



基于协同稀疏解混的高光谱图像变化检测方法

蒋祥明, 高天启, 公茂果*, 蒋汾龙, 范晓龙

西安电子科技大学工程学院协同智能系统教育部重点实验室, 西安 710071

* 通信作者. E-mail: Gong@ieee.org

收稿日期: 2022-10-08; 修回日期: 2022-12-16; 接受日期: 2023-02-13; 网络出版日期: 2023-11-13

国家自然科学基金 (批准号: 62106187, 62036006) 和中央高校基本科研业务费 (批准号: ZYTS23136) 资助项目

摘要 高光谱图像变化检测可以考察地物随时间的变化, 而高光谱图像解混可以分析地物的物质 (亚像元级) 构成. 因此, 将高光谱图像解混引入到高光谱图像变化检测中, 不仅可以考察地物发生变化与否, 还能利用地物成分随时间的演变信息得到更精准的检测结果. 本文首先从高光谱图像的线性混合模型出发, 利用稀疏解混的思想对解混模型进行简化, 进而采用直观的变化向量分析思路, 逐步建立了基于协同稀疏解混的无约束高光谱变化检测模型. 其次, 本文基于子空间匹配的思想构造了匹配光谱库, 以增加解混过程中光谱库和像元光谱的匹配程度. 然后, 本文设计了交替方向乘子法对所建立的无约束变化检测模型进行求解. 最后, 本文设计了自适应的丰度截断策略对解混结果进行集成以得到最终的变化检测结果. 在仿真及真实数据集上的对比实验结果表明: 本方法不仅可以得到高精度的变化检测结果, 还可以在虚检和漏检之间寻求良好的平衡.

关键词 协同稀疏解混, 变化检测, 匹配光谱库, 交替方向乘子法, 自适应丰度截断

1 引言

高光谱图像作为光学遥感影像主流的数据形式之一, 不仅可以提供地物目标在空间维度的分布信息, 还可以提供它们在光谱维度的吸收和散射信息. 随着光谱成像技术的发展, 高光谱遥感已经可以在电磁波谱的紫外至红外波长范围内以纳米级分辨率成像^[1]. 由于物质对光的选择性吸收效应, 不同的物质对于相同的入射光会产生不同的光谱散射效果, 进而造成了不同物质具有不同光谱散射曲线的“指纹”现象. 这一现象赋予了高光谱图像对地物目标的独特区分和识别能力, 极大促进了高光谱遥感在自然灾害评估、农林资源监测、地质勘探、军事侦察、医学检测、化学计量等领域的实际应用^[2], 催生了一系列高光谱图像处理技术, 如: 高光谱图像特征选择与提取、高光谱图像分割、高光谱图像分类、高光谱图像解混、高光谱图像异常检测、高光谱图像变化检测等^[3]. 其中, 高光谱图像变化检测可

引用格式: 蒋祥明, 高天启, 公茂果, 等. 基于协同稀疏解混的高光谱图像变化检测方法. 中国科学: 信息科学, 2023, 53: 2283–2300, doi: 10.1360/SSI-2022-0388
Jiang X M, Gao T Q, Gong M G, et al. Collaborative sparse unmixing-based hyperspectral change detection method (in Chinese). Sci Sin Inform, 2023, 53: 2283–2300, doi: 10.1360/SSI-2022-0388

以检测出地物是否随时间发生了变化^[4], 而高光谱图像解混可以用于分析地物的具体构成成分^[5]. 因此, 将高光谱解混思想引入到变化检测中, 不仅可以检测出地物是否发生变化, 还可以得到地物成分的具体演变细节. 本文主要研究基于解混的高光谱图像变化检测模型及其高效求解算法, 以挖掘解混信息在变化检测中的效用.

目前, 高光谱图像的变化检测方法按照目标的精细度主要可以分为像元级变化检测、对象级变化检测^[6]和亚像元级变化检测 3 类.

像元级变化检测方法是研究最为广泛的一类, 它主要通过分析对应像元的光谱特征差异来判断该像元是否发生变化. 主流的像元级变化检测方法有变化向量分析类方法、影像变换分析类方法及深度特征分析类方法等. 变化向量分析类方法主要通过波段差值获取变化向量, 并根据变化向量的长度和方向判断变化强度和类别, 代表性方法有变化向量分析法 (change vector analysis, CVA)^[7]、稳健变化向量分析法 (robust VCA, RCVA)^[8]、压缩变化向量分析法 (compressed VCA, C²VA)^[9] 等. 影像变换分析类方法主要根据图像的数据结构构造特定的特征空间, 以突出可能的变化并抑制虚假变化, 提高变化检测精度, 此类方法的代表性工作有基于主成分分析^[10,11]和基于独立成分分析的后分类方法^[12,13], 有基于典型相关性分析的多元变化检测方法 (multivariate alteration detection, MAD)^[14,15], 也有基于正交子空间投影的距离判别算法^[16]等. 而深度特征分析类算法主要指基于深度学习的特征提取与变化检测算法, 这类算法虽然兴起时间较晚, 但却由于出色的检测精度而受到广泛的研究. 目前, 已经应用于高光谱变化检测的深度神经网络有循环卷积神经网络^[17]、图卷积神经网络^[18]、3D 卷积神经网络^[19]、跨层卷积神经网络^[20]、卷积长短记忆网络^[21]等. 而且, 为了提升变化检测性能, 学者们还陆续建立了基于双向重建机制^[22]、对抗学习机制^[23]、注意力机制^[24]、自校准机制^[25]的深度神经网络模型.

对象级变化检测方法考虑到单个像元通常不是真实的地物对象, 因此研究像元的变化不如研究地物对象的变化更具实际意义. 对象级变化检测方法大致可以分为直接对象比较法、对象分类后比较法、多时相对象检测法等. 其中, 直接对象比较法通常先从一幅图像中提取出对象, 然后从另一幅图像中找到对应的位置进行匹配分析^[26]. 在这一类方法中, 位置的匹配搜索对检测结果至关重要. 对象分类后比较法是一种典型的先分类后检测方法, 它首先对两幅图像进行单独分割得到各自所包含的地物对象, 然后对两幅图像中的地物对象进行变化检测^[27~29]. 这类方法的检测精度严格依赖于地物对象的分割精度, 且单独分割所得到的对象形状和尺寸在两幅图像中很可能不一致. 因此, 学者们又提出了多时相对象检测法, 通过将多时相影像堆叠后同时分割, 以获得相同尺寸和形状的对象并进行比较^[30,31]. 但此类方法对影像的配准要求较高, 局部的失配都有可能引起大范围的误检. 为了进一步提升变化检测精度, 一些学者进一步拓展了以上方法的思想. 例如, Zhang 等^[32]利用双向映射思想交互地对两幅图像进行直接对象比较, 并通过加权的方式聚合检测结果; Du 等^[33]采用迭代慢特征分析和贝叶斯 (Bayes) 软融合策略提升了对象分类后比较算法的检测精度.

亚像元级变化检测相较于像元级变化检测和对对象级变化检测更加精细, 它不仅可以检测每个像元对应的地物是否发生变化, 还可以检测地物成分的具体变化情况. 因此, 亚像元级变化检测能够自然地利用到高光谱图像的解混信息. 具体地, Wang 等^[34]首先从多时相高光谱图像中利用亚像元映射获得精细空间分辨率土地覆盖制图, 然后通过比较它们的类别标签获得亚像元级变化检测结果. 紧接着, 他们又对低分辨率图像进行光谱解混, 并参考高分辨率图像对解混结果进行亚像元映射, 然后对比亚像元映射结果和高分辨率图像以获得亚像元级变化检测结果^[35]. 相对来说, Ertürk 等^[36~38]利用光谱库或自词典进行光谱稀疏解混并直接比较丰度的亚像元级变化检测方法显得更为简单, 但多时相影像的解混颇为耗时且容易引入虚假变化. Liu 等^[39]建立了一个多时相光谱混合模型, 并基于该模型提

出了一种多时相端元提取和分组框架,进而根据变化端元的丰度生成最终的变化检测结果. Wu 等^[40]首先在亚像元级变化检测的基础上解决了单个像元中端元组合变化被忽视的问题. 随后,他们又针对分辨率不同的高光谱影像提出了一种基于有监督 BP (back propagation) 神经网络的亚像元级变化检测方法,以充分利用高分辨率图像土地覆盖信息^[41]. Yuan 等^[42]基于局部线性嵌入和稀疏字典表示思想建立了多光谱变化检测的联合字典学习方法,可以自适应选择合适阈值以区分变化和未变化. Du 等^[43]提出了基于联合稀疏表示的高光谱异常变化检测方法,通过对应像元的字典表示差异来衡量变化的强度. Deng 等^[44]利用时间序列模型估计和部分土地覆盖估计实现了不透水城市路面的持续亚像元监测. Zhang 等^[45]首先利用多时相高光谱图像的联合解混和主成分分析相互指导来提升变化检测精度. 随后,他们对差异图进行主成分分析,并结合多时相影像光谱解混信息同步获得二值和多类变化检测结果^[46].

然而,以上亚像元级变化检测方法要么将高光谱解混作为辅助检测的工具,要么直接运用已有高光谱解混技术进行后变化检测. 这两种思路不仅无法充分挖掘高光谱图像的亚像元级构成信息,无法高效地利用两幅图像在端元构成上的协同一致性,还会额外增加问题的整体计算复杂度. 即使是 Liu 等^[39]提出的多时相光谱混合模型也面临着模型约束较多、图像尺寸加倍、计算复杂度升高等局限. 为了解决这些问题,本文率先回顾了高光谱图像的线性混合模型和稀疏解混思路,并根据多时相高光谱图像的稀疏解混模型建立了基于协同解混的无约束高光谱图像变化检测模型. 该模型直接面向多时相高光谱影像的差异图,摆脱了伴随高光谱解混模型的非负、和一 (sum-to-one) 约束,极大简化了模型求解的复杂度. 为了缓解稀疏解混过程中光谱库和差异图不匹配的问题,本文基于子空间匹配思想构造了匹配光谱库,以便充分利用光谱库和图像中可能存在的纯像元. 此外,本文利用拉格朗日 (Lagrange) 乘子法求解所建立的模型,并设计了自适应丰度截断策略对解混结果进行集成,以得到最终变化检测结果. 最后,在仿真及真实数据集上的对比实验结果验证了所提出方法的简单有效性.

本文在第 2 节回顾高光谱图像的稀疏解混模型,为第 3 节中建立协同稀疏的高光谱图像变化检测模型奠定基础. 第 4 节给出求解变化检测模型的算法框架,并逐步介绍匹配光谱库的构造、拉格朗日乘子法的迭代步骤以及自适应的丰度截断策略. 第 5 节在多个仿真及真实数据集上通过对比实验验证所提出方法的有效性. 第 6 节对工作进行总结和展望.

2 高光谱稀疏解混模型

受限于高光谱探测器的高程分辨率及地物目标分布的复杂性,高光谱图像中普遍存在着混合像元. 在假定混合机理为线性的情况下,高光谱图像的像元光谱可以近似地表示为一系列基本物质光谱 (端元) 的线性组合,即

$$\begin{aligned} \mathbf{Y} &= \mathbf{M}\mathbf{S} + \mathbf{N} \\ \text{s.t. } \mathbf{S} &\geq 0, \mathbf{1}_p^T \mathbf{S} = \mathbf{1}_n^T, \end{aligned} \quad (1)$$

其中, $\mathbf{Y}$ 是 $L \times n$ 维矩阵,表示波段数为 L 、像元数为 n 的重排高光谱图像; $\mathbf{M}$ 表示波段数为 L 、端元数为 p 的 $L \times p$ 维端元矩阵, $\mathbf{S}$ 表示 $\mathbf{M}$ 中每个端元在 $\mathbf{Y}$ 的每个像元中的丰度所构成的 $p \times n$ 维矩阵, $\mathbf{N}$ 表示建模误差和噪声. 为了使线性混合模型更具实际物理意义,模型 (1) 还对丰度矩阵 $\mathbf{S}$ 施加了非负、和一约束,要求所有端元在每个像元中的丰度非负且和为 1.

线性高光谱解混是模型 (1) 的逆过程,它通常包含端元提取和丰度估计两个基本任务,即:从高光谱图像 $\mathbf{Y}$ 中估计出端元和丰度矩阵 $\mathbf{M}$, $\mathbf{S}$, 这是一个较为复杂的约束多变量矩阵分解问题. 随着光谱库的构建与不断完善,学者们提出了简化该解混问题的方法,即:假定高光谱图像 $\mathbf{Y}$ 中的端元包含在

一个 $L \times q$ ($q \gg p$) 维的过完备光谱库 $\mathbf{A}$ 中, 则端元矩阵 $\mathbf{M}$ 和丰度矩阵 $\mathbf{S}$ 的估计可同时归结为高光谱图像 $\mathbf{Y}$ 关于光谱库 $\mathbf{A}$ 的稀疏回归问题. 假定回归系数矩阵为 $\mathbf{X}$, 则有

$$\begin{aligned} \mathbf{Y} &= \mathbf{A}\mathbf{X} + \mathbf{N} \\ \text{s.t. } \mathbf{X} &\geq 0, \mathbf{1}_q^T \mathbf{X} = \mathbf{1}_n^T. \end{aligned} \quad (2)$$

由于光谱库 $\mathbf{A}$ 的过完备性和光谱特征间的互相干性, 模型 (2) 中 $\mathbf{X}$ 的求解通常是一个不适定问题. 为了得到具有实际物理意义的解, 通常需要对矩阵 $\mathbf{X}$ 施加正则约束.

在模型 (2) 的推理过程中, 我们假定了端元矩阵 $\mathbf{M}$ 位于过完备的光谱库 $\mathbf{A}$ 中, 且其端元数 p 远小于光谱库 $\mathbf{A}$ 中的光谱特征个数 q . 因此, 高光谱图像 $\mathbf{Y}$ 关于光谱库 $\mathbf{A}$ 的系数矩阵 $\mathbf{X}$ 应当具有行稀疏的特性. 故模型 (2) 所对应的稀疏解混模型为

$$\begin{aligned} \min_{\mathbf{X}} \quad & \frac{1}{2} \|\mathbf{Y} - \mathbf{A}\mathbf{X}\|_F^2 + \lambda \|\mathbf{X}\|_{2,0} \\ \text{s.t. } \mathbf{X} &\geq 0, \mathbf{1}_q^T \mathbf{X} = \mathbf{1}_n^T, \end{aligned} \quad (3)$$

其中, $\|\mathbf{X}\|_{2,0} = \|\sqrt{\sum_{j=1}^n X_{i,j}^2}\|_0$ 是施加在矩阵 $\mathbf{X}$ 上的行稀疏正则算子, λ 是正则参数. 由于该正则算子非凸, 为了方便求解, 学者们通常将其中的 l_0 范数松弛为 l_1 范数, 将模型 (3) 转化为

$$\begin{aligned} \min_{\mathbf{X}} \quad & \frac{1}{2} \|\mathbf{Y} - \mathbf{A}\mathbf{X}\|_F^2 + \lambda \|\mathbf{X}\|_{2,1} \\ \text{s.t. } \mathbf{X} &\geq 0, \mathbf{1}_q^T \mathbf{X} = \mathbf{1}_n^T, \end{aligned} \quad (4)$$

然后再采用解析类方法进行求解. 其中, $\|\mathbf{X}\|_{2,1} = \|\sqrt{\sum_{j=1}^n X_{i,j}^2}\|_1$ 也具有诱导矩阵行稀疏的能力.

3 协同稀疏的高光谱变化检测建模

本节将基于高光谱混合模型 (2) 及其稀疏解混模型 (4) 建立协同稀疏的高光谱图像变化检测模型. 具体地, 给定 t_1, t_2 时刻校准后的 $L \times n$ 维高光谱图像 $\mathbf{Y}_1, \mathbf{Y}_2$, 若 $\mathbf{Y}_1$ 和 $\mathbf{Y}_2$ 中所含的端元均包含在一个 $L \times q$ 维光谱库 $\mathbf{A}$ 中, 则根据模型 (2) 可知, 存在矩阵 $\{\mathbf{X}_1, \mathbf{N}_1\}$ 和 $\{\mathbf{X}_2, \mathbf{N}_2\}$, 使得

$$\begin{aligned} \mathbf{Y}_1 &= \mathbf{A}\mathbf{X}_1 + \mathbf{N}_1 \\ \text{s.t. } \mathbf{X}_1 &\geq 0, \mathbf{1}_q^T \mathbf{X}_1 = \mathbf{1}_n^T, \end{aligned} \quad (5)$$

并且

$$\begin{aligned} \mathbf{Y}_2 &= \mathbf{A}\mathbf{X}_2 + \mathbf{N}_2 \\ \text{s.t. } \mathbf{X}_2 &\geq 0, \mathbf{1}_q^T \mathbf{X}_2 = \mathbf{1}_n^T. \end{aligned} \quad (6)$$

将模型 (6) 减去模型 (5) 可得

$$\begin{aligned} \mathbf{Y}^\delta &\triangleq \mathbf{Y}_2 - \mathbf{Y}_1 = \mathbf{A}(\mathbf{X}_2 - \mathbf{X}_1) + (\mathbf{N}_2 - \mathbf{N}_1) \\ \text{s.t. } \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{bmatrix} &\geq 0, \mathbf{1}_q^T \begin{bmatrix} \mathbf{X}_1 & \mathbf{X}_2 \end{bmatrix} = \mathbf{1}_{2n}^T. \end{aligned} \quad (7)$$

类似地, 若令 $\mathbf{X}^\delta \triangleq \mathbf{X}_2 - \mathbf{X}_1$, $\mathbf{N}^\delta \triangleq \mathbf{N}_2 - \mathbf{N}_1$, 则模型 (7) 可以简化为以下无约束线性混合模型:

$$\mathbf{Y}^\delta = \mathbf{A}\mathbf{X}^\delta + \mathbf{N}^\delta, \quad (8)$$

这里, 尽管 $\mathbf{X}_1, \mathbf{X}_2$ 满足非负、和一约束, 但它们的差值 $\mathbf{X}^\delta$ 未必再满足非负、和一约束. 关于模型 (8), 有如下直观理解.

(1) 若 $\mathbf{Y}_1$ 和 $\mathbf{Y}_2$ 中所含的端元均包含在一个光谱库 $\mathbf{A}$ 中, 则它们的差异图 $\mathbf{Y}^\delta$ 中所含的端元也包含在光谱库 $\mathbf{A}$ 中, 因此 $\mathbf{Y}^\delta$ 和 $\mathbf{A}$ 仍具有线性关系.

(2) 由于 $\mathbf{Y}_1$ 和 $\mathbf{Y}_2$ 中所含的端元数目均远小于光谱库 $\mathbf{A}$ 中的光谱特征数目, 则它们的差异图 $\mathbf{Y}^\delta$ 中所含的端元数目也远小于光谱库 $\mathbf{A}$ 中的光谱特征数目.

由于光谱库 $\mathbf{A}$ 的过完备性和光谱特征间的互相干性, 模型 (8) 中 $\mathbf{X}^\delta$ 的求解同样是一个不适定问题. 但基于以上关于模型 (8) 的第 (2) 条直观理解, 不难判断 $\mathbf{X}^\delta$ 同样具有行稀疏的特性. 因此, 可以类似模型 (4) 对 $\mathbf{X}^\delta$ 施加正则约束, 得到如下无约束高光谱图像变化检测模型:

$$\min_{\mathbf{X}^\delta} \frac{1}{2} \|\mathbf{Y}^\delta - \mathbf{A}\mathbf{X}^\delta\|_F^2 + \lambda \|\mathbf{X}^\delta\|_{2,1}. \quad (9)$$

由于 $\|\cdot\|_{2,1}$ 具有协同诱导行稀疏的能力, 所以称模型 (9) 为协同稀疏的高光谱变化检测模型.

4 算法框架

本节将逐步给出模型 (9) 的求解算法框架. 在第 3 节中, 为了建模方便, 直接假定所提供的高光谱图像 $\mathbf{Y}_1$ 和 $\mathbf{Y}_2$ 是校准后的, 但实际给定的高光谱图像通常因为探测条件的不同而具有幅值上的差异. 因此, 为了避免检测到虚假变化, 需要首先对两幅图像做幅值校准. 本文使用以下归一化方法对两幅图像做幅值校准:

$$\mathbf{Y}_i = \mathbf{Y}_i / \max(\max(\mathbf{Y}_i)), \quad i = 1, 2. \quad (10)$$

每幅图像通过除以自身最大的光谱散射值, 可以将所有散射光谱的幅值限制在 1 以下, 以此达到间接校准两幅图像的目的. 目前, 关于高光谱图像校准的技术已经相当丰富, 但不是本文重点, 在此不做深入解读.

4.1 匹配光谱库

图像完成幅值校准后, 便可以构造差异图 $\mathbf{Y}^\delta \triangleq \mathbf{Y}_2 - \mathbf{Y}_1$, 并求解模型 (9). 一般情况下, 光谱库 $\mathbf{A}$ 的探测条件和多时相高光谱影像的探测条件也是不同的, 因此它们之间可能存在光谱差异. 为了更好地检测多时相影像的地物变化细节, 本小节基于子空间匹配思想修剪光谱库, 尽可能保留与图像相匹配的端元, 对差异图进行解混. 匹配光谱库的构造方法如下:

$$\mathbf{A}_m = \gamma_{\text{MUSIC}}(\mathbf{A}, \mathbf{Y}^\delta, K), \quad (11)$$

其中, γ_{MUSIC} 可以根据 $\mathbf{A}$ 中光谱特征在 $\mathbf{Y}^\delta$ 所处子空间上的投影误差大小对其进行剪枝^[47], 以得到与 $\mathbf{Y}^\delta$ 相匹配的光谱库, 而 K 则表示修剪后的匹配光谱库 $\mathbf{A}_m$ 中所保留的端元个数. 为了进一步增加 $\mathbf{A}_m$ 与 $\mathbf{Y}^\delta$ 的匹配度, 本文还采用了文献 [48] 中所提供的匹配校准方法对差异图进行了修正.

4.2 ADMM (alternating direction method of multiplier) 算法

基于匹配光谱库 $\mathbf{A}_m$, 模型 (9) 有以下等价形式:

$$\min_{\mathbf{U}, \mathbf{V}} \frac{1}{2} \|\mathbf{A}_m \mathbf{U} - \mathbf{Y}^\delta\|_F^2 + \lambda \|\mathbf{V}\|_{2,1}, \quad \text{s.t. } \mathbf{V} = \mathbf{U}, \quad (12)$$

其闭式形式为

$$\min_{\mathbf{U}, \mathbf{V}} \frac{1}{2} \|\mathbf{A}_m \mathbf{U} - \mathbf{Y}^\delta\|_F^2 + \lambda \|\mathbf{V}\|_{2,1}, \quad \text{s.t. } \mathbf{U} - \mathbf{V} = \mathbf{0}. \quad (13)$$

进一步地, 模型 (12) 的增广拉格朗日函数为

$$\mathcal{L}(\mathbf{U}, \mathbf{V}, \mathbf{D}) \triangleq \frac{1}{2} \|\mathbf{A}_m \mathbf{U} - \mathbf{Y}^\delta\|_F^2 + \lambda \|\mathbf{V}\|_{2,1} + \frac{\mu}{2} \|\mathbf{U} - \mathbf{V} - \mathbf{D}\|_F^2, \quad (14)$$

其中, $\mu > 0$ 为正则参数. 从函数 (14) 可得, ADMM 算法的迭代方程为

$$\mathbf{U}^{(k+1)} = \arg \min_{\mathbf{U}} \mathcal{L}(\mathbf{U}, \mathbf{V}^{(k)}, \mathbf{D}^{(k)}) = \arg \min_{\mathbf{U}} \frac{1}{2} \|\mathbf{A}_m \mathbf{U} - \mathbf{Y}^\delta\|_F^2 + \frac{\mu}{2} \|\mathbf{U} - \mathbf{V}^{(k)} - \mathbf{D}^{(k)}\|_F^2, \quad (15)$$

$$\mathbf{V}^{(k+1)} = \arg \min_{\mathbf{V}} \mathcal{L}(\mathbf{U}^{(k+1)}, \mathbf{V}, \mathbf{D}^{(k)}) = \arg \min_{\mathbf{V}} \lambda \|\mathbf{V}\|_{2,1} + \frac{\mu}{2} \|\mathbf{U}^{(k+1)} - \mathbf{V} - \mathbf{D}^{(k)}\|_F^2, \quad (16)$$

$$\mathbf{D}^{(k+1)} = \mathbf{D}^{(k)} - \mathbf{U}^{(k+1)} + \mathbf{V}^{(k+1)}. \quad (17)$$

进一步地, 由导数法和阈值法^[49]可分别得到 $\mathbf{U}$, $\mathbf{V}$ 的迭代式

$$\mathbf{U}^{(k+1)} = (\mathbf{A}_m^T \mathbf{A}_m + \mu \mathbf{I})^{-1} [\mathbf{A}_m^T \mathbf{Y}^\delta + \mu(\mathbf{V}^{(k)} + \mathbf{D}^{(k)})], \quad (18)$$

$$\mathbf{V}_r^{(k+1)} = \text{Vect-soft} \left(\mathbf{U}_r^{(k+1)} - \mathbf{D}_r^{(k)}, \frac{\lambda}{\mu} \right), \quad (19)$$

其中, $\mathbf{V}_r^{(k+1)}$, $\mathbf{U}_r^{(k+1)}$, $\mathbf{D}_r^{(k)}$ 分别表示 $\mathbf{V}^{(k+1)}$, $\mathbf{U}^{(k+1)}$, $\mathbf{D}^{(k)}$ 的第 r 行, 且

$$\text{Vect-soft}(\mathbf{b}, \tau) = \frac{\max\{\|\mathbf{b}\|_2 - \tau, 0\}}{\max\{\|\mathbf{b}\|_2 - \tau, 0\} + \tau} \mathbf{b}. \quad (20)$$

最后, 算法 1 总结了模型 (12) 的 ADMM 求解流程.

Algorithm 1 ADMM algorithm for solving the model (12)

Input: $\mathbf{A}_m$, $\mathbf{Y}^\delta$;

Initialization: $k = 0$, $\mu > 0$, $\lambda > 0$, $\mathbf{U}^{(0)}$, $\mathbf{V}^{(0)}$, $\mathbf{D}^{(0)}$;

1: **while** stopping criterion is not met **do**

2: Update $\mathbf{U}^{(k+1)}$ using Eq. (18);

3: Update $\mathbf{V}^{(k+1)}$ using Eq. (19);

4: Update $\mathbf{D}^{(k+1)}$ using Eq. (17);

5: $k = k + 1$.

6: **end while**

Output: $\mathbf{X}^\delta = \mathbf{U}^{(k)}$.

4.3 丰度截断策略

然而, 受限于 $l_{2,1}$ 范数的特性, 模型 (12) 的解通常含有渐进稀疏的行, 这些行所识别出的端元未必包含在差异图中. 因此, 需要研究适当的丰度截断策略, 排除渐进稀疏行所识别的端元. 文献 [50, 51] 采用人工阈值法移除丰度矩阵中微小的非零值, 但阈值的人工选择仍然是个难题, 不具备易用性和可推广性.

本文采用大津法 (Otsu) 对绝对丰度矩阵进行二值化分割 [52], 可以自适应地确定使类间方差达到最大时的阈值, 进而利用该阈值截断丰度矩阵并确定所识别的端元, 具体过程如下:

(1) 采用大津法对绝对丰度矩阵进行二值化分割, 得到分割阈值

$$T = \text{Otsu}(|\mathbf{X}^\delta|), \quad (21)$$

其中, $|\cdot|$ 表示按元素取绝对值, T 为大津法所得的分割阈值.

(2) 基于分割阈值 T 对丰度矩阵进行截断处理, 即

$$\mathbf{X}_{i,j}^\delta = \begin{cases} 0, & |\mathbf{X}_{i,j}^\delta| \leq T, \\ \mathbf{X}_{i,j}^\delta, & |\mathbf{X}_{i,j}^\delta| > T, \end{cases} \quad (22)$$

其中, $\mathbf{X}_{i,j}^\delta$ 表示丰度矩阵 $\mathbf{X}^\delta$ 的第 i 行、 j 列的元素.

(3) 确定 $\mathbf{X}^\delta$ 非零行所对应的 $\mathbf{A}_m$ 中的列, 即为所识别的变化端元. 具体地, $\mathbf{X}^\delta$ 的非零行索引为

$$\text{Idx} = \left\{ i \mid \sum_j |\mathbf{X}_{i,j}^\delta| > 0 \right\}, \quad (23)$$

其所识别的变化端元和端元在各像元中的变化量分别为

$$\mathbf{M} = \mathbf{A}_m(:, \text{Idx}), \quad \mathbf{S} = \mathbf{X}^\delta(\text{Idx}, :). \quad (24)$$

最后, 通过累计每个像元中各变化端元所对应丰度的绝对变化量, 便可得到多时相遥感影像的变化强度向量, 即

$$\mathbf{D} = \sum_i |\mathbf{S}_{i,j}|. \quad (25)$$

进一步地, 通过对变化强度向量 $\mathbf{D}$ 进行二值化分割, 并按照原图像尺寸重新排列, 便可以得到多时相遥感影像的变化检测结果. 为了使二值化分割结果更加准确, 本文提供以下两种可切换方法: (1) 当变化强度向量 $\mathbf{D}$ 的元素直方图具有单波谷的数据分布时, 采用大津法选择分割阈值; (2) 当变化强度向量 $\mathbf{D}$ 的元素直方图具有多波谷的数据分布时, 采用人工法确定分割阈值. 不同于前文的丰度截断场景, 变化强度向量 $\mathbf{D}$ 是通过累计变化端元所对应丰度的绝对变化量得到的, 这种累计效果会持续扩大变化与未变化类别的数值间隔, 更便于人工选择分割阈值.

5 实验与分析

本节针对所提出的模型和算法展开对比实验, 并在精心构造的仿真数据集和几种常用真实数据集上验证其有效性. 此外, 本节还对实验中的相关参数做了敏感性分析. 具体地, 5.1 小节介绍了基本实验设置、对比算法和性能评价指标; 5.2 小节介绍了仿真数据集的构造方法及真实数据集的相关信息; 5.3 小节进行了参数敏感性实验及结果分析; 5.4 小节展示了实验及对比分析结果.

表 1 混淆矩阵
Table 1 Confusion matrix

	Predicted = 1	Predicted = 0
Actual = 1	TP	FN
Actual = 0	FP	TN

5.1 实验设置

在算法 1 中, 需要预先设置正则参数 μ , λ 与迭代变量 $\mathbf{D}$, $\mathbf{U}$, $\mathbf{V}$ 的初始值. 其中, 正则参数的取值可以根据后续的参数敏感性实验得出, 而迭代变量的初始值可以类比已有稀疏解混问题的 ADMM 算法给出. 例如, 文献 [50] 将迭代变量 $\mathbf{D}$, $\mathbf{U}$, $\mathbf{V}$ 分别初始化为 $\mathbf{D}^{(0)} = \mathbf{0}$, $\mathbf{U}^{(0)} = (\mathbf{A}_m^T \mathbf{A}_m + \mu \mathbf{I})^{-1} \mathbf{A}_m^T \mathbf{Y}^\delta$, $\mathbf{V}^{(0)} = \text{Soft}(\mathbf{U}^{(0)}, \lambda/\mu)$. 在 ADMM 算法中, 正则参数 μ 的取值通常会对算法的收敛性产生极大的影响. 为了提升算法的收敛效率, 本文采用文献 [53] 所提供的自适应参数更新策略, 及时调整对原/对偶残差的惩罚力度, 以保障 ADMM 算法的原始残差和对偶残差同步收敛向 0. 此外, 本文采用最大迭代次数和原/对偶残差相结合的方式构造 ADMM 算法的终止条件, 当迭代代数超出最大迭代次数或者原/对偶残差小于一给定阈值时, 算法终止迭代.

为了验证所提出方法的有效性, 本文将展开对比实验研究. 对比算法包括: (1) 变化向量分析法 (CVA); (2) 稳健变化向量分析法 (RCVA); (3) 压缩变化向量分析法 (C²VA); (4) 支持向量机 (support vector machine, SVM); (5) K-近邻算法 (k-nearest neighbor, KNN); (6) 迭代加权多元变化检测算法 (iteratively reweighted MAD, IR-MAD); (7) 主成分分析-K均值聚类算法 (principal component analysis-Kmeans, PCA-Kmeans) [11]; (8) GETNET (general end-to-end two-dimensional CNN framework) 算法 [54]; (9) 基于稀疏解混的变化检测算法 (sparse unmixing based change detection, SUCD) [36]; (10) 基于光谱角加权的局部绝对距离法 (spectral angle weighted-based local absolute distance, SALA) [55]; (11) 基于形态学的最小树重构方法 (mintreeCD) [55]; (12) 本文算法不包含丰度截断时的消融算法, 记为 Prop(n). 其中, CVA, RCVA, C²VA, IR-MAD, PCA-Kmeans 与 SUCD 算法及其所属类别在引言部分均有介绍; SVM 和 KNN 算法是两种最为常见的机器学习算法, 可以直接应用于典型的二分类问题; GETNET 算法是一种端到端的有监督深度学习算法, 其在变化检测过程中融合了解混所得的亚像元级表示信息; SALA 和 mintreeCD 算法有效利用了图像的多种形态学特征; 而 Prop(n) 可用于验证本文所提出的丰度截断策略的有效性. 以上对比算法包含了像元级/亚像元级、无监督/监督、传统/深度学习类方法, 可以从多角度对比考察所提出方法的性能.

为了量化所提出算法与对比算法的性能, 本文基于表 1 中的混淆矩阵计算以下 5 个经典指标: 准确率 (OA)、Kappa 系数、精确率 (P)、召回率 (R), 以及 $F1$ 值, 用于衡量变化检测算法的综合表现. 这些指标的计算公式如下.

(1) 准确率 (OA):

$$\text{OA} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}), \quad (26)$$

OA 计算变化检测正确的像元数占总像元数的比例, 其取值越接近 1 说明变化检测准确率越高.

(2) Kappa 系数:

$$\text{Kappa} = (\text{OA} - P_e) / (1 - P_e), \quad (27)$$

其中

$$P_e = [(\text{TP} + \text{FP})(\text{TP} + \text{FN}) + (\text{FN} + \text{TN})(\text{FP} + \text{TN})] / [(\text{TP} + \text{TN} + \text{FP} + \text{FN})^2]. \quad (28)$$

Kappa 系数可用于一致性评估, 其值越接近 1 表明变化检测结果与真实变化情况越一致.

(3) 精确率 (P) 与召回率 (R):

$$P = TP / (TP + FP), \quad (29)$$

$$R = TP / (TP + FN), \quad (30)$$

其中, P 也被称为查准率, 即正确检测为变化的像元在所有检测为变化的像元中的占比. P 的值越接近于 1, 说明虚检为变化的像元占比越低. R 表示正确检测为变化的像元在所有真实变化像元中的占比, R 的值越接近于 1, 说明漏检的变化像元占比越低. 因为降低虚检率和漏检率是两个相互冲突的目标, 所以 P 和 R 通常是相互制约的.

(4) F_1 值:

$$F_1 = 2 \cdot P \cdot R / (P + R), \quad (31)$$

F_1 是 P , R 的调和平均数, 在 P , R 相互制约时, 可以综合评估变化检测算法的精确率与召回率.

5.2 数据集

本小节首先构造包含亚像元级变化的高光谱图像仿真数据集, 用于验证算法的变化检测结果与真实变化的一致性. 随后, 介绍 3 种代表性高光谱数据集, 用于验证变化检测算法的实际性能.

5.2.1 SD1

SD1 数据集包含两幅高光谱图像, 每幅图像包含 100×100 个像素, 每个像素包含 224 个波段. 其中, 每一幅高光谱图像的构造均遵循线性高光谱混合模型, 其端元均来自于 USGS 1995 光谱库¹⁾的一个子集, 而其丰度矩阵均修改自 Fractal1 仿真数据集²⁾, 具体信息如图 1 所示. 在两幅图像的变化像元中, 既存在物质含量的增加与减少, 也存在物质的出现与消失. 为了验证算法在不同噪声下的变化检测性能, 对两幅图像分别施加不同 SNR (dB) (即: 10, 20, 30, 40) 的高斯白噪声, 形成了含有不同噪声水平的仿真数据集 SD1, 其包含的两幅高光谱图像伪彩图如图 2(a) 所示.

5.2.2 River

如图 2(b) 所示, River 数据集包含由地球观测卫星 EO-1 携带的高光谱传感器 Hyperion 所采集的两幅图像^[54], 采集时间分别为 2013 年 5 月 3 日与 2013 年 12 月 31 日. 每幅图像包含 463×241 个像素, 每个像素包含 242 个波段, 波长范围为 $0.4 \sim 2.5 \mu\text{m}$, 空间分辨率为 30 m. 在去除噪声波段后, 可用波段剩余 198 个. 图像的主要变化是河道的缩减和河床的裸露.

5.2.3 Hermiston

如图 2(c) 所示, Hermiston 数据集所包含的两幅图像也是由地球观测卫星 EO-1 所携带的高光谱传感器 Hyperion 采集的, 采集时间分别为 2004 年 5 月 1 日与 2007 年 5 月 8 日. 每幅图像包含 390×200 个像素, 每个像素包含 242 个波段, 波长范围为 $0.4 \sim 2.5 \mu\text{m}$, 空间分辨率为 30 m. 在去除噪声波段后, 可用波段剩余 198 个. 图像的主要变化是作物类型的演变.

1) <http://speclab.cr.usgs.gov/spectral.lib06>.

2) <http://www.hypercomp.es/hypermix>.




图 1 (网络版彩图) 仿真数据集 SD1 中两幅图像的端元和丰度图. #1~#9 和 (a)~(i) 是第 1 幅图像的端元及其对应的丰度图; #1~#10 和 (j)~(s) 是第 2 幅图像的端元及其对应的丰度图. 为了构造亚像元级变化, 丰度图 (b) 和 (c) 中的部分像元强度值被增加到如图 (k) 和 (l) 所示; 丰度图 (e) 和 (g) 中的部分像元强度值被减小到如图 (n) 和 (p) 所示; 此外, 丰度图 (i) 中的部分像元强度值被减小到 0, 变为丰度图 (r); 丰度图 (s) 为第 2 幅图像中新增端元 #10 的丰度; 剩余端元的丰度图在两幅图像中均保持不变

Figure 1 (Color online) Endmembers and abundance maps in the two images of SD1. #1~#9 and (a)~(i) are the endmembers and their abundance maps for the first image; #1~#10 and (j)~(s) are the endmembers and their abundance maps for the second image. To create subpixel-level changes, some pixels in the abundance map (b) and (c) are increased to the map (k) and (l), respectively; some pixels in the abundance map (e) and (g) are decreased to the map (n) and (p), respectively; some pixels in the map (i) are decreased to 0 to the map (r); the map (s) is the abundance map of the newly appeared endmember #10 in the second image; the abundance maps of the rest endmembers remain unchanged in both images




图 2 (网络版彩图) 仿真数据集与真实数据集所包含图像的伪彩图

Figure 2 (Color online) Pseudo-color map of the images contained in the simulated and real data sets. (a) SD1; (b) River; (c) Hermiston; (d) Santa Barbara

5.2.4 Santa Barbara

如图 2(d) 所示, Santa Barbara 数据集所包含的两幅图像是由 AVIRIS 传感器在圣塔芭芭拉地区 (Santa Barbara, State of California) 拍摄, 拍摄时间分别为 2013 年与 2014 年. 每幅图像包含 984×740 个像素, 每个像素包含 224 个波段. 在去除噪声波段后, 可用波段剩余 205 个. 图像的主要变化是作物类型的演变.

5.3 参数敏感性实验

在采用 ADMM 算法求解模型 (9) 之前, 需要先构造匹配光谱库 $\mathbf{A}_m$. 但 $\mathbf{A}_m$ 中所含的端元个数受控于参数 K , 可能影响模型 (9) 的求解精度. 为此, 本小节首先研究 $K = 50, 100, 200, 300, 400, 498$ 时, 所提出算法在 SD1 数据集上的性能变化. 其中, $K = 498$ 表示光谱库未修剪的情况.

表 2 所提出算法在 SD1 数据集上对参数 K 的敏感性Table 2 Sensitivity of the proposed algorithm to the parameter K with respect to the SD1 data set

K	SNR = 20			SNR = 30			SNR = 40			SNR = 50		
	OA	Kappa	F_1	OA	Kappa	F_1	OA	Kappa	F_1	OA	Kappa	F_1
50	0.9500	0.8707	0.9046	0.9995	0.9986	0.9990	0.9999	0.9996	0.9997	0.9999	0.9997	0.9998
100	0.9442	0.8555	0.8934	0.9997	0.9991	0.9994	0.9999	0.9996	0.9997	0.9999	0.9998	0.9999
200	0.9429	0.8524	0.8910	0.9995	0.9988	0.9991	0.9999	0.9998	0.9998	0.9999	0.9997	0.9998
300	0.9398	0.8441	0.8850	0.9995	0.9988	0.9991	0.9999	0.9997	0.9998	0.9999	0.9997	0.9998
400	0.9320	0.8241	0.8702	0.9994	0.9986	0.9989	0.9999	0.9998	0.9998	0.9999	0.9998	0.9998
498	0.9290	0.8164	0.8645	0.9993	0.9982	0.9987	0.9999	0.9997	0.9998	0.9999	0.9997	0.9998




图 3 (网络版彩图) 所提出算法在不同数据集上的性能指标随正则参数的变化情况

Figure 3 (Color online) Evaluation indicators of the proposed algorithm obtained on different data sets vary against the regularization parameter. (a) SD1 (SNR = 20 dB); (b) SD1 (SNR = 30 dB); (c) SD1 (SNR = 40 dB); (d) SD1 (SNR = 50 dB); (e) River; (f) Hermiston; (g) Santa Barbara

表 2 列出了所提出算法在含有不同噪声的 SD1 数据集上对参数 K 的敏感性实验结果. 由于 F_1 值可以综合评估变化检测算法的精确率与召回率, 表 2 仅列出了算法的 OA, Kappa 和 F_1 值, 用于评估算法性能随参数 K 的变化情况. 从表中数据可以看出, 在同一 SNR 下, 同一检测指标随参数 K 的变化并不大. 仅当 SNR = 20 dB, 且参数 K 的取值达到 300 以上时, 算法的 OA, Kappa 和 F_1 值才随着 K 的增加出现相对明显的降低. 造成这一结果的主要原因可能是: 高光谱图像中的噪声水平比较高时, 基于其所构造的子空间不够准确, 因此匹配光谱库随着 K 的增加会包含更多的欠匹配光谱, 这些欠匹配光谱会对差异图的精确解混产生干扰, 进而降低亚像元级变化检测的精度. 因此, 对于噪声强度比较低的高光谱图像变化检测问题, 参数 K 不属于敏感参数, 其设置也较为简单. 反之, 参数 K 可以设置的相对小一些 (比如: 200 以内), 以减少欠匹配光谱对变化检测精度的影响.

如前文所述, 模型 (9) 中正则参数 λ 的取值也会对算法的性能产生影响. 为此, 本小节继续研究当 λ 的取值发生变化时, 所提出算法在不同数据集上的性能变化. 图 3 展示了所提出算法在不同数据集上的性能指标随正则参数 λ 的变化情况. 从图中可以看出, 算法的性能指标关于正则参数 λ 的取值较为敏感. 而且, 对于不同的数据集, 适合其变化检测的正则参数具有不同的取值区间. 具体地, 对于

表 3 各算法在仿真数据集上的性能指标^{a)}Table 3 Indicators of the algorithms obtained on the synthetic data set (SNR = 30 dB)^{a)}

Algorithm	CVA	RCVA	C ² VA	SVM	KNN	IR-MAD	PCA-Kmeans	GETNET	SUCD	SALA	mintreeCD	Prop(n)	Proposed
OA	0.9462	0.6082	0.9098	0.9584	0.9484	0.9415	0.9309	0.9817	0.9988	0.7651	0.7757	0.9958	0.9996
Kappa	0.8608	0.0744	0.7375	0.8862	0.8516	0.8487	0.8150	0.9528	0.9969	0.3923	0.4198	0.9891	0.9990
P	0.8969	0.3084	1.0000	1.0000	1.0000	0.8881	0.8152	0.9624	0.9977	0.5516	0.5718	0.9988	0.9989
R	0.8976	0.3990	0.6556	0.8411	0.8030	0.8885	0.9116	0.9679	0.9977	0.5514	0.5716	0.9851	0.9996
F1	0.8972	0.3479	0.7920	0.9133	0.8830	0.8883	0.8607	0.9652	0.9977	0.5515	0.5717	0.9919	0.9992

a) The number in bold indicates the maximum value of the corresponding indicator.

含有不同噪声水平的仿真数据集 SD1, 其对应的合适正则参数取值范围为 [5, 50], 该取值范围会随着噪声强度的降低而扩大. 此外, 对于真实数据集 River, Hermiston 和 Santa Barbara, 算法的性能指标随着参数 λ 的取值变化也有不同程度的波动, 它们的合适正则参数取值范围也相差悬殊, 比如: Santa Barbara 对应的合适正则参数取值范围非常广, 但 Hermiston 对应的合适正则参数取值范围则非常窄. 对于合适正则参数取值范围比较窄的数据集, 需要经过反复试错和微调才能确定最优正则参数. 从图 3 中可以看出, 适合数据集 SD1, River, Hermiston 和 Santa Barbara 的正则参数取值分别为 5, 3, 0.1, 100, 因此下文的实验中将采用此参数设置.

5.4 对比实验及结果分析

本小节将通过对比实验验证所提出算法在不同数据集上的有效性. 其中, 有监督算法 KNN, SVM 在每个数据集上分别随机选择 25 个正、负样本训练分类器, 其他算法则根据文章出处进行参数设置. 由于 GETNET 算法的源文没有 Hermiston 和 Santa Barbara 数据集上进行测试, 故本文参考文献 [24, 25] 对其进行相应的参数设置. 此外, 在为各数据集的检测构造匹配光谱库时, 原则上应当选择与数据集尽可能匹配的光谱库, 具体如下: SD1, River 和 Santa Barbara 数据集所采用的光谱库是通过修剪 USGS 1995³⁾ 光谱库得到的; Hermiston 数据集由于保留波段的波长信息未知, 所含地物类型单一, 且包含纯像元的可能性大, 在选择光谱库时考虑了纯像元假设, 其匹配光谱库是通过修剪图像的像元光谱得到的. 下文表格中的指标值均为 20 次独立重复实验的平均值.

首先, 对于 SD1 数据集, 实验仅考察其在噪声水平 SNR = 30 dB 时所提出算法的性能表现. 表 3 列出了所提出算法和各对比算法在该数据集上的性能指标值. 从表 3 中的数值对比可以看出, 所提出算法在准确率、Kappa 系数、召回率, 以及 F_1 值方面均高于对比算法, 仅在查准率方面稍逊于 C²VA, SVM 和 KNN 算法. 这表明所提出算法的变化检测结果与真实变化的一致性最高, 且具有最低的漏检率, 仅在虚检方面稍差于 SVM 和 KNN 算法. 但是, C²VA, SVM 和 KNN 算法的低虚检率是以较高的漏检率为代价得到的. 在剩余对比算法中, CVA, RCVA, IR-MAD, PCA-Kmeans, SALA 和 mintreeCD 算法的变化检测指标相对较差 (特别是 RCVA 算法), 而 GETNET 和 SUCD 算法的检测指标较好, 说明高光谱图像的亚像元表示信息有助于提升变化检测的精度.

图 4 展示了所提出算法和各对比算法在 SD1 数据集上的变化检测结果. 从与参考图 4(n) 的对比中可以看出, 所提出算法几乎取得了视觉上与参考图完全一致的变化检测结果. 相较之下, RCVA 仅仅捕捉到了变化的大致轮廓, 且虚检率和漏检率较高; C²VA, SVM 和 KNN 漏检了许多纹理上的变化, 这与针对表 3 的分析是一致的; IR-MAD 和 PCA-Kmeans 则存在许多集中的区域性检测错误; CVA 尽管平衡了漏检和虚检率, 但其总体检测精度不高; 基于形态属性的 SALA 与 MinTreeCD 算法均难以检测亚像元级的精细变化; 除了少量噪点外, GETNET, SUCD 和不含丰度截断的消融算法则取得了与所提出算法相接近的变化检测结果.

3) <http://speclab.cr.usgs.gov/spectral.lib06>.




图 4 (网络版彩图) 各算法在仿真数据集上的变化检测结果

Figure 4 (Color online) Change maps detected by the algorithms on the synthetic data set (SNR = 30 dB). (a) CVA; (b) RCVA; (c) C²VA; (d) SVM; (e) KNN; (f) IR-MAD; (g) PCA-Kmeans; (h) GETNET; (i) SUCD; (j) SALA; (k) mintreeCD; (l) Prop(*n*); (m) proposed; (n) reference map

表 4 各算法在 River 数据集上的性能指标^{a)}Table 4 Indicators of the algorithms obtained on the River data set^{a)}

Algorithm	CVA	RCVA	C ² VA	SVM	KNN	IR-MAD	PCA-Kmeans	GETNET	SUCD	SALA	mintreeCD	Prop(<i>n</i>)	Proposed
OA	0.9440	0.9466	0.9276	0.9263	0.9392	0.9464	0.9387	0.9444	0.9513	0.9624	0.9604	0.9586	0.9640
Kappa	0.6475	0.6766	0.6601	0.6496	0.6391	0.6621	0.6607	0.6914	0.6933	0.7633	0.7504	0.7391	0.7733
<i>P</i>	0.6775	0.6772	0.5474	0.5606	0.6308	0.6914	0.6132	0.6391	0.7201	0.7836	0.7719	0.7614	0.7929
<i>R</i>	0.6788	0.7372	0.9620	0.9065	0.7229	0.6916	0.7995	0.8288	0.7198	0.7723	0.7842	0.7622	0.7931
<i>F</i> ₁	0.6781	0.7059	0.6978	0.6877	0.6724	0.6915	0.6941	0.7217	0.7200	0.7721	0.7839	0.7618	0.7930

a) The number in bold indicates the maximum value of the corresponding indicator.




图 5 (网络版彩图) 各算法在 River 数据集上的变化检测结果

Figure 5 (Color online) Change maps detected by the algorithms on the River data set. (a) CVA; (b) RCVA; (c) C²VA; (d) SVM; (e) KNN; (f) IR-MAD; (g) PCA-Kmeans; (h) GETNET; (i) SUCD; (j) SALA; (k) mintreeCD; (l) Prop(*n*); (m) proposed; (n) reference map

表 4 列出了所提出算法和各对比算法在 River 数据集上的性能指标值. 从表 4 中的数值对比可以看出, 所提出算法在准确率、Kappa 系数、查准率, 以及 F_1 值方面均高于对比算法, 仅在召回率方面低于 C²VA, SVM, PCA-Kmeans 和 GETNET 算法. 这表明所提出算法的变化检测结果与真实变化的一致性最高, 且具有最低的虚检率, 仅在漏检率方面逊色于 C²VA, SVM, PCA-Kmeans 和 GETNET 算法. 但是, C²VA, SVM, PCA-Kmeans 和 GETNET 算法的高召回率是以损失查准率为代价得到的. 在剩余算法中, CVA, RCVA, KNN 和 IR-MAD 较好地平衡了查准率与召回率, 但相应的取值并不高, 总体检测精度也不高; 相较之下, SUCD, SALA, mintreeCD 以及不含丰度截断的消融算法总体检测精度较高, 且较好地平衡了查准率与召回率.

图 5 展示了所提出算法和各对比算法在 River 数据集上的变化检测结果. 从与参考图 5(n) 的对比中可以看出, 所提出算法的变化检测结果无论是在顶部的离散变化区域, 还是在中下部的集中变化区域, 都在视觉上与参考图保持了一致. 相较之下, C²VA, SVM, PCA-Kmeans 和 GETNET 分别在离散和集中的变化区域检测到许多伪变化, 印证了这些算法较高的召回率和较低的查准率; CVA, RCVA, KNN 和 IR-MAD 在丢失了细节变化的同时, 检测到一些伪变化, 证明了这些算法在召回和查准方面的双向不足; SUCD 和基于形态属性的 SALA 以及 mintreeCD 算法则损失了许多离散的变化细节; 而不舍丰度截断的消融算法所得结果与所提出算法接近, 但其在图像的左上角积累了更多的伪变化, 这说明丰度截断策略可以一定程度地抑制伪变化的检出.

表 5 各算法在 Hermiston 数据集上的性能指标^{a)}

Table 5 Indicators of the algorithms obtained on the Hermiston data set^{a)}

Algorithm	CVA	RCVA	C ² VA	SVM	KNN	IR-MAD	PCA-Kmeans	GETNET	SUCD	SALA	mintreeCD	Prop(<i>n</i>)	Proposed
OA	0.9736	0.9743	0.9782	0.9498	0.9779	0.9791	0.9761	0.9843	0.9744	0.9744	0.9782	0.9850	0.9857
Kappa	0.8819	0.8857	0.9041	0.7466	0.8955	0.9064	0.8927	0.9297	0.8856	0.8853	0.9025	0.9327	0.9360
<i>P</i>	0.8969	0.8953	0.8990	0.9130	0.9710	0.9183	0.9081	0.9377	0.9008	0.9144	0.8993	0.9411	0.9439
<i>R</i>	0.8972	0.9056	0.9349	0.6718	0.8527	0.9185	0.9048	0.9396	0.8997	0.9156	0.9007	0.9415	0.9444
<i>F1</i>	0.8970	0.9004	0.9166	0.7741	0.9080	0.9184	0.9064	0.9387	0.9002	0.9150	0.9006	0.9413	0.9442

a) The number in bold indicates the maximum value of the corresponding indicator.




图 6 (网络版彩图) 各算法在 Hermiston 数据集上的变化检测结果

Figure 6 (Color online) Change maps detected by the algorithms on the Hermiston data set. (a) CVA; (b) RCVA; (c) C²VA; (d) SVM; (e) KNN; (f) IR-MAD; (g) PCA-Kmeans; (h) GETNET; (i) SUCD; (j) SALA; (k) mintreeCD; (l) Prop(*n*); (m) proposed; (n) reference map

表 6 各算法在 Santa Barbara 数据集上的性能指标^{a)}

Table 6 Indicators of the algorithms obtained on the Santa Barbara data set^{a)}

Algorithm	CVA	RCVA	C ² VA	SVM	KNN	IR-MAD	PCA-Kmeans	GETNET	SUCD	SALA	mintreeCD	Prop(<i>n</i>)	Proposed
OA	0.8703	0.8635	0.8321	0.9215	0.8832	0.8720	0.8562	0.9086	0.9260	0.8522	0.8607	0.9183	0.9323
Kappa	0.7298	0.7148	0.6503	0.8374	0.7458	0.7334	0.6858	0.8146	0.8449	0.6905	0.7083	0.8297	0.8590
<i>P</i>	0.8240	0.8208	0.7763	0.8763	0.9372	0.8266	0.9142	0.8239	0.9053	0.8112	0.8219	0.8832	0.9004
<i>R</i>	0.8523	0.8353	0.8049	0.9321	0.7545	0.8538	0.7002	0.9764	0.9066	0.8136	0.8245	0.9129	0.9309
<i>F1</i>	0.8379	0.8280	0.7904	0.9033	0.8336	0.8399	0.7930	0.8937	0.9060	0.8124	0.8232	0.8973	0.9154

a) The number in bold indicates the maximum value of the corresponding indicator.

表 5 列出了所提出算法和各对比算法在 Hermiston 数据集上的性能指标值. 从表 5 中的数值对比可以看出, 所提出算法在准确率、Kappa 系数、召回率, 以及 F_1 值方面均高于对比算法, 仅在查准率方面略低于 KNN 算法. 这表明所提出算法的变化检测结果与真实变化的一致性最高, 且具有最低的漏检率, 仅在虚检率方面逊色于 KNN 算法. 但是, KNN 算法的召回率远不如所提出的算法和 SVM 以外的对比算法, 表明其漏检率极高. 在剩余算法中, SVM 的总体检测精度最低, GETNET 算法和不含丰度截断的消融算法总体检测精度与所提出算法最为接近, 且具有良好的查准率与召回率; 其他算法的总体检测精度与所提出算法相差也不大, 且能很好地平衡查准率与召回率, 这一点可以从它们相差不多的 F_1 值中看出.

图 6 展示了所提出算法和各对比算法在 Hermiston 数据集上的变化检测结果. 从与参考图 6(n) 的对比中可以看出, GETNET 与不含丰度截断的消融算法以及所提出算法的变化检测结果除了包含少许伪变化外, 剩余变化在视觉上均与参考图保持了一致. 相较之下, SVM, KNN 在图像的左下、上中、右下部均漏检了许多变化区域, 这也印证了它们较低的召回率; IR-MAD 则漏检了左下区域的变化; 而 CVA, RCVA, C²VA, PCA-Kmeans, SUCD 以及基于形态属性的 SALA, mintreeCD 算法则虚检出了许多伪变化, 这也是它们的查准率比其他算法偏低一些的原因.

表 6 列出了所提出算法和各对比算法在 Santa Barbara 数据集上的性能指标值. 从表 6 中的数值对比可以看出, 所提出算法在准确率及 Kappa 系数方面均高于对比算法, 但在查准率方面低于 KNN 和 SUCD 算法, 在召回率方面低于 SVM 和 GETNET 算法. 这表明所提出算法的变化检测结果与真




图 7 (网络版彩图) 各算法在 Santa Barbara 数据集上的变化检测结果

Figure 7 (Color online) Change maps detected by the algorithms on the Santa Barbara data set. (a) CVA; (b) RCVA; (c) C²VA; (d) SVM; (e) KNN; (f) IR-MAD; (g) PCA-Kmeans; (h) GETNET; (i) SUCD; (j) SALA; (k) mintreeCD; (l) Prop(n); (m) proposed; (n) reference map

实变化的一致性最高,但在漏检和虚检方面均非最优.然而,综合查准率和召回率所得的 F_1 值均高于对比算法,表明所提出算法在平衡虚检和漏检方面的综合效果最好.更具体地,KNN 和 PCA-Kmeans 算法的查准率虽高,但它们的召回率很低,表明它们的漏检率很高;SVM 和 GETNET 算法的召回率虽高,但它们的查准率较低,表明它们的虚检率高于所提出算法.在剩余算法中,C²VA 在总体检测精度、查准率和召回率方面表现均不理想;CVA, RCVA, IR-MAD 与基于形态属性的 SALA, mintreeCD 算法的综合表现差别不大,远逊色于所提出的算法;SUCD 的综合表现与所提出算法最为接近,在虚检和漏检的平衡方面也表现较好.

图 7 展示了所提出算法和各对比算法在 Santa Barbara 数据集上的变化检测结果.从与参考图 7(n) 的对比中可以看出,所提出算法的变化检测结果在视觉上与参考图的一致性最高,SUCD 算法次之,而 SVM 顺次之.相较之下,KNN 和 PCA-Kmeans 算法漏检了一些集中变化的区域,印证了它们具有极低的召回率;CVA, RCVA, C²VA, IR-MAD, GETNET 和 SALA 在未变化的区域虚检出了许多变化的像元,而 mintreeCD 则检出了许多集中的伪变化区域,印证了它们较低的查准率.尽管 SVM, SUCD 和所提出算法也将一些未变化像元虚检为变化,但它们的检测结果与参考图的一致性更强.而不含丰度截断的消融算法所得检测结果与所提出算法相比,包含更多离散的伪变化像素,说明丰度截断策略可以在一定程度上抑制伪变化的检出.

综上,本文所提出的算法在仿真数据集及 3 个代表性真实数据集上均取得最高的准确率和 Kappa 系数,表明其变化检测结果与真实变化的一致性最高.尽管所提出算法的查准率与召回率往往难以达到最优,但综合查准率和召回率所得的 F_1 值均优于对比算法,表明所提出算法在像元的漏检和虚检方面达到了极好的平衡,没有顾此失彼.同时,消融对比实验表明本文所提出的丰度截断策略可以有效地抑制虚检.因此,本文所建立的协同稀疏高光谱变化检测方法是有效且实用的.

6 总结

本文在稀疏解混思想的启发下,针对多时相高光谱遥感影像的差异图,建立了基于协同解混的无约束高光谱图像变化检测模型.为了提升解混的精度,本文基于子空间匹配思想构建了匹配光谱库,并设计了交替方向乘子法求解所建立的无约束正则模型.此外,针对稀疏正则项所引起的丰度渐进稀疏问题,本文还设计了自适应的丰度截断策略对解混结果进行去尾操作,以抑制非活动端元对变化检测结果的影响.在仿真及真实数据集上的对比实验结果表明,本文所提出的算法可以取得与真实变化最为一致的检测结果,且能够较好地平衡对像元的虚检和漏检.在未来的工作中,我们将进一步探讨高光谱图像的亚像元表示信息和空间光谱信息对变化检测的积极作用.

参考文献

- 1 Bioucas-Dias J M, Plaza A, Dobigeon N, et al. Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2012, 5: 354–379
- 2 Zhang L P, Wu C. Advance and future development of change detection for multi-temporal remote sensing imagery. *Acta Geod Cartogr Sin*, 2017, 46: 1447–1459 [张良培, 武辰. 多时相遥感影像变化检测的现状与展望. *测绘学报*, 2017, 46: 1447–1459]
- 3 Plaza A, Benediktsson J A, Boardman J W, et al. Recent advances in techniques for hyperspectral image processing. *Remote Sens Environ*, 2009, 113: S110–S122
- 4 Liu S C, Marinelli D, Bruzzone L, et al. A review of change detection in multitemporal hyperspectral images: current techniques, applications, and challenges. *IEEE Geosci Remote Sens Mag*, 2019, 7: 140–158
- 5 Keshava N, Mustard J F. Spectral unmixing. *IEEE Signal Process Mag*, 2002, 19: 44–57
- 6 Hussain M, Chen D, Cheng A, et al. Change detection from remotely sensed images: from pixel-based to object-based approaches. *ISPRS J Photogramm Remote Sens*, 2013, 80: 91–106
- 7 Bovolo F, Bruzzone L. A theoretical framework for unsupervised change detection based on change vector analysis in the polar domain. *IEEE Trans Geosci Remote Sens*, 2006, 45: 218–236
- 8 Thonfeld F, Feilhauer H, Braun M, et al. Robust change vector analysis (RCVA) for multi-sensor very high resolution optical satellite data. *Int J Appl Earth Obs GeoInf*, 2016, 50: 131–140
- 9 Bovolo F, Marchesi S, Bruzzone L. A framework for automatic and unsupervised detection of multiple changes in multitemporal images. *IEEE Trans Geosci Remote Sens*, 2011, 50: 2196–2212
- 10 Deng J S, Wang K, Deng Y H, et al. PCA-based landuse change detection and analysis using multitemporal and multisensor satellite data. *Int J Remote Sens*, 2008, 29: 4823–4838
- 11 Celik T. Unsupervised change detection in satellite images using principal component analysis and *k*-means clustering. *IEEE Geosci Remote Sens Lett*, 2009, 6: 772–776
- 12 Zhong J, Wang R. Multi-temporal remote sensing change detection based on independent component analysis. *Int J Remote Sens*, 2006, 27: 2055–2061
- 13 Marchesi S, Bruzzone L. ICA and kernel ICA for change detection in multispectral remote sensing images. In: *Proceedings of IEEE International Geoscience and Remote Sensing Symposium*, Cape Town, 2009
- 14 Nielsen A A, Conradsen K, Simpson J J. Multivariate alteration detection (MAD) and MAF postprocessing in multispectral, bitemporal image data: new approaches to change detection studies. *Remote Sens Environ*, 1998, 64: 1–19
- 15 Nielsen A A. The regularized iteratively reweighted MAD method for change detection in multi- and hyperspectral data. *IEEE Trans Image Process*, 2007, 16: 463–478
- 16 Wu C, Du B, Zhang L P. A Subspace-based change detection method for hyperspectral images. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2013, 6: 815–830
- 17 Mou L C, Bruzzone L, Zhu X X. Learning spectral-spatial-temporal features via a recurrent convolutional neural network for change detection in multispectral imagery. *IEEE Trans Geosci Remote Sens*, 2018, 57: 924–935
- 18 Qu J H, Xu Y S, Dong W Q, et al. Dual-branch difference amplification graph convolutional network for hyperspectral image change detection. *IEEE Trans Geosci Remote Sens*, 2022, 60: 1–12
- 19 Zhao C H, Cheng H, Feng S. A spectral-spatial change detection method based on simplified 3-D convolutional autoencoder for multitemporal hyperspectral images. *IEEE Geosci Remote Sens Lett*, 2022, 19: 1–5
- 20 Zheng Z, Wan Y, Zhang Y J, et al. CLNet: cross-layer convolutional neural network for change detection in optical remote sensing imagery. *ISPRS J Photogramm Remote Sens*, 2021, 175: 247–267
- 21 Shi C J, Zhang Z J, Zhang W C, et al. Learning multiscale temporal-spatial-spectral features via a multipath convolutional LSTM neural network for change detection with hyperspectral images. *IEEE Trans Geosci Remote Sens*, 2022, 60: 1–16
- 22 Song B, Tang Y S, Zhan T M, et al. BRCN-ERN: a bidirectional reconstruction coding network and enhanced residual network for hyperspectral change detection. *IEEE Geosci Remote Sens Lett*, 2022, 19: 1–5
- 23 Lei J, Li M Q, Xie W Y, et al. Spectral mapping with adversarial learning for unsupervised hyperspectral change detection. *Neurocomputing*, 2021, 465: 71–83
- 24 Gong M G, Jiang F L, Qin A K, et al. A spectral and spatial attention network for change detection in hyperspectral

- images. *IEEE Trans Geosci Remote Sens*, 2022, 60: 1–14
- 25 Wang L G, Wang L F, Wang Q M, et al. RSCNet: a residual self-calibrated network for hyperspectral image change detection. *IEEE Trans Geosci Remote Sens*, 2022, 60: 1–17
- 26 Miller O, Pikaz A, Averbuch A. Objects based change detection in a pair of gray-level images. *Pattern Recogn*, 2005, 38: 1976–1992
- 27 Walter V. Object-based classification of remote sensing data for change detection. *ISPRS J Photogramm Remote Sens*, 2004, 58: 225–238
- 28 Xian G, Homer C. Updating the 2001 national land cover database impervious surface products to 2006 using landsat imagery change detection methods. *Remote Sens Environ*, 2010, 114: 1676–1686
- 29 Zhang X L, Xiao P F, Feng X Z, et al. Separate segmentation of multi-temporal high-resolution remote sensing images for object-based change detection in urban area. *Remote Sens Environ*, 2017, 201: 243–255
- 30 Desclée B, Bogaert P, Defourny P. Forest change detection by statistical object-based method. *Remote Sens Environ*, 2006, 102: 1–11
- 31 Wang B, Choi S, Byun Y, et al. Object-based change detection of very high resolution satellite imagery using the cross-sharpening of multitemporal data. *IEEE Geosci Remote Sens Lett*, 2015, 12: 1151–1155
- 32 Tang Y Q, Zhang L P. Urban change analysis with multi-sensor multispectral imagery. *Remote Sens*, 2017, 9: 252
- 33 Wu C, Du B, Cui X H, et al. A post-classification change detection method based on iterative slow feature analysis and Bayesian soft fusion. *Remote Sens Environ*, 2017, 199: 241–255
- 34 Wang Q M, Atkinson P M, Shi W Z. Fast subpixel mapping algorithms for subpixel resolution change detection. *IEEE Trans Geosci Remote Sens*, 2014, 53: 1692–1706
- 35 Wang Q M, Shi W Z, Atkinson P M, et al. Land cover change detection at subpixel resolution with a hopfield neural network. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2015, 8: 1339–1352
- 36 Ertürk A, Iordache M D, Plaza A. Sparse unmixing-based change detection for multitemporal hyperspectral images. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2016, 9: 708–719
- 37 Ertürk A, Iordache M D, Plaza A. Sparse unmixing with dictionary pruning for hyperspectral change detection. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2017, 10: 321–330
- 38 Ertürk A, Plaza A. Informative change detection by unmixing for hyperspectral images. *IEEE Geosci Remote Sens Lett*, 2015, 12: 1252–1256
- 39 Liu S C, Bruzzone L, Bovolo F, et al. Unsupervised multitemporal spectral unmixing for detecting multiple changes in hyperspectral images. *IEEE Trans Geosci Remote Sens*, 2016, 54: 2733–2748
- 40 Wu K, Du Q. Subpixel change detection of multitemporal remote sensed images using variability of endmembers. *IEEE Geosci Remote Sens Lett*, 2017, 14: 796–800
- 41 Wu K, Zhong Y F, Wang X M, et al. A novel approach to subpixel land-cover change detection based on a supervised back-propagation neural network for remotely sensed images with different resolutions. *IEEE Geosci Remote Sens Lett*, 2017, 14: 1750–1754
- 42 Lu X Q, Yuan Y, Zheng X T. Joint dictionary learning for multispectral change detection. *IEEE Trans Cybern*, 2017, 47: 884–897
- 43 Wu C, Du B, Zhang L P. Hyperspectral anomalous change detection based on joint sparse representation. *ISPRS J Photogramm Remote Sens*, 2018, 146: 137–150
- 44 Deng C B, Zhu Z. Continuous subpixel monitoring of urban impervious surface using Landsat time series. *Remote Sens Environ*, 2020, 238: 110929
- 45 Guo Q L, Zhang J P, Zhang Y. Multitemporal hyperspectral images change detection based on joint unmixing and information coguidance strategy. *IEEE Trans Geosci Remote Sens*, 2021, 59: 9633–9645
- 46 Guo Q L, Zhang J P, Zhong C X, et al. Change detection for hyperspectral images via convolutional sparse analysis and temporal spectral unmixing. *IEEE J Sel Top Appl Earth Obs Remote Sens*, 2021, 14: 4417–4426
- 47 Iordache M D, Bioucas-Dias J M, Plaza A, et al. MUSIC-CSR: hyperspectral unmixing via multiple signal classification and collaborative sparse regression. *IEEE Trans Geosci Remote Sens*, 2013, 52: 4364–4382
- 48 Iordache M D, Bioucas-Dias J M, Plaza A. Total variation spatial regularization for sparse hyperspectral unmixing. *IEEE Trans Geosci Remote Sens*, 2012, 50: 4484–4502
- 49 Wright S J, Nowak R D, Figueiredo M A T. Sparse reconstruction by separable approximation. *IEEE Trans Signal*

- Process, 2009, 57: 2479–2493
- 50 Iordache M D, Bioucas-Dias J M, Plaza A. Collaborative sparse regression for hyperspectral unmixing. *IEEE Trans Geosci Remote Sens*, 2013, 52: 341–354
- 51 Qi L, Li J, Wang Y, et al. Spectral-spatial-weighted multiview collaborative sparse unmixing for hyperspectral images. *IEEE Trans Geosci Remote Sens*, 2020, 58: 8766–8779
- 52 Otsu N. A threshold selection method from gray-level histograms. *IEEE Trans Syst Man Cybern*, 1979, 9: 62–66
- 53 Boyd S, Parikh N, Chu E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers. *FNT Machine Learn*, 2011, 3: 1–122
- 54 Wang Q, Yuan Z H, Du Q, et al. GETNET: a general end-to-end 2-D CNN framework for hyperspectral image change detection. *IEEE Trans Geosci Remote Sens*, 2018, 57: 3–13
- 55 Hou Z F, Li W, Li L, et al. Hyperspectral change detection based on multiple morphological profiles. *IEEE Trans Geosci Remote Sens*, 2022, 60: 1–12

Collaborative sparse unmixing-based hyperspectral change detection method

Xiangming JIANG, Tianqi GAO, Maoguo GONG*, Fenlong JIANG & Xiaolong FAN

Key Laboratory of Collaborative Intelligence Systems, Ministry of Education, School of Electronic Engineering, Xidian University, Xi'an 710071, China

* Corresponding author. E-mail: Gong@ieee.org

Abstract Hyperspectral change detection can investigate whether ground objects have changed, while hyperspectral unmixing can investigate the (subpixel-level) composition of ground objects. Therefore, unmixing-based hyperspectral change detection can not only investigate whether the ground objects have changed but also provide more accurate detection results using the evolution information of substances. This paper first reviews the linear mixture model of hyperspectral images and simplifies the linear unmixing model based on the sparse unmixing idea. Subsequently, the direct change vector analysis is used to analyze the sparse unmixing model of multitemporal images, obtaining the collaborative sparse unmixing-based unconstrained hyperspectral change detection model. Second, a matched spectral library is constructed based on the subspace projection to alleviate mismatches between the spectral library and hyperspectral signatures. Third, an alternating direction method of multipliers is designed to solve the unconstrained change detection model. Fourth, an adaptive abundance truncation strategy is designed to aggregate the unmixing results to obtain the final change detection map. Comparison experiments on synthetic and real datasets demonstrate that our proposed method can not only achieve high-precision change detection results but also maintain an excellent balance between false positives and false negatives.

Keywords collaborative sparse unmixing, change detection, matched spectral library, alternating direction method of multipliers, adaptive abundance truncation