确的作物产量变化。农民经常会在几年之间交替种植不同作物,以恢复土壤中的氮。随着季节的变化,作物会生长达到高峰,然后随着失去水分变成褐色而逐渐减少,确定作物生长高峰期的时间具有重要的意义^[130]。Lewis-Beck 等^[130]将野外辅助数据信息纳入贝叶斯解混框架的先验分布中,识别了玉米和大豆的独特时间生长曲线,并与实地调查结果表现出高度一致性。

在生长季节,树木和杂草生长或腐烂,而灌溉和降水影响着土壤水分条件的变化。这些动态和紧密混合的场景给树木状况的远程监测带来了严重的问题。植被生产参数的精确监测需要从混合像元中去不需要的背景效应^[131]。Iordache 等^[131]采用字典修剪的稀疏解混方法和 MESMA 对虚拟植被场景解混,在获得高精度解混结果的同时建立起植物生产系统的全年监测框架。作物收割后的残茬在短期内有助于水土保持和质量改善,促进污染物的生物降解。对作物残茬的良好管理能提高灌溉效

率和减少侵蚀,实现长期可持续性耕种^[132]。Chi 等^[132]结合 N-FINDR 与经典非线性流形降维算法以解释高光谱数据固有的非线性,对普渡大学的 Hyperion 图像实行解混。通过丰度和纤维素吸收指数与实际残余含量的线性回归分析,证实了非线性解混方法的优秀性能。由于植物的枯萎和死亡只发生在极端的胁迫阶段,对植被健康状况的目视检查往往不能及时避免产量损失。Delalieux 等^[133]利用 LS 线性解混方法融合生成空间与光谱分辨率都高的数据,计算新数据的标准化植被指数后,准确地检测出商业柑橘园的水分胁迫现象。

4.1.4 森林与土壤侵蚀等灾害监测

光谱解混为自然灾害等重大事件的应对提供更准确的信息。地中海地区和湿润及干旱气候过渡区,灌木、矮灌木和草本的生长空间分布呈高度碎片性,高度的混合使得对这些脆弱环境中的生态系统测绘难以开展^[134]。Shoshany 等^[134]对以色列中部气候梯度地区的 Landsat 图像进行线性解混,在区分植被与土壤覆盖丰度的同时,绘制了气候梯度上一种典型的矮灌木植被覆盖比例空间变化图。山火对人类和自然界动植物的生存环境会造成巨大的破坏,烧伤程度多等级类别的离散划分与火灾后植被、凋落物和土壤的变化大小相对应。通过分析处理高光谱遥感图像,可指示烧伤的严重程度并绘制出来,从而及时获取火灾后的具体情况,并协助重建人员减轻火灾的当下和长期影响^[135-136]。Robichaud 等^[136]利用混合调制的匹配滤波方法识别了燃烧区域灰烬、土壤、烧焦植被和绿色植被的端元丰度,经过与实地勘测结果的对比较证,能更准确地评估火灾对土壤表面的影响。盐渍化和碱化是干旱和半干旱地区主要的土地退化过程,会导致土壤肥力和生产力下降。反射率一般随土壤表面盐浓度的增加而增加,对盐害土壤的遥感观测是恢复土壤肥力并防止进一步退化的重要措施^[137]。Ghosh 等^[137]通过对 Hyperion 图像进行基于 PPI 和约束 LS 方法的线性解混,绘制出以轻度、中度和重度盐害土壤端元为代表的各类盐害土壤丰度分布,结果具有良好的拟合性。此外,Brook 和 Dor^[138]探讨了不同稀疏 NMF 方法的高光谱遥感图像线性解混结果,关于落在植被冠层上的沉降污染粉尘的检测和识别等实际定量应用。

4.2 水体

水体占地表总面积 70% 以上,包括海洋、湖泊、河流、冰川和地下水等多种形式,是地球生态

循环系统的重要组成部分和人类生产生活的关键资源。如图 6 所示,如湖泊等常见的自然水下环境系统往往较为复杂,不但生活有种类繁多的水生动植物、微生物和栖底生物,水体中还溶解或悬浮着不同的有机和无机物质,从水体表面向水底延伸,水体的组成和光学特性都会发生明显的变化。而这种变化也总是动态的,在周边的陆地、其他水体径流与大气条件、水底地形与生物环境等因素的作用下,水体呈现出异质性非线性混合尤为明显的状态。传统的水体监测依赖于不同地点的多次现场取样,但面对着采样成本高、欠采样概率大、采样的空间和时间范围严重受限等问题。此时,如要开展延伸范围广阔,以及出于保护目的或环境苛刻而无法实地进行水体应用的研究,遥感观测就成为一种不可替代的手段。




图 6 水下环境光谱混合示意图

Fig. 6 Schematic diagram of spectral mixing of underwater environments

4.2.1 水体悬浮物和水质定量分析

水质和水体中悬浮物浓度的定量监测是重要的遥感应用方向。水体浑浊度作为衡量水质的重要光学参量,与水体中有机和无机物质含量直接相关。由于会阻碍光线在水中传播,常对从微生物和藻类到鱼类等的生存造成影响。在沿海和内陆水域,有色溶解有机物、总悬浮颗粒和叶绿素 a 等构成了主要的水体成分,水体成分光学特性的差异以及浓度的变化很大程度上决定了水体表面离水反射率的固有混合特性。水体自身悬浮物质混合物、水面上的植被覆盖以及陆地与水体的碎片式交织等造成的复杂光谱混合现象,常会严重影响水质监测与评价的精度^[139-145]。

湿地具有阻挡洪水、净化水和保持生物多样性的作用,但农业用地每年向沼泽等湿地排放大量的悬浮物质,加上雪融季节沙砾和淤泥的流入,对土壤条件和植被的生长影响显著。此外,水面

和周边地表的异质结构也降低着遥感应用的精度^[140]。Kameyama 等^[140]通过现场采集和实验室观测获取北海道港口泥潭的芦苇和高低浓度浊水典型端元光谱,并将线性 LS 丰度估计与浑浊度指数通过单形体几何性质相联系,得到 Landsat TM 影像中的浑浊度指数分布;对浑浊度指数定标后通过线性回归拟合出浑浊水体的分布图,从而证实植被受到了水体浑浊度变化的影响。遥感观测能很好检测泛滥平原在陆地和水体间阶段性地变化,但由于水体不同光学成分的混合以及径流和风引起的水成分快速变化,需要采用光谱解混技术获取各种物质的丰度。Stech 等^[141]对亚马孙流域泛滥平原的 MODIS 图像进行应用分析,在用 LS 法估计得到叶绿素 a、可溶解有机物和无机物颗粒的丰度图后,结合实地采集的少量样本数据构建空间回归模型插值生成了该区域的水体浑浊度分布图。在此基础上,Alcantara 等^[142]结合克里金插值和对估计的丰度和实测数据的空间回归分析,发现样本空间自相关性的采用可提升高度复杂水体浑浊度的估计精度。杨强等^[143]将 PPI 算法提取的 ASTER 图像端元与野外采集的结果进行水质模型线性回归分析,得到了研究区水体中镁离子浓度分布,并由浓度的高低变化判断出污染源头。Burazerovic 等^[144]在水质评估的研究中,以不同混合浓度的水类型作为端元,结合 FCLS 方法估计丰度;并根据部分实测浓度的样本集,线性回归出整个图像的颜色分布,能充分地覆盖水的变化状态。

较浅和缺乏植被的湖泊中,沉积物再悬浮现象较为频繁,不但会加速水体原生物被藻类替代,而且提升了促使光衰减的悬浮颗粒物(SPM)浓度。水下水生植被能控制水体沉积物的再悬浮并维持物种多样性。但工农业的发展和自然资源的滥用,大幅减少了水下水生植被的含量,而富营养化湖泊含有更高浓度的悬浮颗粒、浮游生物和溶解物质,且透明度很低,许多植物也因此快速消失^[145]。如图 7 所示,Giardino 等^[145]基于生物光学模型和对湖泊高光谱遥感图像的线性解混,先后得到光学深水区域中 SPM、叶绿素 a 及有色可溶解有机物的浓度,以及光学浅水区 3 种底栖基质丰度与水柱高(cH)分布图。通过对湖泊不同深度区域的 SPM 与代表性水生植被比例的回归分析和实地验证,证实了有根的大型植物对保持水体清澈度的积极作用及地理差异性。

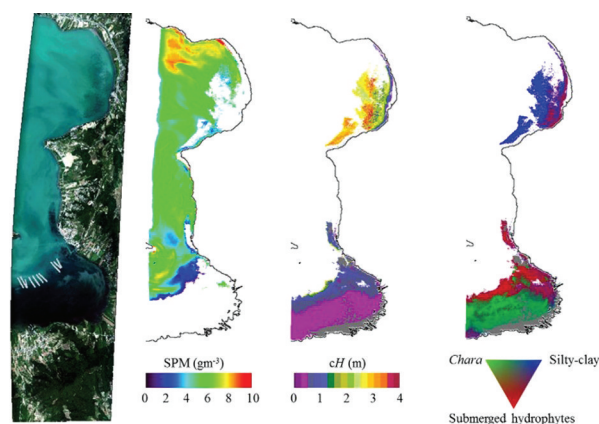


图 7 深水区的 SPM 浓度,浅水区的 cH 浓度和底栖基质丰度图^[145]

Fig. 7 Maps of SPM concentration in deep water, cH concentration in optically-shallow waters, and benthic substrate abundance^[145]

4.2.2 海岸水底物质成分估计

高光谱遥感的优势使其能较好地应对如珊瑚礁、海草床等河口和近海岸的底栖生物生境监测,对海洋生态环境的保护具有重要的意义。受地理环境、不同深度水体干扰和生物群落结构特征等影响,底栖生物生境具有复杂空间动态变化,对监测中的光谱解混应用提出了要求。Velez-Reyes 等^[146]和 Ustin^[147]利用夏威夷海湾 AVIRIS 图像研究底栖生物区域,考虑到深度和水体光学性质的空间变化对线性解混的影响,将深度等物理参数与实地采集端元砂砾、珊瑚和海藻的丰度联合反演,得到了移除水体影响后精度改善的丰度。

海平面急剧上升和海水性质的变化等会对珊瑚礁造成较大的威胁,高光谱遥感可替代传统费用高的实地取样调查方式,监测珊瑚礁的健康状况并对珊瑚礁底层类型进行详细区分。但珊瑚礁光谱变异性显著,白化和未白化的珊瑚的区分需要高的空间分辨率,而且水柱和水面对反射率会造成明显的干扰,经常需要采用非线性解混方法。Hedley 等^[148]结合光谱求导和最小二乘解混珊瑚礁图像,发现在较理想的条件下线性解混可以采用,而存在非线性效应时可对波段重采样,所得的丰度会受到珊瑚类型和数量影响。此外,非监督解混方法 ICA^[149]和 NMF^[150-151]也被用在对海底覆盖类型分布的调查上。其中,Eches 等^[150]和 Guillaume 等^[151]将水深和邻域水柱干扰的辐射传输模型与 NMF 解混框架结合,同时反演海底典型物质丰度分布和水深等物理参数,提升了监测的精度和对噪声的鲁棒性。

4.2.3 湖泊和冰雪的覆盖变化检测

在监测湖泊和冰雪覆盖变化的遥感应用中也离不开光谱解混技术。随着天然湿地湖泊的减少,小池塘为干旱地区的野生动物提供了重要的水源和栖息地,需要通过遥感手段检测水的分布和评估范围。但这些水池往往小而孤立,受到混合像元的影响,它们往往要在亚像元尺度才能识别出来^[152-153]。Jarchow 等^[153]利用匹配滤波的方法,关注水体端元及丰度从干旱区 Landsat 图像中的线性解混估计,结果表明水覆盖范围与实际地表水面相似,可适用于湿度低的干旱区域。山区的融冰径流是世界上许多地区最重要的水源之一,冰川和季节性积雪能提供春季或夏季的用水,冰雪覆盖情况也对气象和水文预测非常重要^[154]。随着温室效应使冰川不断紧缩,开展复杂山脉地形的冰雪遥感观测变得非常重要。积雪覆盖在其他物质上,根据覆盖度的不同和积雪自身异质性,图像像元中经常是积雪与背景物质的混合光谱^[155]。Cortés 等^[154]采用线性 LS 解混方法处理 Landsat 图像,估计雪、植被和裸露的岩石的覆盖丰度,在多数冰川前沿发现了显著的面积减少趋势。最近,Masson 等^[155]结合 VCA 算法与连续时间序列的积雪区域 MODIS 图像中雪背景物质的相似性提取积雪端元,进而使 FCLS 估计的积雪覆盖丰度更贴近标定的高分辨率参考数据。

4.3 城市环境

4.3.1 不透水面提取与城市发展监测

加速的全球城市化在带来人口和经济增长的同时,也产生了一系列社会和环境问题。在复杂的城市扩张时空变化过程中,越来越多如植被和裸土等其他土地覆盖类型,转变为建筑物屋顶、沥青道路、高速公路、停车场和人行道等不透水层。不透水层

的增加不仅指示着城市的发展状态,而且影响着城市气候和生态环境变化。特别在发展中国家,城市化缺乏合理规划引起的环境恶化将严重影响可持续发展。不透水层建筑材料的老化和变质,以及多种地表类型间的转换等使城市在本质上是高度异质的,在这种背景下开展城市遥观测需要光谱解混技术^[156-160],而考虑光谱变异性的 MESMA 等方法也较为常用。

Michishita 等^[156]利用 MESMA 解混南昌及周边城市 20 年间 5 个时间序列的 Landsat 图像,将得到的地物丰度分布与社会经济统计数据结合分析,揭示了城市开发与人口及第二、三产业间的正相关性,以及不同城市城市化机制的差异性。Dutta 等^[157]同样对发展中国家的城市德拉敦 10 年间多时相 Landsat 图像线性解混,根据城市建筑和植被比例的增减分析了城市化对绿化和环境的影响。Demarchi 等^[158]用 MESMA 解混城市及郊区复杂场景的高光谱图像,生成如图 8 所示的 4 种地物端元丰度分布,较低的不透水面与其他地物的混淆误差说明了高光谱数据对城市土地覆盖测绘和解混的改善作用。

Yang 等^[159-161]在对城市高分影像不透水面提取的过程中考虑了树冠和阴影对线性解混的严重影响,将有无阴影区域区分和树冠模糊度消除等方法与线性解混结合,有效地降低了对城市不透水面的低估,为监测城市及周边森林水文环境提供了更有效的帮助。Feng 等^[162]分析对比了如 N-FINDR 和 PPI 等传统解混方法与采用不同约束的 NMF 方法在城市不透水面解混上的效果,NMF 方法不但能超过传统方法达到高于 85% 的不透水面分类精度,而且更适用于端元未知的情形。




图 8 城市数据解混结果^[158]。(a)原始图像;(b)灰色表面丰度;(c)红色表面丰度;(d)植被丰度;(e)裸土丰度

Fig. 8 Unmixing results of urban dataset^[158]. (a) Original imagery; (b) gray surface abundance map; (c) red surface abundance map; (d) vegetation abundance map; (e) bare soil abundance map

热岛现象对于研究城市的气候变化较为重要,Deng 等^[163]将 Landsat 图像中代表性的黑暗、明亮不

透水表面和潮湿、干燥土壤的热响应,与从高分图像 IKONOS 中以 FCLS 求得的丰度结合起来反演米级

的城市地表温度,基于丰度的热混合模型在缓解低反射率地表混淆的同时,生成更真实的地表温度分布图。Meganem 等^[164]则考虑到城市复杂的三维结构所引起的显著多次散射非线性混合效应,基于线性二次模型扩展 NMF,并给出四种不同的优化策略用于高光谱遥感图像解混,具有较好的精度和延展性。

4.3.2 其他应用

光谱解混在污染气体、油气泄漏检测等人类活动的其他方面也体现了较高的技术价值。甘玉泉^[165]通过线性解混提取雾端元和丰度,去除雾端元后再归一化调整其他有效地物丰度,保留了更多的低频背景信息而更接近于真实的情况。Addabbo 等^[166]利用 ICA 绘制了污染气体二氧化硫的垂直高度变化,提供了重要的空气质量参考资料。孙晴晴^[167]采用 N-FINDR 和半约束 LS 方法提取遥感图像中海面油和水端元并估计丰度,实现了对海面原油溢油量的定量分析。Soydan 等^[168]将 MVSA 方法应用于可能会影响地球表面化学和矿物组成的油气微渗漏的遥感探测中,能全面评估油气微渗透制图并为勘探研究提供指导。

4.4 矿物地表与行星

不同的矿物和岩石物理化学性质的变化,在可见光近红外和短波红外光谱区间表现出明确的吸收和反射特征,通过分析处理 Hyperion 等高光谱遥感图像,可有效地提取这些矿物狭窄的诊断性特征,从而为矿物勘探等用途提供依据。复杂矿物在高光谱遥感图像呈现的混合像元经过光谱解混,能使埋藏的矿石和地质结构被准确识别,完成精细的矿物制图。Magendran 等^[169]利用 PPI 方法对矿物覆盖地区的 Hyperion 图像线性解混绘制出铁矿石丰度图,结合丰度和光谱特征进一步划分出不同品级的铁矿石分布,揭示了对应的铁矿石比例和杂质变化。Ayoobi 等^[170]采用匹配滤波等不同方法解混斑岩铜

矿 Hyperion 图像,成功绘制出斑岩矿床蚀变系统中的绢云母矿丰度分布,并排除具有不可靠丰度矿物的样本。喀斯特地貌在过去数十年受到较为严重的土壤侵蚀,存在荒漠化问题。植被和基岩覆盖率是表征喀斯特石漠化程度和地表性状的重要生态指标。Zhang 等^[171]利用光谱解混提取 Hyperion 图像中土壤、岩石和植被的丰度,根据由丰度得到的指标综合分析研究区,绘制出与地标真实接近的岩石荒漠化图,对岩溶的监测和评价具有重要作用。

在行星遥感探测的任务中,获取行星表面矿物的类型、分布与理化特性等,有助于理解行星历史和空间演化过程,也对外星移民和资源开采等未来可能的宇宙探测活动的意义重要。但轨道数据量大、图像空间分辨率等阻碍着提取精细的行星表面物质信息。光谱解混为行星表面的矿物组分、含量和颗粒大小的获取提供了可行的途径^[172-175]。Parente 等^[172]在对火星探测的高光谱遥感图像解析中,如图 9 所示,采用端元平滑约束的 NMF 方法从聚类生成的各子区域图像中提取局部端元,经过筛选后得到近似实际参考的候选端元集。Zambon 等^[173]通过线性光谱解混推算灶神星小行星上各矿物的含量,并在辉石、斜长石和橄榄石混合物实验中得到验证,在灶神星已知的闪长岩含量相对较高的地区能发现超过一半的闪长岩。月球作为地球唯一的天然卫星,对地球气候环境的变化也有相当的影响,提取月表矿物的丰度能为月球的登入、资源的估算和月表的演化历史等太空探索内容服务。林红磊等^[174]结合辐射传输 Hapke 模型对采集数据的单次散射反照率转换结果,以及稀疏解混算法 SUnSAL,成功地实现了对玉兔号光谱数据中矿物丰度的反演和粒径分布曲线的绘制。Yin 等^[175]利用稀疏表示和考虑端元束的 LS 回归方法解混嫦娥 1 号光谱图像,也准确估计出月表矿物的丰度分布。

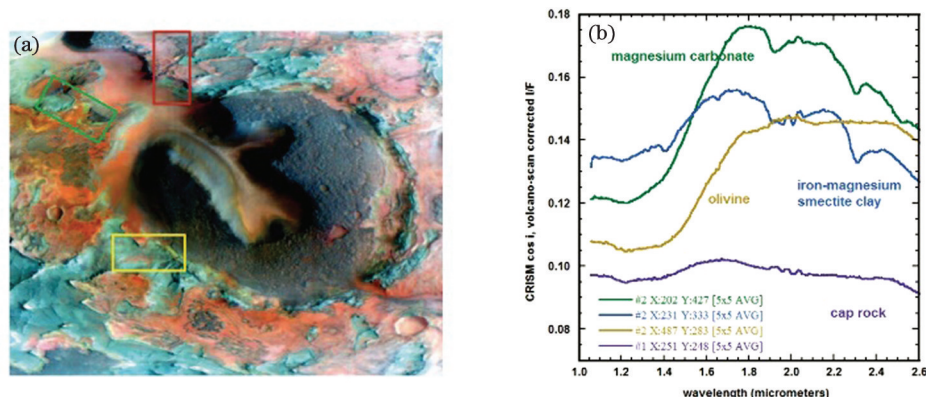


图 9 火星遥感图像解混^[172]。(a) 原始图像;(b) 选择的端元光谱

Fig. 9 Unmixing for Mars remote sensing imagery^[172]. (a) Original imagery; (b) selected endmember spectra

5 光谱解混的室内级应用

在室内级的小尺度现代应用中,光谱解混的价值可体现在医疗荧光成像中的药物分子与细胞蛋白的成分分析与疾病诊断、拉曼显微图像的脑瘤及其他组织形态评估等方面,也可用于分析食品的营养成分含量与品质,并对不同化学物质材料和颜料色素的组成进行识别等。目前,这些室内级应用中所采用的光谱解混技术,大都来自遥感光谱成像和应用等复杂问题研究中的已有理论和方法。

5.1 医学分析

荧光散射光学断层扫描和荧光多光谱成像以其成本低、易于使用等优势,在医疗诊断、跟踪药物的传输和吸收代谢过程及临床等医学领域中得到广泛使用。例如,向患者体内注射荧光化合物标记后,会与靶向肿瘤特异性结合,从而使研究人员能够检测和定位病人体内的癌细胞。在血红蛋白组织和其他化合物对较低波长信号强吸收的作用下,标记物一般会在组织吸收较低的近红外光谱域进行最佳激发,癌细胞便可通过测量标记发出的荧光信号定位。然而,生物组织具有高度的光散射和自荧光特点,加上体内外光谱差异和多目标荧光的交叠,以及随着组织介质厚度的增加,荧光信号的光传播呈指数衰减等因素的作用,常会产生显著的光谱混合现象,导致标记物的错误定位^[176-181]。

为在基于荧光成像的医学分析中克服混合像元问题和去除自荧光的影响,Nadrigny 等^[176]利用无约束 LS 法估计预定义荧光蛋白的丰度,有效表达了光谱重叠荧光蛋白在单分泌细胞器的自发荧光。Montcuquet 等^[177]则提出稀疏正则化的 NMF 方法来检测空间稀疏的特异性荧光并消除自荧光干扰。如图 10 所示,在白鼠体内实验中比其他方法表现出更强的鲁棒性和精度,能有效地进行肿瘤定位和大小分析。Zhao 等^[178]将目标背景分离的增强处理与 LS 解混方法结合起来,成功从背景自荧光中分离出多个重叠的目标荧光 AF488 和 AF594,获得了理想的效果。核酸的肺部输送可用于治疗如纤维化、癌症和感染等肺部疾病,肺给药治疗性 RNA 具有较高的肺滞留率和减少全身副作用等优点^[179]。基于此,Geyer 等^[179]通过线性解混清楚检测出 AF750 荧光信号,并与食物来源的自荧光明确区分,同时也观察到了荧光试剂在肾脏和膀胱的排泄过程。Liu 等^[180]将 ICA 方法用在荧光成像和药物动力学的研究中,定量反演出在不同的时间点,特定功能结构中药物浓度的变化。Ran 等^[181]在阿兹海默症荧光蛋白分析中,通过线性解混区分自荧光、束缚和自由探针荧光在白鼠体内的分布,能为疾病发展过程中组织的变化提供依据。Cheng 等^[182]通过线性 LS 方法解混多个重叠的荧光团信号,对活细胞内的蛋白分子的氧化还原变化进行了有效的监控。

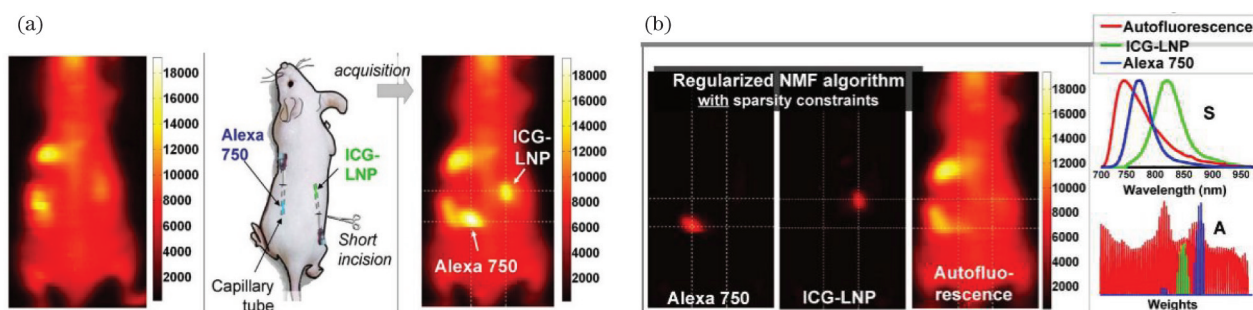


图 10 荧光图像解混^[177]。(a) 自荧光采集与特定标记混合的原始数据;(b) 稀疏正则 NMF 解混结果

Fig. 10 Unmixing for autofluorescence image^[177]. (a) Original data of autofluorescence acquisition and mixed specific fluorescent markers; (b) unmixing results of sparsity regularized NMF

拉曼显微光谱成像在生物和医学领域也有广泛的应用,图像每个像元的光谱特征都包含与诊断相关的大量生化信息,可提供亚细胞级无标签方式的分子对比,服务于临床组织和细胞诊断。拉曼光谱也可以检测未加工、未干燥的组织切片,而不需要任何染色、洗涤或干燥过程^[183-186]。例如,脑瘤的诊断可参考脂质含量和组成的变化,以及细胞核的大小、数目和分布的变化等信息。为在对正常脑组织造成

最小伤害的情况下完全切除肿瘤,结合探针和拉曼成像可无标签描绘出肿瘤边缘。Bergner 等^[184-185]采用 N-FINDR、VCA 和非负 LS 方法解混非干脑瘤组织的拉曼显微光谱图像以进行形态学分析,准确揭示出胆固醇、核酸、胡萝卜素和蛋白质等物质的丰度分布,为恶性肿瘤的评估提供定量的生化参数数据。Lobanova 等^[186]结合奇异值分解和 NMF 方法,对大尺度人类粥样硬化主动脉组织的拉曼高光

谱图像进行解混分析,在精确量化高低浓缩化合物的生化成分和识别出病变组织的同时,大幅缩短了计算时间。

在医学分析的其他方面, Du 等^[187]用 ICA 解混高光谱医学图像实现了对癌症的筛选; Lopes 等^[188]以 MVSA 方法解混药品高光谱图像,在没有关于样品先验知识的情况下,开展了假冒药品检测与成分的确;针对多光谱层析光声成像数据的解混问题, Tzoumas 等^[189]和 Ding 等^[190]通过仿真和真实实验分别研究了正交子空间投影和非负约束 LS 等方法,在分解吸收组织中分子药物和背景等方面的实际应用潜力和改进措施。

5.2 食品检测与材料识别

食品质量控制领域中,利用高光谱图像可反映食品中水分和脂肪含量等化学成分,并且根据光谱的变化评估食品腐败程度和检测产品缺陷。例如,鱼片中的血液会产生红色斑点和泛红色,而血液量和分布是衡量鱼肉质量的主要参数之一。在储存过

程中,血液作为脂质氧化的催化剂,吸收光谱会随血液的氧化状态而变化。当鱼被宰杀和切片后,活鱼血液中原有和脱氧的血红蛋白,会逐渐氧化成高铁血红蛋白。因此,根据血红蛋白状态的吸收光谱可估算鱼片高光谱图像中的血液浓度^[191]。 Skjelvareid 等^[191]利用非负约束的 LS 方法估计预先选择或测得的有氧、脱氧和高铁血红蛋白以及水和肌肉端元的丰度。然后,结合含不同血液浓度的均匀鳕鱼肉样本测量实验,以指数函数拟合出丰度和高铁血红蛋白含量间的关系,得到如图 11 所示的鱼片血液浓度分布图,从而可服务于鱼片的自动质量分级和加工。另外, Collewet 等^[192]将空间正则最小二乘优化方法用在含有多种组织结构的核磁共振图像的量化分析中,检验糕点食品的成分。图像中往往有些目标的结构太小或太薄,加上较低的空间分辨率影响,产生如糊状物和气体的混合以及脂肪和气体的混合等。经过线性解混,糕点的脂肪、糊状物和气体三种成分比例被清晰地展现出来。

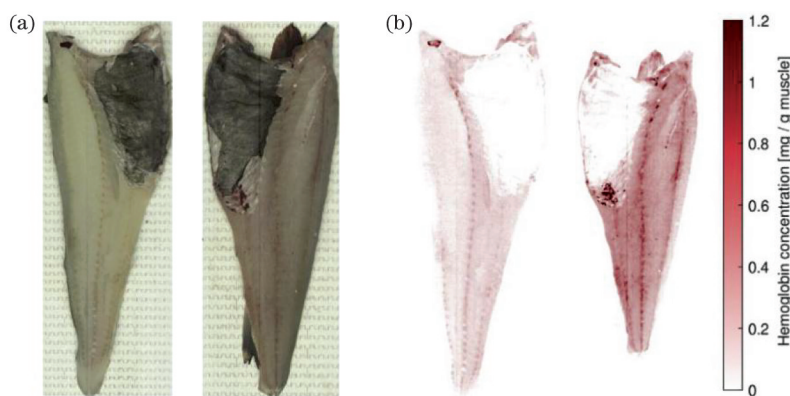


图 11 鱼肉高光谱图像解混^[191]。(a)原始数据;(b)血液浓度解混结果

Fig. 11 Unmixing for fish muscle hyperspectral image^[191]. (a) Original data; (b) unmixing results of blood concentration

此外,在材料科学、物理和化学实验中,许多光谱响应可以被描述为多个成分端元光谱的线性混合叠加结果。例如,这些端元可以是拉曼和高光谱成像中的光学光谱、质谱、电子显微镜的能量损失谱等。丰度则对应如化学物质的浓度和相位等端元光谱权重^[193]。 Kannan 等^[193]将矩阵分解框架中的主成分分析和稀疏与平滑正则 NMF 方法,用到材料分析领域的不同实际问题中,提供更有意义和可解释的解混结果。植物细胞壁是一种基于纤维素的纳米复合材料,嵌入在聚碳酸酯和芳香族聚合物基质中,其化学和结构性质取决于物种、年龄和环境条件等因素,也往往含有重叠的多个组分^[194]。拉曼成像可在微尺度上以非破坏性的方式揭示植物组织的组成,其中需要用到光谱解混技术。如图 12 所示,

Prats-Mateu 等^[194]对比分析了 VCA 和 NMF 等方法对树茎拉曼图像的解混效果,提取出细胞壁和胞腔等组织端元的丰度比例。解混结果正确地描述出植物的异质结构,并可视化细胞壁组成和结构的细微变化,适用于植物细胞的识别和分类。

艺术品的保存或历史分析要求对所使用的材料及其随后的变化有深入了解。高光谱成像能容易获取材料表面各种化学物质的详尽光谱信息,为识别绘画艺术品的颜料及修复提供了具有保护作用的非接触途径。在高光谱色素识别过程中需要通过光谱解混确定各颜料成分的分布,以及某颜料是否和艺术品画布等其他材料混合。 Grabowski 等^[195]参考通用颜料库,采用 SISAL 方法对带有不同颜料的画布样本数据解混并分类,能正确地识别色素和区分




图 12 云杉树茎拉曼图像解混^[194]。(a) 原始数据;(b) VCA 和 NMF 解混结果

Fig. 12 Unmixing for spruce stem Raman image^[194]. (a) Original data; (b) unmixing results of VCA and NMF

相似颜色和相似元素组成的颜料。另外, Zhang 等^[196]最近利用 NMF 方法提取混合的多波段入侵光纤信号的不同纯频谱, 提高了光纤预警系统在复杂周边环境下的识别精度。

6 问题及展望

面向多物质异质混合光谱的亚像元级分解与精细信息的提取, 且以多光谱特别是高光谱图像为数据支撑, 光谱解混的基础方法和应用研究历经了数十年的探索和发展, 相关研究成果已形成独特而统一的框架。既从辐射传输理论到线性与非线性混合数学模型的构建, 也从几何投影到机器学习等先进技术驱动的优化, 光谱解混理论和方法的研究紧密围绕着精度和效率两个主题。其中, 深挖图像的稀疏和空间等结构特性是提升实际解混效果的重要途径, 而多种约束及参数的合理配置与计算更是生成精确解混结果的必备要素。另一方面, 由植被、水体和城市等复杂地表场景到外星表面的遥感应用, 再由遥感到室内级的医学、食品和材料分析等应用, 光谱解混能在不同尺度上满足各学科领域对精细化数据分析和量化应用的需求。然而, 光谱解混这两方面发展历程中也尚存较多不足, 需要后续深入改进。

光谱解混理论和方法的研究中可重点关注:

1) 非线性光谱混合机制更完善的数理表达以及复杂模型的高效求解。相比线性解混, 非线性解混采用的模型种类繁多, 虽能在不同程度上解释部分非线性贡献, 但它们在数理形式和适用场景上的局限性, 依然会产生对非线性效应的误解和过拟合等问题。因此, 完善和提升非线性混合模型的泛化性和准确性, 并同时解决计算过程中如共线性等难题实现高效高精度求解, 将是解混研究的重要方向。

2) 解混中光谱变异性问题的深入探究。在光照等观测条件和物质自身的结构异质性等因素影响下, 以同物异谱或同谱异物为表象的光谱变异性在实际观测图像中较为普遍, 并类似于非线性混合效应, 会对解混精确性造成直接的干扰。在混合模型中融入光谱变异性和采用数据流形和统计描述, 是削弱其影响的有效方法, 而从理论上区分光谱变异性与非线性混合效应的差异和联系, 有望在解混中同时处理好这两个难点。3) 解混约束优化问题的智能式求解。解混算法往往需处理好含有多种约束和庞大参数规模的复杂优化问题, 这在非线性的解混中尤为突出。如图卷积神经网络等人工智能与机器学习的最新代表成果, 有望被用于提升解混的精确度。4) 多源数据融合的解混, 以及提升解混性能定量评价可靠性的虚拟仿真场景观测数据的渲染生成等前沿方向, 将是未来解混研究的重点, 而国内的相关工作有待进一步跟进和补充。5) 解混的理论方法研究不仅应紧密联系实际的应用需求, 而且可与实际的传感器硬件特性相关联, 实现如星载实时解混等高新技术。

光谱解混的应用需建立与理论方法的协同发展, 具体包括: 1) 应用中高光谱数据和先进解混算法的推广使用。目前许多实际应用中采用的是多光谱数据, 虽然数据获取渠道比高光谱数据更广, 但也较大限制到了光谱解混性能的发挥。此外, 虽然存在大量的先进解混方法, 但应用中最常用的依然是 N-FINDR 或 VCA 端元提取以及约束 LS 丰度估计等类似的经典方法。需要促进最新的解混技术研究成果, 尤其是非线性解混与如水体监测等复杂应用问题的关联。2) 解混对特定应用领域先验知识的利用。不同的应用领域背景和对解混需求的差异, 要求解混方法能与实际问题相结合, 并通过相应的

改进取得最佳的效果。3) 解混结果的评估验证及其与应用领域中物理参数回归关系的优化改进。更多地结合实地测量、虚拟仿真数据等多重手段合理评定解混结果的精确性,可更好地保证应用效果的可靠性。此外,以人工智能方法替代传统线性回归,学习解混结果与应用领域中物理参数的内在关系也较为重要。4) 解混专业商用软件的开发与推广。许多应用领域的技术人员常用如 ENVI 等商用软件中的解混模块处理数据,但其集成的解混算法有限且较难满足现代智能化需求。开发专门面向解混并能集成最新技术成果的国产专业软件具有相当的必要性。5) 开拓新的解混应用方向。

7 结束语

光谱解混技术具有丰富的科学内涵,在不同领域中的成功应用更体现其对于国民经济建设和科学研究等的重要现实意义。本文分别从国内外光谱解混在技术和应用两个方面的研究历程出发,首先介绍了常见的线性与非线性混合模型,并对基于几何、正则优化和统计机器学习原理的三类解混方法的发展状况进行了总结。然后,依次分析了光谱解混在改进其他技术性能、服务各类现实遥感和室内级应用时,对数据的精细信息提取与量化分析所起到的重要推动作用。最后,对光谱解混理论方法和应用研究中的不足,以及将来有潜力的发展方向进行了探讨。从最初只针对遥感图像处理中的特定问题,光谱解混正逐步发展和衍生出独特的新内容,可有力提升光谱数据处理的精确与高效性。

长江入海口等典型的河口海岸水质遥感观测中,以悬浮泥沙为代表的水体成分区域性和季节性时空演变是相关定量研究的难点。而不同深度水体成分呈现出的强烈非线性混合本质光学特点,使非线性解混前沿的理论和研究方法研究,与水体定量遥感应用自然地紧密关联,将是下一步重要的研究方向。其中,结合水体光学辐射传输方程,构建相适应的简化而实用的非线性光谱混合模型,并设计高效的约束优化算法,将有望解混得到各水体要素更准确的光谱特征和分布比例。在此基础上,可通过最新的深度学习技术克服传统经验方法的缺陷,建立水体反射光谱特征与水体要素物理浓度间更真实的反演模式,满足水体生态环境保护和资源开发利用等高精度的现代需求。

参 考 文 献

- [1] Goetz A F, Vane G, Solomon J E, et al. Imaging spectrometry for earth remote sensing[J]. *Science*, 1985, 228(4704): 1147-1153.
- [2] Shaw G A, Burke H K. Spectral imaging for remote sensing[J]. *Lincoln Laboratory Journal*, 2003, 14(1): 3-28.
- [3] Keshava N, Mustard J F. Spectral unmixing[J]. *IEEE Signal Processing Magazine*, 2002, 19(1): 44-57.
- [4] Zhang B, Gao L R. Hyperspectral image classification and target detection[M]. Beijing: Science Press, 2011.
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.
- [5] Zhao Y S. Principles and methods of remote sensing application analysis[M]. Beijing: Science Press, 2003.
赵英时. 遥感应用分析原理与方法[M]. 北京: 科学出版社, 2003.
- [6] Liu L Y. Principles and applications of quantitative vegetation remote sensing[M]. Beijing: Science Press, 2014.
刘良云. 植被定量遥感原理与应用[M]. 北京: 科学出版社, 2014.
- [7] Thenkabail P S, Lyon J G, Huete A. Hyperspectral remote sensing of vegetation[M]. Liu H Q, Li S L, Transl. Beijing: China Agricultural Science and Technology Press, 2015.
森卡贝尔·普拉萨德·S, 里昂·约翰·G, 韦特·阿尔弗雷德. 高光谱植被遥感[M]. 刘海启, 李召良, 译. 北京: 中国农业科学技术出版社, 2015.
- [8] Bioucas-Dias J M, Plaza A, Camps-Valls G, et al. Hyperspectral remote sensing data analysis and future challenges[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2013, 1(2): 6-36.
- [9] Tong Q X, Xue Y Q, Zhang L F. Progress in hyperspectral remote sensing science and technology in China over the past three decades[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(1): 70-91.
- [10] Bioucas-Dias J M, Plaza A, Dobigeon N, et al. Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, 5(2): 354-379.
- [11] Yang B, Wang B. Review of nonlinear unmixing for hyperspectral remote sensing imagery[J]. *Journal of Infrared and Millimeter Waves*, 2017, 36(2): 173-185.
杨斌, 王斌. 高光谱遥感图像非线性解混研究综述

- [J]. 红外与毫米波学报, 2017, 36(2): 173-185.
- [12] Wang B, Yang B. Theories and methods of unmixing for hyperspectral remote sensing imagery: linear to nonlinear[M]. Beijing: Science Press, 2019.
王斌, 杨斌. 高光谱遥感图像解混理论与方法——从线性到非线性[M]. 北京: 科学出版社, 2019.
- [13] Ma W K, Bioucas-Dias J M, Chan T H, et al. A signal processing perspective on hyperspectral unmixing: insights from remote sensing[J]. IEEE Signal Processing Magazine, 2014, 31(1): 67-81.
- [14] Dobigeon N, Tourneret J Y, Richard C, et al. Nonlinear unmixing of hyperspectral images: models and algorithms [J]. IEEE Signal Processing Magazine, 2014, 31(1): 82-94.
- [15] Heylen R, Parente M, Gader P. A review of nonlinear hyperspectral unmixing methods[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 1844-1868.
- [16] Khan M J, Khan H S, Yousaf A, et al. Modern trends in hyperspectral image analysis: a review[J]. IEEE Access, 2018, 6: 14118-14129.
- [17] Willett R M, Duarte M F, Davenport M A, et al. Sparsity and structure in hyperspectral imaging: sensing, reconstruction, and target detection [J]. IEEE Signal Processing Magazine, 2014, 31(1): 116-126.
- [18] Ghamisi P, Yokoya N, Li J, et al. Advances in hyperspectral image and signal processing: a comprehensive overview of the state of the art [J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(4): 37-78.
- [19] Hapke B. Bidirectional reflectance spectroscopy: 1. theory [J]. Journal of Geophysical Research: Solid Earth, 1981, 86(B4): 3039-3054.
- [20] Close R R, Gader P D, Wilson J. Hyperspectral unmixing using macroscopic and microscopic mixture models [J]. Journal of Applied Remote Sensing, 2014, 8(1): 083642.
- [21] Heylen R, Gader P. Nonlinear spectral unmixing with a linear mixture of intimate mixtures model[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(7): 1195-1199.
- [22] Borel C C, Gerstl S A W. Nonlinear spectral mixing models for vegetative and soil surfaces [J]. Remote Sensing of Environment, 1994, 47(3): 403-416.
- [23] Nascimento J M P, Bioucas-Dias J M. Nonlinear mixture model for hyperspectral unmixing [J]. Proceedings of SPIE, 2009, 7477: 74770I.
- [24] Fan W Y, Hu B X, Miller J, et al. Comparative study between a new nonlinear model and common linear model for analysing laboratory simulated-forest hyperspectral data [J]. International Journal of Remote Sensing, 2009, 30(11): 2951-2962.
- [25] Halimi A, Altmann Y, Dobigeon N, et al. Nonlinear unmixing of hyperspectral images using a generalized bilinear model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(11): 4153-4162.
- [26] Altmann Y, Halimi A, Dobigeon N, et al. Supervised nonlinear spectral unmixing using a postnonlinear mixing model for hyperspectral imagery [J]. IEEE Transactions on Image Processing, 2012, 21(6): 3017-3025.
- [27] Dobigeon N, Tits L, Somers B, et al. A comparison of nonlinear mixing models for vegetated areas using simulated and real hyperspectral data [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 1869-1878.
- [28] Marinoni A, Gamba P. A novel approach for efficient p -linear hyperspectral unmixing[J]. IEEE Journal of Selected Topics in Signal Processing, 2015, 9(6): 1156-1168.
- [29] Heylen R, Scheunders P. A multilinear mixing model for nonlinear spectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(1): 240-251.
- [30] Uezato T, Yokoya N, He W. Illumination invariant hyperspectral image unmixing based on a digital surface model [J]. IEEE Transactions on Image Processing, 2020, 29: 3652-3664.
- [31] Qian L Y, Wu D C, Zhou X J, et al. Radiation calibration and ground object information acquisition based on high spectral imaging lidar system[J]. Acta Optica Sinica, 2020, 40(11): 1128001.
钱立勇, 吴德成, 周晓军, 等. 高光谱成像激光雷达系统辐射定标和地物信息获取[J]. 光学学报, 2020, 40(11): 1128001.
- [32] Boardman J W, Kruse F A, Green R O. Mapping target signatures via partial unmixing of AVIRIS data [C]//In Summaries of the Fifth JPL Airborn Earth Science Workshop, January 23-26, 1995, Pasadena, CA, USA. Pasadena: JPL Publication, 1995, 95(1): 23-26.
- [33] Winter M E. N-FINDR: an algorithm for fast autonomous spectral end-member determination in hyperspectral data [J]. Proceedings of SPIE, 1999, 3753: 266-275.
- [34] Nascimento J M P, Dias J M B. Vertex component analysis: a fast algorithm to unmix hyperspectral data [J]. IEEE Transactions on Geoscience and Remote

- Sensing, 2005, 43(4): 898-910.
- [35] Heylen R, Burazerovic D, Scheunders P. Fully constrained least squares spectral unmixing by simplex projection [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(11): 4112-4122.
- [36] Pu H Y, Xia W, Wang B, et al. A fully constrained linear spectral unmixing algorithm based on distance geometry[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(2): 1157-1176.
- [37] Wang L G, Liu D F, Wang Q M. Geometric method of fully constrained least squares linear spectral mixture analysis [J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(6): 3558-3566.
- [38] Chan T H, Chi C Y, Huang Y M, et al. A convex analysis-based minimum-volume enclosing simplex algorithm for hyperspectral unmixing [J]. IEEE Transactions on Signal Processing, 2009, 57(11): 4418-4432.
- [39] Li J, Agathos A, Zaharie D, et al. Minimum volume simplex analysis: a fast algorithm for linear hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(9): 5067-5082.
- [40] Bioucas-Dias J M. A variable splitting augmented Lagrangian approach to linear spectral unmixing[C]// 2009 First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, August 26-28, 2009, Grenoble, France. New York: IEEE Press, 2009: 1-4.
- [41] Lunga D, Prasad S, Crawford M M, et al. Manifold-learning-based feature extraction for classification of hyperspectral data: a review of advances in manifold learning [J]. IEEE Signal Processing Magazine, 2014, 31(1): 55-66.
- [42] Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290(5500): 2319-2323.
- [43] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290(5500): 2323-2326.
- [44] Chi J, Crawford M M. Selection of landmark points on nonlinear manifolds for spectral unmixing using local homogeneity[J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(4): 711-715.
- [45] Heylen R, Scheunders P, Rangarajan A, et al. Nonlinear unmixing by using different metrics in a linear unmixing chain[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6): 2655-2664.
- [46] Yang B, Chen Z, Wang B. Nonlinear endmember identification for hyperspectral imagery via hyperpath-based simplex growing and fuzzy assessment[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 351-366.
- [47] Chen X H, Chen J, Jia X P, et al. A quantitative analysis of virtual endmembers' increased impact on the collinearity effect in spectral unmixing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(8): 2945-2956.
- [48] Yang B, Wang B, Wu Z M. Nonlinear hyperspectral unmixing based on geometric characteristics of bilinear mixture models [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(2): 694-714.
- [49] Heinz D C, Chang C I. Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(3): 529-545.
- [50] Neville R A, Staenz K, Szeredi T, et al. Automatic endmember extraction from hyperspectral data for mineral exploration[R]. Canada: Natural Resources Canada/CMSS/Information Management, 1999.
- [51] Iordache M D, Bioucas-Dias J M, Plaza A. Sparse unmixing of hyperspectral data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(6): 2014-2039.
- [52] Iordache M D, Bioucas-Dias J M, Plaza A. Total variation spatial regularization for sparse hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(11): 4484-4502.
- [53] Plaza A, Martinez P, Perez R, et al. Spatial/spectral endmember extraction by multidimensional morphological operations[J]. IEEE Transactions on Geoscience and Remote Sensing, 2002, 40(9): 2025-2041.
- [54] Rogge D M, Rivard B, Zhang J, et al. Integration of spatial-spectral information for the improved extraction of endmembers [J]. Remote Sensing of Environment, 2007, 110(3): 287-303.
- [55] Miao L D, Qi H R. Endmember extraction from highly mixed data using minimum volume constrained nonnegative matrix factorization [J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(3): 765-777.
- [56] Qian Y T, Jia S, Zhou J, et al. Hyperspectral unmixing via $L_{1/2}$ sparsity-constrained nonnegative

- matrix factorization [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49 (11): 4282-4297.
- [57] Lu X Q, Wu H, Yuan Y, et al. Manifold regularized sparse NMF for hyperspectral unmixing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(5): 2815-2826.
- [58] Echès O, Guillaume M. A bilinear-bilinear nonnegative matrix factorization method for hyperspectral unmixing [J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(4): 778-782.
- [59] Yokoya N, Chanussot J, Iwasaki A. Nonlinear unmixing of hyperspectral data using semi-nonnegative matrix factorization [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(2): 1430-1437.
- [60] Zare A, Ho K C. Endmember variability in hyperspectral analysis: addressing spectral variability during spectral unmixing[J]. *IEEE Signal Processing Magazine*, 2014, 31(1): 95-104.
- [61] Halimi A, Honeine P, Bioucas-Dias J M. Hyperspectral unmixing in presence of endmember variability, nonlinearity, or mismodeling effects[J]. *IEEE Transactions on Image Processing*, 2016, 25 (10): 4565-4579.
- [62] Chen J, Richard C, Honeine P. Nonlinear estimation of material abundances in hyperspectral images with ℓ_1 -norm spatial regularization[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52 (5): 2654-2665.
- [63] Qu Q, Nasrabadi N M, Tran T D. Abundance estimation for bilinear mixture models via joint sparse and low-rank representation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52 (7): 4404-4423.
- [64] Yang B, Wang B. Band-wise nonlinear unmixing for hyperspectral imagery using an extended multilinear mixing model[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(11): 6747-6762.
- [65] Zare A, Gader P. PCE: piecewise convex endmember detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(6): 2620-2632.
- [66] Nascimento J M P, Bioucas-Dias J M. Hyperspectral unmixing based on mixtures of dirichlet components [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(3): 863-878.
- [67] Altmann Y, Dobigeon N, McLaughlin S, et al. Nonlinear spectral unmixing of hyperspectral images using Gaussian processes [J]. *IEEE Transactions on Signal Processing*, 2013, 61(10): 2442-2453.
- [68] Altmann Y, Dobigeon N, Tourneret J Y. Unsupervised post-nonlinear unmixing of hyperspectral images using a Hamiltonian Monte Carlo algorithm [J]. *IEEE Transactions on Image Processing*, 2014, 23 (6): 2663-2675.
- [69] Altmann Y, Dobigeon N, Tourneret J Y. Nonlinearity detection in hyperspectral images using a polynomial post-nonlinear mixing model [J]. *IEEE Transactions on Image Processing*, 2013, 22 (4): 1267-1276.
- [70] Imbiriba T, Bermudez J C M, Richard C, et al. Nonparametric detection of nonlinearly mixed pixels and endmember estimation in hyperspectral images [J]. *IEEE Transactions on Image Processing*, 2016, 25(3): 1136-1151.
- [71] Xia W, Liu X S, Wang B, et al. Independent component analysis for blind unmixing of hyperspectral imagery with additional constraints[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(6): 2165-2179.
- [72] Wang N, Du B, Zhang L P, et al. An abundance characteristic-based independent component analysis for hyperspectral unmixing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53 (1): 416-428.
- [73] Broadwater J, Chellappa R, Banerjee A, et al. Kernel fully constrained least squares abundance estimates [C] // 2007 IEEE International Geoscience and Remote Sensing Symposium, July 23-28, 2007, Barcelona, Spain. New York: IEEE Press, 2007: 4041-4044.
- [74] Rand R S, Resmini R G, Allen D W. Characterizing intimate mixtures of materials in hyperspectral imagery with albedo-based and kernel-based approaches [J]. *Proceedings of SPIE*, 2015, 9611: 961112.
- [75] Zhao L Y, Zheng J P, Li X R, et al. Kernel simplex growing algorithm for hyperspectral endmember extraction [J]. *Journal of Applied Remote Sensing*, 2014, 8(1): 083594.
- [76] Zhu F, Honeine P. Biobjective nonnegative matrix factorization: linear versus kernel-based models [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(7): 4012-4022.
- [77] Chen J, Richard C, Honeine P. Nonlinear unmixing of hyperspectral data based on a linear-mixture/nonlinear-fluctuation model [J]. *IEEE Transactions on Signal Processing*, 2013, 61(2): 480-492.
- [78] Ammanouil R, Ferrari A, Richard C, et al. Nonlinear unmixing of hyperspectral data with vector-valued kernel functions [J]. *IEEE Transactions on Image Processing*, 2017, 26(1): 340-354.

- [79] Gu Y F, Wang S Z, Jia X P. Spectral unmixing in multiple-kernel Hilbert space for hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(7): 3968-3981.
- [80] Guan S H, Yang G, Lu S, et al. Multi-objective optimization of hyperspectral band selection based on attention mechanism[J]. *Acta Optica Sinica*, 2020, 40(21): 2128002.
关世豪, 杨桃, 卢珊, 等. 基于注意力机制的多目标优化高光谱波段选择[J]. *光学学报*, 2020, 40(21): 2128002.
- [81] Gong M G, Li H, Luo E H, et al. A multiobjective cooperative coevolutionary algorithm for hyperspectral sparse unmixing [J]. *IEEE Transactions on Evolutionary Computation*, 2017, 21(2): 234-248.
- [82] Yang B, Luo W F, Wang B. Constrained nonnegative matrix factorization based on particle swarm optimization for hyperspectral unmixing [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(8): 3693-3710.
- [83] Zhao G P, Zhao C H, Jia X P. Multilayer unmixing for hyperspectral imagery with fast kernel archetypal analysis[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(10): 1532-1536.
- [84] Li J, Li X R, Huang B, et al. Hopfield neural network approach for supervised nonlinear spectral unmixing[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(7): 1002-1006.
- [85] Ayerdi B, Graña M. Hyperspectral image nonlinear unmixing and reconstruction by ELM regression ensemble[J]. *Neurocomputing*, 2016, 174(Part A): 299-309.
- [86] Borsoi R A, Imbiriba T, Bermudez J C M. Deep generative endmember modeling: an application to unsupervised spectral unmixing [J]. *IEEE Transactions on Computational Imaging*, 2020, 6: 374-384.
- [87] Bi X J, Zhou Z Y. Hyperspectral image classification algorithm based on two-channel generative adversarial network[J]. *Acta Optica Sinica*, 2019, 39(10): 1028002.
毕晓君, 周泽宇. 基于双通道 GAN 的高光谱图像分类算法[J]. *光学学报*, 2019, 39(10): 1028002.
- [88] Wu Z B, Ye S, Liu J J, et al. Sparse non-negative matrix factorization on GPUs for hyperspectral unmixing[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(8): 3640-3649.
- [89] Bernabé S, Botella G, Martín G, et al. Parallel implementation of a full hyperspectral unmixing chain using OpenCL[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(6): 2452-2461.
- [90] Li C, Gao L R, Plaza A, et al. FPGA implementation of a maximum simplex volume algorithm for endmember extraction from remotely sensed hyperspectral images [J]. *Journal of Real-Time Image Processing*, 2019, 16(5): 1681-1694.
- [91] Cerra D, Müller R, Reinartz P. Noise reduction in hyperspectral images through spectral unmixing[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(1): 109-113.
- [92] Ertürk A. Enhanced unmixing-based hyperspectral image denoising using spatial preprocessing[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2720-2727.
- [93] Yang J X, Zhao Y Q, Chan J C W, et al. Coupled sparse denoising and unmixing with low-rank constraint for hyperspectral image [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(3): 1818-1833.
- [94] Zou C Z, Xia Y S. Restoration of hyperspectral image contaminated by Poisson noise using spectral unmixing [J]. *Neurocomputing*, 2018, 275: 430-437.
- [95] Wang L, Feng Y, Gao Y L, et al. Compressed sensing reconstruction of hyperspectral images based on spectral unmixing[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(4): 1266-1284.
- [96] Yi C, Zhao Y Q, Yang J X, et al. Joint hyperspectral superresolution and unmixing with interactive feedback[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(7): 3823-3834.
- [97] Ertürk A, Güllü M K, Çeşmeci D, et al. Spatial resolution enhancement of hyperspectral images using unmixing and binary particle swarm optimization[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(12): 2100-2104.
- [98] Bendoumi M A, He M Y, Mei S H. Hyperspectral image resolution enhancement using high-resolution multispectral image based on spectral unmixing[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(10): 6574-6583.
- [99] Zhou Y, Feng L Y, Hou C P, et al. Hyperspectral and multispectral image fusion based on local low rank and coupled spectral unmixing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(10): 5997-6009.

- [100] Nezhad Z H, Karami A, Heylen R, et al. Fusion of hyperspectral and multispectral images using spectral unmixing and sparse coding [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(6): 2377-2389.
- [101] Vargas E, Arguello H, Tourneret J Y. Spectral image fusion from compressive measurements using spectral unmixing and a sparse representation of abundance maps [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(7): 5043-5053.
- [102] Yokoya N, Yairi T, Iwasaki A. Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(2): 528-537.
- [103] Villa A, Chanussot J, Benediktsson J A, et al. Spectral unmixing for the classification of hyperspectral images at a finer spatial resolution[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2011, 5(3): 521-533.
- [104] Dopido I, Villa A, Plaza A, et al. A quantitative and comparative assessment of unmixing-based feature extraction techniques for hyperspectral image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, 5(2): 421-435.
- [105] Liu K H, Lin Y, Chen C S. Linear spectral mixture analysis via multiple-kernel learning for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(4): 2254-2269.
- [106] Ibarrola-Ulzurrun E, Drumetz L, Marcello J, et al. Hyperspectral classification through unmixing abundance maps addressing spectral variability[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(7): 4775-4788.
- [107] Jafarzadeh H, Hasanlou M. An unsupervised binary and multiple change detection approach for hyperspectral imagery based on spectral unmixing [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(12): 4888-4906.
- [108] Ertürk A, Iordache M D, Plaza A. Sparse unmixing with dictionary pruning for hyperspectral change detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(1): 321-330.
- [109] Liu S C, Bruzzone L, Bovolo F, et al. Unsupervised multitemporal spectral unmixing for detecting multiple changes in hyperspectral images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(5): 2733-2748.
- [110] Duran O, Petrou M. Spectral unmixing with negative and superunity abundances for subpixel anomaly detection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 6(1): 152-156.
- [111] Altmann Y, McLaughlin S, Hero A. Robust linear spectral unmixing using anomaly detection [J]. *IEEE Transactions on Computational Imaging*, 2015, 1(2): 74-85.
- [112] Nakhostin S, Clenet H, Corpetti T, et al. Joint anomaly detection and spectral unmixing for planetary hyperspectral images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(12): 6879-6894.
- [113] Qu Y, Wang W, Guo R, et al. Hyperspectral anomaly detection through spectral unmixing and dictionary-based low-rank decomposition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(8): 4391-4405.
- [114] Ziemann A K. Local spectral unmixing for target detection[C]//2016 IEEE Southwest Symposium on Image Analysis and Interpretation (SSIAI), March 6-8, 2016, Santa Fe, NM, USA. New York: IEEE Press, 2016: 77-80.
- [115] Hlavka C A, Spanner M A. Unmixing AVHRR imagery to assess clearcuts and forest regrowth in Oregon[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1995, 33(3): 788-795.
- [116] Kressler F P, Steinnocher K T. Detecting land cover changes from NOAA-AVHRR data by using spectral mixture analysis[J]. *International Journal of Applied Earth Observation and Geoinformation*, 1999, 1(1): 21-26.
- [117] Kumar U, Kerle N, Ramachandra T V. Constrained linear spectral unmixing technique for regional land cover mapping using MODIS data[M]//Elleithy K. *Innovations and advanced techniques in systems, computing sciences and software engineering*. Dordrecht: Springer, 2008: 416-423.
- [118] He Y Q, Qin Y, Fu Q H, et al. Application of mixed pixel decomposition method using dynamic endmember combination in dynamic monitoring of vegetation abundance: a case study of Changting county[J]. *Tropical Geography*, 2016, 36(5): 860-868.
- 何颖清, 秦雁, 扶卿华, 等. 动态端元组合混合像元分解法在植被覆盖度动态监测中的应用: 以长汀县为例[J]. *热带地理*, 2016, 36(5): 860-868.
- [119] Gudex-Cross D, Pontius J, Adams A. Enhanced

- forest cover mapping using spectral unmixing and object-based classification of multi-temporal Landsat imagery [J]. *Remote Sensing of Environment*, 2017, 196: 193-204.
- [120] Stagakis S, Vanikiotis T, Sykioti O. Estimating forest species abundance through linear unmixing of CHRIS/PROBA imagery [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 119: 79-89.
- [121] Guo C L, Xie W J, Huang H G. Spectral unmixing method in extracting coverage information of populus euphratica [J]. *Journal of Northeast Forestry University*, 2014, 42(11): 82-87.
郭春蕾, 解潍嘉, 黄华国. 应用混合像元分解提取胡杨覆盖度信息[J]. *东北林业大学学报*, 2014, 42(11): 82-87.
- [122] Wang J J, Zhang Y, Bussink C. Unsupervised multiple endmember spectral mixture analysis-based detection of opium poppy fields from an EO-1 Hyperion image in Helmand, Afghanistan [J]. *Science of the Total Environment*, 2014, 476/477: 1-6.
- [123] Chakravorty S, Shah E, Chowdhury A S. Application of spectral unmixing algorithm on hyperspectral data for mangrove species classification[M]//Gupta P, Zaroliagis C. *Applied algorithms. Lecture notes in computer science*. Cham: Springer, 2014, 8321: 223-236.
- [124] Chakravorty S, Chakrabarti S. Design and development of higher order spectral unmixing model for mangrove species discrimination [J]. *Proceedings of the National Academy of Sciences, India Section A: Physical Sciences*, 2017, 87(4): 557-566.
- [125] Sonnentag O, Chen J M, Roberts D A, et al. Mapping tree and shrub leaf area indices in an ombrotrophic peatland through multiple endmember spectral unmixing [J]. *Remote Sensing of Environment*, 2007, 109(3): 342-360.
- [126] Múcher C A, Kooistra L, Vermeulen M, et al. Quantifying structure of Natura 2000 heathland habitats using spectral mixture analysis and segmentation techniques on hyperspectral imagery [J]. *Ecological Indicators*, 2013, 33: 71-81.
- [127] Li X, Wang F, Xu D B, et al. Application research on the method for extracting soybean covered areas based on the pixel unmixing[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2008, 24(1): 213-217.
李霞, 王飞, 徐德斌, 等. 基于混合像元分解提取大豆种植面积的应用探讨[J]. *农业工程学报*, 2008, 24(1): 213-217.
- [128] Lobell D B, Asner G P. Cropland distributions from temporal unmixing of MODIS data [J]. *Remote Sensing of Environment*, 2004, 93(3): 412-422.
- [129] Yang C H, Everitt J H, Bradford J M. Airborne hyperspectral imagery and linear spectral unmixing for mapping variation in crop yield [J]. *Precision Agriculture*, 2007, 8(6): 279-296.
- [130] Lewis-Beck C, Zhu Z Y, Mondal A, et al. A parametric approach to unmixing remote sensing crop growth signatures[J]. *Journal of Agricultural, Biological, and Environmental Statistics*, 2019, 24(3): 502-516.
- [131] Iordache M D, Tits L, Bioucas-Dias J M, et al. A dynamic unmixing framework for plant production system monitoring [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2016-2034.
- [132] Chi J, Crawford M M. Spectral unmixing-based crop residue estimation using hyperspectral remote sensing data: a case study at Purdue University[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2531-2539.
- [133] Delalieux S, Zarco-Tejada P J, Tits L, et al. Unmixing-based fusion of hyperspatial and hyperspectral airborne imagery for early detection of vegetation stress [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2571-2582.
- [134] Shoshany M, Svoray T. Multidate adaptive unmixing and its application to analysis of ecosystem transitions along a climatic gradient [J]. *Remote Sensing of Environment*, 2002, 82(1): 5-20.
- [135] Veraverbeke S, Dennison P, Gitas I, et al. Hyperspectral remote sensing of fire: state-of-the-art and future perspectives[J]. *Remote Sensing of Environment*, 2018, 216: 105-121.
- [136] Robichaud P R, Lewis S A, Laes D Y M, et al. Postfire soil burn severity mapping with hyperspectral image unmixing[J]. *Remote Sensing of Environment*, 2007, 108(4): 467-480.
- [137] Ghosh G, Kumar S, Saha S K. Hyperspectral satellite data in mapping salt-affected soils using linear spectral unmixing analysis[J]. *Journal of the Indian Society of Remote Sensing*, 2012, 40(1): 129-136.
- [138] Brook A, Dor E B. Quantitative detection of settled dust over green canopy using sparse unmixing of airborne hyperspectral data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and*

- Remote Sensing, 2016, 9(2): 884-897.
- [139] Rogers A S, Kearney M S. Reducing signature variability in unmixing coastal marsh thematic mapper scenes using spectral indices [J]. International Journal of Remote Sensing, 2004, 25(12): 2317-2335.
- [140] Kameyama S, Yamagata Y, Nakamura F, et al. Development of WTI and turbidity estimation model using SMA: application to Kushiro Mire, eastern Hokkaido, Japan [J]. Remote Sensing of Environment, 2001, 77(1): 1-9.
- [141] Stech J, Alcantara E, Novo E, et al. Turbidity in the amazon floodplain assessed through a spatial regression model applied to fraction images derived from MODIS/Terra [J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(10): 2895-2905.
- [142] Alcântara E, Barbosa C, Stech J, et al. Improving the spectral unmixing algorithm to map water turbidity distributions[J]. Environmental Modelling & Software, 2009, 24(9): 1051-1061.
- [143] Yang Q, Zhang Z, Qin Z H, et al. Decomposition technique of mixed pixel used in monitoring and evaluation of water quality based on ASTER [J]. Remote Sensing Information, 2011, 26(2): 20-25, 85.
杨强, 张志, 覃志豪, 等. 基于 ASTER 数据的混合像元分解技术在水质监测与评价中的应用 [J]. 遥感信息, 2011, 26(2): 20-25, 85.
- [144] Burazerović D, Heylen R, Raymaekers D, et al. A spectral-unmixing approach to estimate water-mass concentrations in case 2 waters[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(8): 3595-3605.
- [145] Giardino C, Bresciani M, Valentini E, et al. Airborne hyperspectral data to assess suspended particulate matter and aquatic vegetation in a shallow and turbid lake [J]. Remote Sensing of Environment, 2015, 157: 48-57.
- [146] Vélez-Reyes M, Goodman J, Rosario S, et al. Subsurface unmixing with application to underwater classification[J]. Proceedings of SPIE, 2007, 6743: 674309.
- [147] Ustin S L. Classification of benthic composition in a coral reef environment using spectral unmixing[J]. Journal of Applied Remote Sensing, 2007, 1(1): 011501.
- [148] Hedley J D, Mumby P J, Joyce K E, et al. Spectral unmixing of coral reef benthos under ideal conditions [J]. Coral Reefs, 2004, 23(1): 60-73.
- [149] Vassilia K, Polychronis K, Styliani I. Independent component analysis for coastal water mapping using hyperspectral datasets[C]//2009 First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, August 26-28, 2009, Grenoble, France. New York: IEEE Press, 2009: 1-7.
- [150] Eches O, Guillaume M. Seabed estimation using triple NMF method [C]//2012 IEEE International Geoscience and Remote Sensing Symposium, July 22-27, 2012, Munich, Germany. New York: IEEE Press, 2012: 4130-4133.
- [151] Guillaume M, Juste L, Lenot X, et al. NMF hyperspectral unmixing of the sea bottom: influence of the adjacency effects, model and method [C]//2018 9th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), September 23-26, 2018, Amsterdam, Netherlands. New York: IEEE Press, 2018: 1-5.
- [152] Dörnhöfer K, Oppelt N. Remote sensing for lake research and monitoring: recent advances [J]. Ecological Indicators, 2016, 64: 105-122.
- [153] Jarchow C J, Sigafus B H, Muths E, et al. Using full and partial unmixing algorithms to estimate the inundation extent of small, isolated stock ponds in an arid landscape[J]. Wetlands, 2020, 40(3): 563-575.
- [154] Cortés G, Giroto M, Margulis S A. Analysis of sub-pixel snow and ice extent over the extratropical Andes using spectral unmixing of historical Landsat imagery [J]. Remote Sensing of Environment, 2014, 141: 64-78.
- [155] Masson T, Mura M D, Dumont M, et al. Snow cover estimation from image time series based on spectral unmixing[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(3): 337-341.
- [156] Michishita R, Jiang Z B, Xu B. Monitoring two decades of urbanization in the Poyang Lake area, China through spectral unmixing [J]. Remote Sensing of Environment, 2012, 117: 3-18.
- [157] Dutta D, Rahman A, Kundu A. Growth of Dehradun city: an application of linear spectral unmixing (LSU) technique using multi-temporal landsat satellite data sets [J]. Remote Sensing Applications: Society and Environment, 2015, 1: 98-111.
- [158] Demarchi L, Canters F, Chan J C W, et al. Multiple endmember unmixing of CHRIS/proba imagery for mapping impervious surfaces in urban and suburban environments[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(9):

- 3409-3424.
- [159] Yang J, Li P J. Impervious surface extraction in urban areas from high spatial resolution imagery using linear spectral unmixing[J]. *Remote Sensing Applications: Society and Environment*, 2015, 1: 61-71.
- [160] Yang J, He Y H, Caspersen J. Fully constrained linear spectral unmixing based global shadow compensation for high resolution satellite imagery of urban areas [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2015, 38: 88-98.
- [161] Yang J, He Y H. Automated mapping of impervious surfaces in urban and suburban areas: linear spectral unmixing of high spatial resolution imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2017, 54: 53-64.
- [162] Feng B Y, Wang J F. Evaluation of unmixing methods for impervious surface area extraction from simulated EnMAP imagery [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(6): 1777-1798.
- [163] Deng C B, Wu C S. Estimating very high resolution urban surface temperature using a spectral unmixing and thermal mixing approach [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2013, 23: 155-164.
- [164] Meganem I, Deville Y, Hosseini S, et al. Linear-quadratic blind source separation using NMF to unmix urban hyperspectral images [J]. *IEEE Transactions on Signal Processing*, 2014, 62(7): 1822-1833.
- [165] Gan Y Q. Research and application of spectral unmixing method for hyperspectral remote sensing imagery[D]. Beijing: University of Chinese Academy of Sciences(Xi'an Institute of Optics and Precision Mechanics, CAS), 2018.
甘玉泉. 高光谱遥感图像光谱解混方法研究及其应用[D]. 北京: 中国科学院大学(中国科学院西安光学精密机械研究所), 2018.
- [166] Addabbo P, Di-Bisceglie M, Galdi C. The unmixing of atmospheric trace gases from hyperspectral satellite data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(1): 320-329.
- [167] Sun Q Q. Research of spectral unmixing technique and its application in the oil quantity analysis[D]. Dalian: Dalian Maritime University, 2012.
孙晴晴. 光谱解混技术的研究及其在油量分析中的应用[D]. 大连: 大连海事大学, 2012.
- [168] Soydan H, Koz A, Düzgün H Ş. Identification of hydrocarbon microseepage induced alterations with spectral target detection and unmixing algorithms [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2019, 74: 209-221.
- [169] Magendran T, Sanjeevi S. Hyperion image analysis and linear spectral unmixing to evaluate the grades of iron ores in parts of Noamundi, Eastern India[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2014, 26: 413-426.
- [170] Ayoobi I, Tangestani M H. Evaluation of subpixel unmixing algorithms in mapping the porphyry copper alterations using EO-1 Hyperion data, a case study from SE Iran [J]. *Remote Sensing Applications: Society and Environment*, 2018, 10: 120-127.
- [171] Zhang X, Shang K, Cen Y, et al. Estimating ecological indicators of Karst rocky desertification by linear spectral unmixing method [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2014, 31: 86-94.
- [172] Parente M, Mustard J F, Murchie S, et al. Robust unmixing of hyperspectral images: application to mars[C]//2011 IEEE International Geoscience and Remote Sensing Symposium, July 24-29, 2011, Vancouver, BC, Canada. New York: IEEE Press, 2011: 1291-1294.
- [173] Zambon F, Tosi F, de Sanctis M C, et al. Testing linear spectral unmixing on laboratory mixtures: application to VIR data for asteroid Vesta[C]//2014 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), June 24-27, 2014, Lausanne, Switzerland. New York: IEEE Press, 2014: 1-4.
- [174] Lin H L, Zhang X, Yang Y Z, et al. Retrieval of the mineral abundance and particle size distribution at the landing site of Yutu rover with hyperspectral remote sensing data[J]. *Journal of Remote Sensing*, 2019, 23(5): 831-840.
林红磊, 张霞, 杨亚洲, 等. 玉兔号月球车巡视点矿物丰度及粒径分布高光谱反演[J]. *遥感学报*, 2019, 23(5): 831-840.
- [175] Yin J H, Huang C Y, Luo X Y, et al. Automatic endmember bundle unmixing methodology for lunar regional area mineral mapping [J]. *Icarus*, 2019, 319: 349-362.
- [176] Nadrigny F, Rivals I, Hirrlinger P G, et al. Detecting fluorescent protein expression and co-localisation on single secretory vesicles with linear spectral unmixing[J]. *European Biophysics Journal*, 2006, 35(6): 533-547.
- [177] Montcuquet A S, Hervé L, Navarro F, et al. *In*

- in vivo* fluorescence spectra unmixing and autofluorescence removal by sparse nonnegative matrix factorization [J]. IEEE Transactions on Biomedical Engineering, 2011, 58(9): 2554-2565.
- [178] Zhao Y, Hu C, Peng J L, et al. Target-to-background separation for spectral unmixing in *in-vivo* fluorescence imaging [J]. Journal of Shanghai Jiaotong University (Science), 2014, 19(5): 600-611.
- [179] Geyer A, Lorenzer C, Gehrig S, et al. Fluorescence- and computed tomography for assessing the biodistribution of siRNA after intratracheal application in mice [J]. International Journal of Pharmaceutics, 2017, 525(2): 359-366.
- [180] Liu X, Liu F, Zhang Y, et al. Unmixing dynamic fluorescence diffuse optical tomography images with independent component analysis [J]. IEEE Transactions on Medical Imaging, 2011, 30(9): 1591-1604.
- [181] Ran C Z, Moore A. Spectral unmixing imaging of wavelength-responsive fluorescent probes: an application for the real-time report of amyloid beta species in Alzheimer's disease [J]. Molecular Imaging and Biology, 2012, 14(3): 293-300.
- [182] Cheng W Y, Larson J M, Samet J M. Monitoring intracellular oxidative events using dynamic spectral unmixing microscopy [J]. Methods, 2014, 66(2): 345-352.
- [183] Hedegaard M, Matthäus C, Hassing S, et al. Spectral unmixing and clustering algorithms for assessment of single cells by Raman microscopic imaging [J]. Theoretical Chemistry Accounts, 2011, 130(4/5/6): 1249-1260.
- [184] Bergner N, Krafft C, Geiger K D, et al. Unsupervised unmixing of Raman microspectroscopic images for morphochemical analysis of non-dried brain tumor specimens [J]. Analytical and Bioanalytical Chemistry, 2012, 403(3): 719-725.
- [185] Bergner N, Medyukhina A, Geiger K D, et al. Hyperspectral unmixing of Raman micro-images for assessment of morphological and chemical parameters in non-dried brain tumor specimens [J]. Analytical and Bioanalytical Chemistry, 2013, 405(27): 8719-8728.
- [186] Lobanova E G, Lobanov S V. Efficient quantitative hyperspectral image unmixing method for large-scale Raman micro-spectroscopy data analysis [J]. Analytica Chimica Acta, 2019, 1050: 32-43.
- [187] Du B, Wang N, Zhang L P, et al. Hyperspectral medical images unmixing for cancer screening based on rotational independent component analysis [M] // Sun C Y, Fang F, Zhou Z H, et al. Intelligence science and big data engineering. Lecture notes in computer science. Heidelberg: Springer, 2013, 8261: 336-343.
- [188] Lopes M B, Bioucas-Dias J M, Figueiredo M A T, et al. Spectral unmixing via minimum volume simplices: application to near infrared spectra of counterfeit tablets [C] // 2009 First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, August 26-28, 2009, Grenoble, France. New York: IEEE Press, 2009: 1-4.
- [189] Tzoumas S, Deliolanis N C, Morscher S, et al. Unmixing molecular agents from absorbing tissue in multispectral optoacoustic tomography [J]. IEEE Transactions on Medical Imaging, 2014, 33(1): 48-60.
- [190] Ding L, Deán-Ben X L, Burton N C, et al. Constrained inversion and spectral unmixing in multispectral optoacoustic tomography [J]. IEEE Transactions on Medical Imaging, 2017, 36(8): 1676-1685.
- [191] Skjeltvareid M H, Heia K, Olsen S H, et al. Detection of blood in fish muscle by constrained spectral unmixing of hyperspectral images [J]. Journal of Food Engineering, 2017, 212: 252-261.
- [192] Collewet G, Moussaoui S, Deligny C, et al. Multi-tissue partial volume quantification in multi-contrast MRI using an optimised spectral unmixing approach [J]. Magnetic Resonance Imaging, 2018, 49: 39-46.
- [193] Kannan R, Ievlev A V, Laanait N, et al. Deep data analysis via physically constrained linear unmixing: universal framework, domain examples, and a community-wide platform [J]. Advanced Structural and Chemical Imaging, 2018, 4(1): 6.
- [194] Prats-Mateu B, Felhofer M, de Juan A, et al. Multivariate unmixing approaches on Raman images of plant cell walls: new insights or overinterpretation of results? [J]. Plant Methods, 2018, 14: 52.
- [195] Grabowski B, Masarczyk W, Głomb P, et al. Automatic pigment identification from hyperspectral data [J]. Journal of Cultural Heritage, 2018, 31: 1-12.
- [196] Zhang Y, Sun C B, Yang D, et al. Multiband imaging and linear unmixing of optical fiber intrusion signal [J]. Optik, 2018, 167: 60-72.