

光谱—频域属性模式融合的高光谱遥感图像变化检测

周承乐^{1,2}, 石茜^{1,2}, 李军³, 张新长⁴

1. 中山大学 地理科学与规划学院, 广州 510275;
2. 广东省城镇化与地理模拟重点实验室, 广州 510275;
3. 中国地质大学(武汉)计算机学院, 武汉 430074;
4. 广州大学 地理科学与遥感学院, 广州 510006

摘要: 高光谱作为“图谱合一”的遥感技术, 具有精细光谱和空间影像的地面覆盖观测与识别优势。然而, 高光谱遥感数据的光谱信息表征以及空间信息的利用给双时相高光谱遥感图像变化检测任务带来了巨大的挑战。为此, 本文探讨了一种光谱—频域属性模式融合的高光谱遥感图像变化检测方法 SFDAPF (Spectral-Frequency Domain Attribute Pattern Fusion)。首先, 设计一种基于梯度相关性的光谱绝对距离, 使双时相高光谱遥感图像像元对的属性模式从光谱信息表征方面得到了逐级量化; 其次, 基于傅里叶变换理论提出一种变化像元属性模式显著性增强策略, 从全局空间信息利用方面改善了变化与非变化属性像元对的可分性; 再次, 将全图属性模式显著性水平与梯度相关性的光谱绝对距离进行融合, 得到变化检测的综合界定值; 最后, 依据虚警阈值确定双时相高光谱遥感图像变化检测的二值化结果。将本文提出的 SFDAPF 方法在开源的双时相高光谱遥感图像河流和农场数据集上进行了变化检测性能验证, 结果表明 SFDAPF 方法能够优于传统的和最新的变化检测方法, 变化检测的总体精度在河流和农场数据集上分别达到了 0.96508 和 0.97287 (最高精度为 1.00000)。证实了本文 SFDAPF 方法的有效性。

关键词: 高光谱图像, 变化检测, 图像融合, 特征提取, 显著性分析, 傅里叶变换

中图分类号: TP701/P2

引用格式: 周承乐, 石茜, 李军, 张新长. 2024. 光谱—频域属性模式融合的高光谱遥感图像变化检测. 遥感学报, 28(1): 105–120

Zhou C L, Shi Q, Li J and Zhang X C. 2024. Spectral-frequency domain attribute pattern fusion for hyperspectral image change detection. National Remote Sensing Bulletin, 28(1): 105–120 [DOI: 10.11834/jrs.20232600]

1 引言

遥感对地观测技术的数据主要有合成孔径雷达图像、全色图像、多光谱图像以及高光谱图像。高光谱遥感图像能够提供比其他遥感图像更丰富的光谱信息。例如, 与多光谱遥感图像比较而言, 多光谱图像的光谱分辨率在 $10^{-1}\lambda$ 数量级范围, 仅包含可见光至近红外光谱区间的几个或十几个波段, 而高光谱图像光谱范围较广, 谱带较窄 ($<10^{-3}\lambda$), 波段数可达几百甚至上千, 能够获取几乎连续的地物覆盖光谱信息。因此, 高光谱遥感图像比多光谱遥感图像更易于识别细微变化, 反映不同物

体材质等 (Luo 等, 2019)。然而, 高光谱遥感图像为地面覆盖观测信息的精准解译既带来诸多便利, 又带来了高维非线性数据处理方面的挑战 (苏红军, 2022)。为此, 许多学者针对不同的任务需求, 开展了分类、目标识别、变化检测等算法研究 (Zhou 等, 2022; Shang 等, 2021; Su 等, 2022)。遥感图像变化检测作为遥感对地观测技术的关键应用之一, 可以持续观察和发现成像场景的变化信息, 近年来被广泛应用于环境监测 (Hemati 等, 2021)、城市扩张 (Yousif 和 Ban, 2014)、自然灾害检测与评估 (Zhang 等, 2003) 等领域。

收稿日期: 2022-11-20; 预印本: 2023-04-19

基金项目: 国家自然科学基金 (编号: 42222106, 61976234, T2225019)

第一作者简介: 周承乐, 研究方向为遥感图像理解与变化检测。E-mail: chengle_zhou@foxmail.com

通信作者简介: 石茜, 研究方向为遥感图像处理与农业遥感应用。E-mail: shixi5@mail.sysu.edu.cn

实质上, 双时相遥感图像变化检测目的在于对前后时相影像的空间—光谱差异性进行建模, 从而区别2期影像中的变化区域与非变化区域。一般而言, 变化检测任务包含了数据预处理、差异性挖掘与表征以及性能度量与评估3个关键步骤(Zhao等, 2022)。双时相遥感图像变化检测方法可以概括为四类, 即代数方法、转换方法、分类方法以及深度学习方法(Liu等, 2019)。

代数方法主要包括图像差异、图像比例、图像回归、绝对距离、变化向量分析等(Du等, 2012; Carvalho等, 2011)。该类方法直接对双时相遥感图像执行代数运算, 从而评判2期影像像元对的属性模式(变化属性与非变化属性)。目前, 大多数代数方法属于逐像素分析方法, 且服从像元变化由灰度差异反映的假设。变换方法(Ortiz-Rivera等, 2006; Marchesi和Bruzzone, 2009)主要是将遥感数据从原始特征空间投影至另一个特征空间, 从而识别变化属性的像元或区域。然而, 这类方法往往仅利用遥感图像的光谱信息, 忽略了邻域像元之间的相似性(Zhang等, 2012)。分类方法包括遥感图像后分类与直接分类2种方式(Demir等, 2012; Bovolo等, 2008)。后分类的做法在于将不同时相的遥感图像分别进行分类, 然后对分类结果进行比较分析, 以获取变化属性的像元; 直接分类则是将不同时相遥感图像先做差值运算, 然后借助分类器确定变化属性的像元。

最近, 基于深度学习方法的双时相高光谱遥感图像变化检测是比较热门的研究方向, 该类方法以数据驱动的方式构建非线性变换, 以得到适配变化检测任务的数据高阶特征(Zheng等, 2021; Zhan等, 2021)。例如, Du等(2019)利用对称深度网络与慢特征分析理论设计了一种双时相高光谱遥感图像变化检测方法。实验结果证明该方法的检测性能优于当时其他先进的变化检测算法, 其中包括其他基于慢特征分析和深度学习的方法。Wang等(2019)提出了一种端到端二维卷积神经网络的双时相高光谱遥感图像变化检测算法, 其思路在于, 首先利用原始光谱特征与解混后端元特征, 共同构建了像元对的二维差值矩阵, 然后采用二维深度卷积神经网络获取像元对的高阶语义属性。Ou等(2022)在慢特征分析的理论基础上设计了原始光谱信息的快慢特征筛选策略, 并将像元对的二维差值矩阵作为属性模式

的表征方式, 从而提出了基于二维卷积神经网络的变化检测方法。Wang等(2022)提出了一种端到端残差自校准网络。该网络通过自适应地对像元的局部空间信息与光谱特征的依赖性进行建模, 以提高变化检测的精度。此外, Hu等(2023)设计了二元变化引导的高光谱遥感图像多类别变化检测网络, 其思路在于利用稳定的二元变化检测方法促进多类别变化信息检测与分离。虽然上述深度学习方法能够在变化检测任务中取得优越的检测结果, 但均属于由数据驱动的弱监督变化检测方法, 其检测性能受限于训练数据库中训练样本数量以及标签准确性。实际应用中的变化检测任务不存在大量且准确的标记样本, 大多深度学习方法则采用某种机制(如变化向量分析(Carvalho等, 2011)等)构建出可供特征学习的弱标记样本, 而弱标记样本中往往存在噪声标签。

近年来, 频域分析方法在自然图像显著性分析领域得到了广泛的应用(Li等, 2013; Jaemsiri等, 2019)。其基本思路在于对灰度化的自然图像进行傅里叶变换得到对应的幅度谱和相位谱, 并利用二维高斯核对幅度谱进行低通滤波, 然后对原始相位谱与滤波后的幅度谱进行逆傅里叶变换, 从而得到前景与背景对比度增强的显著差异图像。此外, 图像频域分析方法逐渐发展至遥感影像变化检测领域, 例如, Gao等(2018)结合频域分析方法与随机多图策略提出了合成孔径雷达图像变化检测方法, 该方法利用频域分析手段的目的在于从前后时相SAR图像的差值图像中确定具有显著差异特征的区域。然而, 不同于单波段SAR图像, 高光谱遥感图像具有光谱波段高维特性, 因此如何综合光谱维的全波段信息并提取前后时相图像的频域显著差异是一个具有挑战的任务。

对于双时相高光谱遥感图像变化检测算法而言(包括传统方法与深度学习方法), 其核心问题在于2期影像像元对光谱差异化的有效表征以及像元邻域上下文信息的充分利用, 从而使得检测算法的总体精度(虚警与漏检)达到最佳(Kwan, 2019)。最近, Hou等(2021)结合代数运算与空间形态学特征提出了一种高光谱遥感图像变化检测方法, 该方法通过引导滤波将形态学空间信息与基于光谱信息的代数运算结果进行融合, 虽然降低了变化检测的漏检率却未有效抑制虚警现象。因此, 从漏检与虚警平衡的角度出发, 充分挖掘

与表示像元对的光谱信息差异特征, 对降低算法的漏检现象极其重要; 同时联合像元对的空间信息降低算法虚警现象, 值得进一步思考与探索。基于此, 本文提出了一种光谱—频域属性模式融合的高光谱遥感图像变化检测方法 SFDAPF (Spectral-Frequency Domain Attribute Pattern Fusion)。首先, 设计一种基于梯度相关性的光谱绝对距离 GCASD (Gradient Correlation-Based Absolute Spectral Distance), 使像元对的变化属性从光谱信息表征方面得到了逐级量化; 其次, 基于傅里叶变换理论提出了一种高光谱遥感图像的变化像元属性模式显著性增强 SE (Significant Enhancement) 策略, 从全局空间信息利用方面增强了变化与非变化属

性模式的可分性; 再次, 本文将全图变化属性显著水平与 GCASD 进行有效融合, 得到变化检测的综合界定值; 最后, 依据虚警阈值确定双时相高光谱遥感图像变化检测的二值化结果。

2 研究方法

本文提出的光谱—频域属性模式融合的高光谱遥感图像变化检测方法主要包含 2 个部分, 即基于梯度相关性的光谱绝对距离与基于傅里叶变换理论的显著性增强策略, 其具体架构流程如图 1 所示。总的来说, 前者从光谱特征层面对像元对的变化属性进行逐级量化; 后者从频域高频幅度特征增强了变化属性像元的显著性。




图 1 基于光谱—频域属性模式融合的高光谱遥感图像变化检测流程图

Fig. 1 Outline of change detection in hyperspectral remote sensing image via spectral-frequency domain attribute pattern fusion

2.1 图像分组及融合

在计算 2 时相高光谱遥感图像像元对的梯度相关性绝对距离之前, 本文分别对原始图像 I_{T_1} 与 I_{T_2} 进行波段分组与融合, 目的在于消除噪声波段以及提升算法执行效率 (Tu 等, 2021)。首先, 本文分别将 I_{T_1} 与 I_{T_2} 划分为 M 个具有连续且相邻波段的波段子集, 第 m 个 ($m=1, 2, \dots, M$) 波段子集 H^m 表示为

$$H^m = \begin{cases} I^{(m-1) \lfloor Q/M \rfloor + 1}, \dots, I^{m \lfloor Q/M \rfloor}, & m \lfloor Q/M \rfloor \leq Q \\ I^{(m-1) \lfloor Q/M \rfloor + 1}, \dots, I^Q, & m \lfloor Q/M \rfloor > Q \end{cases} \quad (1)$$

式中, $I = [I^1, I^2, \dots, I^Q]$ 表示为具有 Q 个波段的 I_{T_1} 或 I_{T_2} 图像, $\lfloor Q/M \rfloor$ 为不大于 Q/M 的最大整数。值得一提的是, 本文依据 Zhou 等 (2021) 在高光谱

遥感图像分类任务中的经验, 将波段分组的数量 M 设置为 25。

一旦获得 H^m 波段子集, 则 I_{T_1} 或 I_{T_2} 的融合图像 R^m 可以被定义为

$$R^m = \frac{1}{U} \sum_{t=1}^{U_m} H_{t_m}^m \quad (2)$$

式中, U_m 为第 m 个波段子集中的波段数量, $H_{t_m}^m$ 表示为第 m 个波段子集中第 t_m 个波段。

2.2 梯度相关性的光谱绝对距离

光谱绝对距离 D_{ad} 在变化检测任务中是 1 种简单直观的检测器, 其公式表达为

$$D_{ad} = \sum_{i=1}^Q |B_i^{T_1} - B_i^{T_2}| \quad (3)$$

式中, Q 是高光谱遥感图像 I_{T_1} 或 I_{T_2} 各自的波段数

量, $B_i^{T_1}$ 和 $B_i^{T_2}$ 分别表示 I_{T_1} 或 I_{T_2} 第 i 个波段的图像。光谱绝对距离检测器的基本假设在于像元或区域的变化会引起地物辐亮度明显变化, 因此辐射校正和几何校正对 2 期图像的变化检测结果有着显著的影响。参考 Hou 等 (2022) 报道, 利用 2 期影像待测像元在 8 连通邻域像元上的光谱和空间相似性, 设计了光谱角权重的局部绝对距离 res_b , 其公式为

$$\text{res}_b = \left(\sum_{j=1}^8 \sum_{k=1}^Q \left| \mathbf{x}_{j,k}^{T_1} - \mathbf{x}_{j,k}^{T_2} \right| \right) \left(\frac{\mathbf{x}_b^{T_1} \cdot \mathbf{x}_b^{T_2}}{\left| \mathbf{x}_b^{T_1} \right| \left| \mathbf{x}_b^{T_2} \right|} \right) \quad (4)$$

$b = 1, 2, \dots, N$

式中, N 表示 I_{T_1} 或 I_{T_2} 任一高光谱遥感图像的像元数量, $\mathbf{x}_b^{T_1}$ 与 $\mathbf{x}_b^{T_2}$ 分别为 I_{T_1} 或 I_{T_2} 图像的待测像元, $\mathbf{x}_{j,k}^{T_1}$ 和 $\mathbf{x}_{j,k}^{T_2}$ 是对应于单波段图像 8 连通邻域中像元的光谱向量。事实上, 从式 (4) 中不难看出, 两期影像中变化属性的界定值是依据待测像元的 8 连通邻域像元间的光谱绝对距离以及待测像元之间余弦相似性而确定。因此, 介于变化与非变化区域的边界与角点像元极大程度上会判为变化像元, 从而引发围绕变化像元或区域的虚警现象。

为了克服上述问题, 本文设了 1 种梯度相关性的光谱绝对距离, 如图 2 所示。首先, 本文对图像融合后 2 期图像 R_{T_1} 与 R_{T_2} 的边缘以“对称”方式进行填充, 以确保边缘与角点像元具有 8 连通区域。本文中, 填充的行列数均为 2。




图2 梯度相关性光谱绝对距离

Fig. 2 Gradient correlation-based absolute spectral distance

其次, 2 期图像 R_{T_1} 与 R_{T_2} 的 8 连通区域中心像元对的光谱绝对距离 dist_b 被定义为

$$\text{dist}_b = \sum_{i=1}^Q \left| r_{i,b}^{T_1} - r_{i,b}^{T_2} \right|, \quad b = 1, 2, \dots, N \quad (5)$$

式中, $r_{i,b}^{T_1}$ 表示 R_{T_1} 图像中第 b 个像元 $\mathbf{r}_b^{T_1}$ 的第 i 个波段的光谱反射值, $r_{i,b}^{T_2}$ 表示 R_{T_2} 图像中第 b 个像元 $\mathbf{r}_b^{T_2}$ 的第 i 个波段的光谱反射值。

然后, 本文引入光谱余弦距离函数 $f(\mathbf{y}_{T_1}, \mathbf{y}_{T_2})$,

以量化各像元对之间的相似性, 其表达式为

$$f(\mathbf{y}_{T_1}, \mathbf{y}_{T_2}) = \frac{\mathbf{y}_{T_1} \cdot \mathbf{y}_{T_2}^T}{\left| \mathbf{y}_{T_1} \right| \left| \mathbf{y}_{T_2}^T \right|} \quad (6)$$

式中, $\mathbf{y}_{T_1} \in \mathbb{R}^Q$ 与 $\mathbf{y}_{T_2} \in \mathbb{R}^Q$ 为表示 2 时相图像像元的通用符号。因此, 中心像元对的余弦相似性为 $\omega_b = f(\mathbf{r}_b^{T_1}, \mathbf{r}_b^{T_2})$ 。此处, 若仅用光谱绝对距离与余弦相似性界定像元对的属性模式, 将导致属性模式趋向于变化属性, 原因在于高光谱遥感数据获取的过程中往往受云层遮挡、传感器抖动等自然与非自然因素的影响。为此, 本文利用中心像元 8 连通区域像元之间的余弦相似值 ω_{c-b} , 构造了权重缩放因子 g_b , 逐级量化像元对的光谱属性模式, 从而有效克服了虚警现象, 公式为

$$\omega_{c-b} = f(\mathbf{r}_{c-b}^{T_1}, \mathbf{r}_{c-b}^{T_2}) \quad (c = 1, 2, \dots, 8) \quad (7)$$

$$g_b = \frac{1}{8} \sum \left| \text{Grad}(\omega_{c-b}) \right| \quad (8)$$

式中, $\mathbf{r}_{c-b}^{T_1}$ 和 $\mathbf{r}_{c-b}^{T_2}$ 分别表示为 $\mathbf{r}_b^{T_1}$ 与 $\mathbf{r}_b^{T_2}$ 中心像元对应的第 c 个邻域像元, $\text{Grad}(\cdot)$ 为对 ω_{c-b} 内各分量计算梯度的表达式, g_b 表示由梯度相关性构成的权重缩放因子。

最后, 本文通过 8 连通区域平均余弦权重、权重缩放因子以及中心像元对的光谱绝对距离, 构造经 g_b 缩放后的平均余弦权重 s_b , 获取全图光谱属性模式的综合界定值 D , 计算公式为

$$s_b = \bar{\omega}_b \times (1 - g_b) \quad (9)$$

$$D = s_b \times \text{dist}_b, \quad b = 1, 2, \dots, N \quad (10)$$

式中, $\bar{\omega}_b$ 为 ω_{c-b} 的平均余弦权重。

2.3 傅里叶变换理论的频域显著性增强

近年来, 图像显著性检测的研究热度逐渐由自然图像处理领域蔓延、发展至遥感图像处理领域 (Cong 等, 2019; Li 等, 2019)。显著性检测中存在 1 个基本假设 (Koch 和 Poggio, 1999), 即: 视觉系统对频繁出现的特征具有较低的响应, 而对偏离规范的特征保持敏感。受此启发, 本文从图像显著性检测的思路出发, 设计了基于傅里叶变换理论的高光谱遥感图像变化属性显著性增强方案。由于高光谱遥感图像的高维特征, 本文首先采用主成分分析算法 (Prasad 和 Bruce, 2008) 分别提取 2 期遥感图像的第一主成分特征, 同时利用图像差值运算获取 2 时相第一主成分特征之间的结构与纹理差异信息 G (图像)。

其次, 本文利用傅里叶变换将图像 G 映射到

频域，并从图像频谱特征中提取其幅度谱 $A(f)$ ，公式表示如下：

$$A(f) = \mathcal{R}(\mathcal{F}(G)) \quad (11)$$

式中， $\mathcal{F}(\cdot)$ 与 $\mathcal{R}(\cdot)$ 分别表示傅里叶变换与取频域复数特征的模值（幅度谱）。事实上，对变化检测任务而言，变化属性属于高频分量而非变化属性属于低频分量，而傅里叶频谱的平均振幅 $A(f)$ 与频率倒数成正比（Srivastava 等，2003；Hou 和 Zhang, 2007），因而非变化属性对应于高幅值。此处，本文对 $A(f)$ 进行了 $\log$ 变换（ $\mathcal{L}(f)$ ），抑制非变化属性的幅值上限，同时放大变化属性的幅值的差异性，公式表达如下所示：

$$\mathcal{L}(f) = \log(A(f)) \quad (12)$$

然后，本文引入二维高斯滤波对图像的 $\log$ 幅度谱进行标准差诱导的窗口 $\omega_g \times \omega_g$ 滑动滤波，以进一步抑制非变化属性的幅度，从而提升变化和变化属性像元的可分性。其中，二维高斯掩码函数 $K(\mathbf{x}, \mathbf{y})$ 及其滤波输出 $\mathcal{G}(f)$ 如下所示：

$$K(\mathbf{x}, \mathbf{y}) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{(\mathbf{x} - \mathbf{x}_c)^2 + (\mathbf{y} - \mathbf{y}_c)^2}{2\sigma^2}\right) \quad (13)$$

$$\mathcal{G}(f) = \mathcal{L}(f) \times K(\mathbf{x}, \mathbf{y}) \quad (14)$$

$$\omega_g = 2 \times \text{ceil}(2\sigma) + 1 \quad (15)$$

式中， $\mathbf{x}_c$ 与 $\mathbf{y}_c$ 为中心像元的二维坐标位置， $\mathbf{x}_c = \frac{(\omega_g - 1)}{2} + 1$ ， $\mathbf{x}$ 与 $\mathbf{y}$ 表示8连通区域像元的二维坐标， σ 为二维高斯滤波的标准差， $\text{ceil}(\cdot)$ 表示为向上取整数。

此外，为得到频域显著水平 G_1 ，本文对频域表示特征进行相位谱特征提取 $P(f)$ ，公式表示如下所示：

$$P(f) = \mathcal{I}(\mathcal{F}(G)) \quad (16)$$

式中， $\mathcal{I}(\cdot)$ 为对频域复数特征取其虚部的函数。此后，利用 $\mathcal{G}(f)$ 和 $P(f)$ 进行逆傅里叶变换，获得频域显著水平 G_1 ，其公式表达如下所示：

$$G_1 = \mathcal{F}^{-1}(\exp(\mathcal{G}(f) + P(f)))^2 \quad (17)$$

式中， $\mathcal{F}^{-1}(\cdot)$ 表示为逆傅里叶变换。当梯度相关性的光谱绝对距离 D 与频域显著水平 G_1 均获得以后，本文对两者进行点乘运算，以获取全图属性模式的光谱—频域综合界定值 V_c ，公式如下所示：

$$V_c = \text{Norm}(D) \times \text{Norm}(G_1) \quad (18)$$

式中， $\text{Norm}(\cdot)$ 表示最大最小归一化函数。

2.4 虚警阈值二值化分割

为获得双时相高光谱遥感图像变化检测的二值化分类结果，本文将 V_c 的值从最小值到最大值等间距划分 5000 个备选阈值，并在每个备选阈值下统计本文方法的查全率及虚警率，最后，在虚警率 β_1 水平下，以阈值对全图进行二值化分割。值得一提的是，下文将以实验的方式对不同虚警率水平下的变化检测效果进行详细分析。

3 实验结果与分析

3.1 实验数据集描述

(1) 河流数据集：该数据集利用 Earth Observing-1 (EO-1) Hyperion 传感器分别于 2013 年 5 月 3 日和 2013 年 12 月 31 日在中国江苏省某个河流区域进行收集，包含 2 个时相的高光谱遥感图像，每个图像共有 242 个光谱波段。单幅影像的光谱范围为 0.4—2.5 μm ，光谱分辨率为 10 nm，图像大小为 463×241 像素，图像中主要变化的覆盖类型为河滩。值得一提的是，本文实验采用了高光谱遥感图像中的 198 个高信噪比波段进行了方法性能验证，其获取途径为 <http://crabwq.github.io>。图 3 为河流数据集 T1 和 T2 时相的假彩色图以及地面真值图 GT (Ground Truth)。此外，从该数据集地面真值图与 2 期假彩色图像对比中观察，地面真值图似乎存在“斑点噪声”，原因在于用 ENVI 生成的 2 期假彩色图像的斑点区域差异可视化不明显，但对应区域确实存在覆盖变化，该数据集细节信息请参考 (Wang 等，2019)。

(2) 农场数据集：该数据集同样由 EO-1 Hyperion 传感器分别于 2006 年 5 月 3 日和 2007 年 4 月 23 日在中国江苏省盐城市某个湿地农业区所采集。单幅影像的光谱范围、光谱分辨率与河流数据集类似。该数据集图像的大小为 420×140 像素，去除噪声及水吸收波段后的 154 个光谱波段用于本文算法性能验证实验，该数据集细节信息请参考 (Song 等，2018)。图 4 为农场数据集 T1 和 T2 时相的假彩色图以及地面真值图。

3.2 性能评价指标

本研究在二分类的混淆矩阵基础上引入了总体准确率 OA (Overall Accuracy)、平均准确率 AA (Average Accuracy)、Kappa 系数 (Kappa)、交并

比IoU (Intersection over Union) 以及F1分数 (F1-score) 等5个性能评估指标, 以客观公正地评判各个双时相高光谱遥感图像变化检测算法的性能优劣性。此外, 本文中变化像元的总体精度记为OAc以及非变化像元的总体精度记作OAu。




图3 河流高光谱遥感图像数据集

Fig. 3 River hyperspectral remote sensing images dataset




图4 农场高光谱遥感图像数据集

Fig. 4 Farmland hyperspectral remote sensing images dataset

3.3 参数设置及分析

在本研究所提出的SFDAPF变化检测方法中, 高斯滤波标准差 σ 与虚警阈值 β_i 的大小将会直接影响SFDAPF方法的检测精度 (包括OA、OAu及

OAc)。因此, 本研究分别在河流与农场高光谱遥感图像数据集上探讨了 σ 与 β_i 对SFDAPF方法检测精度的定量化影响。图5与图6中的红色箭头表示标准差 σ 与虚警阈值 β_i 分别设定为某一值时OA、OAu及OAc所对应的指标。蓝色箭头为本文所设定 σ 与 β_i 参数下所对应的OA、OAu及OAc指标。

在基于河流高光谱遥感数据集的参数分析实验中, σ 与 β_i 的大小变化区间分别设置为 $\{0.1, 0.6, \dots, 4.1\}$ 和 $\{1 \times 10^{-3}, 2.5 \times 10^{-3}, \dots, 1 \times 10^{-1}\}$ 。图5展现了SFDAPF方法下OA、OAu及OAc等3个性能指标随不同 σ 与 β_i 值的变化程度。由图5 (a)可见: 当 σ 取值固定时, SFDAPF方法的OA值大小随着 β_i 从 1×10^{-3} 到 1×10^{-1} 区间的变化呈现了先上升后下降的趋势; 而当 β_i 取值固定, OA指标随着 σ 值的增大而缓慢减小。由图5 (b)和图5 (c)可知: 当虚警水平较高时, SFDAPF方法将会增大对变化像元的敏感性, OAc指标相对较高而OAu指标相对较低所示); 当虚警水平较低时, SFDAPF方法将会降低对变化像元的感知能力, OAc指标有所下降而OAu指标有所上升 (图5中红蓝箭头所示)。 σ 的大小决定了高斯函数的宽度, σ 越大函数图像跨幅越宽, 反之则越窄。换言之, 其值大小影响着平滑程度。而在SFDAPF方法中, 滤波的目的在于抑制非变化像元的幅度特征从而增强变化和变化像元的可分性, 因此较大的 σ 并不是最佳的选择。此外, 若仅依据SFDAPF方法的OA指标选取最佳的 σ 与 β_i , 似乎并不能获得最好的检测效果 (图5中红蓝箭头所示)。其原因在于, 变化像元在图像中属于少数部分, 非变化像元检测精度较高时OA指标同样能够取得最高值。因此, 本文依据OA、OAu以及OAc三者的平衡, 将 σ 与 β_i 分别设置为0.1与 2.5×10^{-2} 。

同样地, 本文在农场高光谱遥感数据集上分析了高斯滤波标准差 σ 与虚警阈值 β_i 对本文SFDAPF方法的检测精度影响。 σ 与 β_i 的大小变化区间同样分别设置为 $\{0.1, 0.6, \dots, 4.1\}$ 和 $\{1 \times 10^{-3}, 2.5 \times 10^{-3}, \dots, 1 \times 10^{-1}\}$ 。如图6所示, SFDAPF方法的OA、OAu及OAc等3个指标随 σ 与 β_i 取值变化的总体趋势与河流数据集上大致类似。在农场数据集上, 本文同样对最高OA取值与次高OA取值的 σ 与 β_i 进行了分析, 结果见图6。可见: 当 σ 与 β_i 分别设定为0.1和 1×10^{-2} 时, SFDAPF方法

的OA、OAu与OAc取值分别达到97.35%、99.00%和96.77%，此时OA为最高（如图6中红蓝箭头所示）。而当 σ 与 β_i 分别设定为0.1和 2.5×10^{-2} 时，SFDAPF方法的OA、OAu与OAc取值分别达到97.29%、97.50%和93.31%，此时OA为次高。根据最高与次高指标的分析，OA与OAu指标分别降低0.06%和2.50%，OAc指标提升了3.46%，这表

明仅依据SFDAPF方法的OA指标设定 σ 与 β_i 值，将使SFDAPF方法无法取得漏检与虚警的合理平衡。因此，河流与农场2个数据集的参数分析实验结果均证明了本文SFDAPF方法在变化检测任务的有效性。此外，若将SFDAPF方法拓展至新的双时相高光谱遥感图像数据集，本文建议将SFDAPF方法的 σ 与 β_i 参数分别设置为0.1与 2.5×10^{-2} 。




图5 河流高光谱遥感图像数据集上高斯滤波标准差 σ 与虚警阈值 β_i 对所提出的SFDAPF方法的变化检测总体精度影响
Fig. 5 Influence of Gaussian filter standard deviation σ and false alarm threshold β_i on the change detection accuracy of the proposed SFDAPF method on the river hyperspectral remote sensing image dataset




图6 农场高光谱遥感图像数据集上高斯滤波标准差 σ 与虚警阈值 β_i 对所提出的SFDAPF方法的变化检测总体精度影响
Fig. 6 Influence of Gaussian filter standard deviation σ and false alarm threshold β_i on the change detection accuracy of the proposed SFDAPF method on the farmland hyperspectral remote sensing image dataset

3.4 组件性能贡献分析

本文提出的SFDAPF方法由梯度相关性绝对光谱距离（GCASD）、图像融合（IF）以及显著性增强（SE）3个核心组件构成。因此，本小节在河流与农场数据集上定性与定量地分析了每个核心组件对SFDAPF方法的性能贡献。首先，本文在河流高光谱遥感图像上，从定性层面的图像可视化角度，分别给出了GCASD组件、SE组件、GCASD与

SE组件融合（记作GCASD&SE）的可视化像元属性模式的强度信息以及SFDAPF方法的变化检测结果（图7）。图7（b）为GCASD组件的像元属性强度信息，可见检测结果对像元对的变化属性极为敏感，从而导致大多数像元均趋向于变化像元。图7（c）为SE组件的像元属性强度信息，可见该强度信息对标地面真实值（图7（a））和图7（b），具有更为理想的虚警现象。但是，SE组件的强度信

息在孤立点与小面积变化区域表现出低显著程度现象。因此，将GCASD组件与SE组件的强度信息进行融合，能够在非变化像元抑制与变化像元增强方面得到有效互补，其融合结果如图7（d）所示，像元属性模式相比于图7（b）和图7（c）更接近于地面真实值，对应的SFDAPF变化检测结果如图7（e）所示。




图7 GCASD与SE组件以及SFDAPF方法对河流高光谱遥感图像的变化区域的可视化结果(GT为地面真值图)
Fig. 7 Visualization of GCASD and SE components and SFDAPF method for changing regions of river hyperspectral remote sensing images

其次，本文在河流与农场高光谱遥感数据集上分别对GCASD、IF及SE组件的性能贡献进行了定量分析。实验结果如表1所示，值得注意的是，表1中所有组件及SFDAPF方法的F1、IoU及OA变化检测指标均在虚警率 2.5×10^{-2} 水平下计算得到。由表可知，GCASD在河流数据集上的F1、IoU、OA指标及时间消耗分别为0.98024、0.96124、0.96410和34.2。同时，由表观察，尽管IF组件的引入对GCASD 3个指标具有微幅退化效应，但是时间消耗方面能够降低42.9 s的运行时间，这极大地提高了GCASD计算效率。类似地，对于GCASD及IF组件在农场数据集上的检测精度与时间消耗同样得出与河流数据上相同的结论。这说明IF组件在算法执行效率方面具有较大的贡献。此外，由表1结果可知，SE组件的F1、IoU及OA指标在河流数据集上均略低于GCASD组件，而在农场数据集上均略高于GCASD组件，但GCASD与SE的综合检测结果（即SFDAPF）均优于GCASD与SE组件的任一结果。这充分表明梯度相关性光谱绝对距离与显著性增强结果的融合在变化检测任务上具有信息互补性，能够有效提高本文方法的变化检测精度。值得注意的是，SE组件的执行时间无论是在河流数据集还是在农场数据集都具有较低的时间消耗，均在3 s左右。因此，从检测精度与时间消耗角度综合来看，SE组件是非常具有贡献的方法组件。

表1 所提方法在不同高光谱遥感数据集上的各组成部分性能贡献

Table 1 Performance contribution of each component of the proposed method on different hyperspectral remote sensing datasets

指标	河流高光谱遥感数据集				农场高光谱遥感数据集			
	GCASD	IGF	SE	SFDAPF	GCASD	IGF	SE	SFDAPF
F1	0.98043	0.98024	0.97971	0.98076	0.97281	0.97072	0.97865	0.98078
IoU	0.96162	0.96124	0.96023	0.96225	0.94705	0.94310	0.95820	0.96229
OA	0.96447	0.96410	0.96312	0.96508	0.96130	0.95824	0.97011	0.97287
时间/s	77.1	34.2	3.38	34.7	35.4	19.0	2.94	19.4

注：粗体表示为每个评估指标中的最高精度。OA为总体精度；F1为F1分数；IoU为交并比指标。GCASD为基于梯度相关性的光谱绝对距离；IF为图像融合；SE为显著性增强；SFDAPF为本文方法。

此外,图8给出了农场高光谱遥感图像地面真值图与GCASD、IF、SE及SFDAPF的变化检测效果图。值得注意的是,为了清晰观察与对比,本文对地面真值图及检测效果图的3个区域分别进行了红、黄、蓝颜色圈定;GCASD、IF、SE及SFDAPF方法的二值化结果分别在OA指标为96.82%、96.13%、97.01%和97.29%下所获得。由图可知,尽管GCASD方法采用了局部上下文信息去定义像元属性模式的界定值,但在检测结果中仍存在较多的虚警现象。IF方法的检测结果图与GCASD方法检测结果图相差不大,但其在执行效率方面的贡献非常显著,这在上述部分已经进行了实验分析。SE方法的变化检测效果图相比于

GCASD和IF方法,则虚警现象得到了明显的改善。这充分表明,对频域幅度特征进行高斯滤波能够有效抑制非变化像元,提升了变化像元的显著性,从而改善了虚警现象。此外,图8(e)给出了由GCASD与SE组件像元属性模式界定值融合所得到的SFDAPF方法检测结果,由图可知,SFDAPF方法检测结果比GCASD与SE组件中任一组件的检测都具有较少的虚警现象(红、黄及蓝区域)。该结果表明,本文对梯度相关性光谱绝对距离以及频域显著性水平进行融合,对高光谱遥感图像变化检测的虚警和漏检现象的改善是极其有效的,能够有助于变化检测任务的图像解释。




图8 农场高光谱遥感数据集上各组件以及SFDAPF方法的变化检测效果

Fig. 8 Change detection effect of each component and SFDAPF method on farm hyperspectral remote sensing dataset

3.5 不同变化检测方法的性能比较

为进一步验证提出的SFDAPF方法在双时相高光谱遥感图像变化检测任务中的有效性,本文使用SFDAPF方法和其他变化检测方法进行比较分析。对比方法包括经典的CVA (Carvalho等, 2011)、PCA-CVA (Baisantray等, 2012)与IRMAD (Nielsen, 2007)方法以及先进的PTCD (Hou等, 2021)、SALA (Hou等, 2022)与MMPs (Hou等, 2022)方法。

其中,CVA是利用2期图像各波段的差值和作为像元属性模式的界定值;PCA-CVA是在CVA之

前采用了主成分分析算法进行特征提取;IRMAD是在多变量检测方法基础上引入迭代重加权的检测变化检测方法;PTCD为基于局部块张量分解和重建策略的检测方法;SALA为基于光谱角加权局部绝对距离的检测方法;MMPs在SALA的基础上引入形态学滤波的变化检测方法。上述对比方法中所涉及的实验参数分别使用对应文献中默认的参数。此外,本文使用河流与农场2个双时相高光谱遥感数据集来进行性能验证实验,采用3.2部分中的OA、AA、Kappa、IoU以及F1等5个性能评估指标对各方法的性能优越性进行评测。

表2和图9给出了CVA、PCA-CVA、IRMAD、


PTCD、SALA、MMPs及本文SFDAPF方法在河流数据集上的实验结果。就经典的变化检测方法CVA、PCA-CVA及IRMAD分析而言，由表2观察可知，CVA的OAc和OAu为0.97391和0.87660，PCA-CVA的OAc和OAu为0.95184和0.95030，IRMAD的OAc和OAu为0.97103和0.71778，CVA的检测结果对像元的变化属性模式更为敏感，IRMAD的检测结果对像元的变化属性模式为警惕，而PCA-CVA方法相比两者取得了较好的检测结果。实际上，CVA仅采用像元对之间的光谱特征差值和评判像元的属性模式，而IRMAD和PCA-CVA则是在计算属性模式界定值之前分别执行了仿射变换与主成分特征提取操作，因此像元属性模式的判定结果优于CVA方法。此外，这3个方法与本文SFDAPF方法比较而言，不难看出


SFDAPF的OAc指标低于CVA与PCA-CVA方法，其原因在于SE组件通过频域二维高斯滤波获取高置信的变化像元强度信息的同时也一定程度上抑制了纹理信息与周围像元差异较微弱的变化像元的强度信息，使得变化与非变化像元强度信息的对比度较大，导致SFDAPF方法收缩了变化像元属性模式的强度信息范围，从而呈现出OAc指标偏低。但SFDAPF方法的OAu指标是3个方法中的最高精度（0.97504）。同时，SFDAPF方法的F1（0.98076）、IoU（0.96225）、OA（0.96508）3个指标同样远高于上述3个经典方法。结果表明：与经典方法比较，本文SFDAPF方法在梯度相关性光谱绝对距离计算阶段引入像元局部上下文信息以及采用全局显著性增强策略对降低虚警是有效的。

表2 各方法在河流高光谱遥感数据上采用不同评估指标的检测结果
Table 2 Detection results of different methods using different evaluation indicators on river hyperspectral remote sensing dataset

方法	AA	OAu	OAc	Kappa	F1	IoU	OA	时间/s
CVA	0.92525	0.87660	0.97391	0.54010	0.93301	0.87442	0.88505	9.57×10^{-2}
PCA-CVA	0.95107	0.95184	0.95030	0.74778	0.97297	0.94736	0.95170	9.87×10^{-1}
IRMAD	0.84440	0.97103	0.71778	0.68196	0.97205	0.94562	0.94902	4.81×10^{-1}
PTCD	0.75330	0.91018	0.59641	0.40713	0.93419	0.87651	0.88291	1.29×10^3
SALA	0.92881	0.91165	0.94597	0.61456	0.95122	0.90698	0.91463	5.57
MMPs	0.93119	0.92239	0.93999	0.64275	0.95679	0.91715	0.92392	1.36×10^2
SFDAPF	0.91771	0.97504	0.86038	0.79152	0.98076	0.96225	0.96508	3.47×10^1

注：粗体表示为每个评估指标中的最高精度。AA为平均精度；OAu和OAc分别为未变化像元和变化像元总体精度；Kappa为用于一致性检验评估指标。





(e) PTCD (OA=88.29%) (f) SALA (OA=92.39%) (g) MMPs (OA=91.46%) (h) SFDAPF (OA=96.51%)

图9 各方法在河流高光谱遥感数据集上的变化检测效果

Fig. 9 Change detection effect of each method on river hyperspectral remote sensing dataset

与先进的变化检测方法比较而言,即PTCD、SALA以及MMPs方法。由表2可知,MMPs在AA、OA等5个指标方面的精度远高于PTCD方法同时也略高于SALA方法,为3个先进方法中精度指标最高的一个竞争方法。相比之下,尽管本文SFDAPF方法的AA和OAc指标低于MMPs方法,但是OAu、Kappa、F1、IoU和OA分别达到了0.97504、0.79152、0.98076、0.96225和0.96508,均优于MMPs对应的指标精度。此外,就算法执行时间方面来评估,本文SFDAPF方法相比于传统方法需要较多的时间消耗,但是比PTCD与MMPs检测方法明显具有时间消耗方面的优势。这进一步说明本文SFDAPF方法在检测精度与时间消耗方面的有效性与可行性。

图9给出了各方法在最高OA指标下的二值化检测结果。由图9可知,CVA、PCA-CVA、PTCD、SALA、MMPs等5个对比均出现不同区域不同程度的虚警现象,而IRMAD方法则存在严重的漏检现象。相比之下,依据检测结果及OA指标的分析与比较,本文SFDAPF方法在虚警与漏检中达到了较好的平衡,其二值化检测结果更接近于图9(a)的地面真值图以及OA指标为最高精度。因此,从可视化的二值化结果来看,进一步验证了本文SFDAPF方法比传统的与最新的检测方法更具性能优越性。

表3和图10给出了上述6个对比方法及本文SFDAPF方法在农场高光谱遥感图像数据集上的实验结果与二值化检测结果。不同于河流数据集,农场数据集成块变化的区域占绝大多数,孤立点

的变化像元为极少部分。由表3观察,本文SFDAPF方法的AA、Kappa、F1、IoU、OA指标达到了最高的精度,比次高精度分别高出了0.01985、0.05653、0.01474、0.02798、0.02187。此外,SFDAPF方法的OAu(0.97500)与OAc(0.96766)指标并未取得最高精度,但仅比最高精度分别低了0.00673和0.01237,可以称之为略低于最高精度。算法时间消耗方面,本文SFDAPF方法比CVA、PCA-CVA与IRMAD方法没有明显的运行效率优势,但是从性能与时间评估指标综合来看,传统方法的实用性并不如本文SFDAPF方法。与PTCD、SALA及MMPs等最新的检测方法对比而言,除了SFDAPF方法比SALA方法慢了13.07 s外,SFDAPF方法比PTCD与MMPs方法分别快了157.6与116.6 s了。因此,表3实验结果表明:从检测精度与时间消耗方面进行综合评述,本文SFDAPF方法通过融合梯度相关性光谱绝对距离与全局显著性增强结果,平衡了高光谱遥感图像变化检测任务中的虚警和漏检现象,极大地提高变化检测的总体识别与检测精度。

此外,图10呈现了地面真值图以及CVA、PCA-CVA、IRMAD、PTCD、SALA、MMPs、SFDAPF方法分别最高OA指标下的二值化检测结果图。由图可知,CVA、PTCD、SALA、MMPs方法均存在不同程度虚警现象,而PCA-CVA和IRMAD存在不同程度漏检现象。相比之下,本文SFDAPF方法取得较高的OA精度及变化检测效果,同样在虚警与漏检方面达到了平衡。尤其是,通

过河流和农场 2 个数据集是验证实验，本文 SFDAPF 方法是唯一一个在 2 个数据集同时取得虚警与漏检平衡的检测方法，这充分说明了本文 SFDAPF 方法在高光谱遥感图像变化检测任务上的鲁棒性和泛化性。

表 3 各方法在农场高光谱遥感数据集上采用不同评估指标的检测结果

Table 3 Detection results of different methods using different evaluation indicators on farmland hyperspectral remote sensing dataset								
方法	AA	OAu	OAc	Kappa	F1	IoU	OA	时间/s
CVA	0.93138	0.89428	0.96848	0.80847	0.93782	0.88291	0.91581	6.98×10^{-2}
PCA-CVA	0.92877	0.98173	0.87580	0.87817	0.96604	0.93431	0.95100	3.24×10^{-1}
IRMAD	0.65043	0.95085	0.35000	0.35673	0.85798	0.75129	0.77654	1.49
PTCD	0.90932	0.97004	0.84861	0.83799	0.95481	0.91352	0.93481	1.77×10^2
SALA	0.94637	0.92212	0.97062	0.85213	0.95353	0.91118	0.93619	6.33
MMPs	0.95148	0.92293	0.98003	0.86007	0.95586	0.91545	0.93949	1.36×10^2
SFDAPF	0.97133	0.97500	0.96766	0.93470	0.98078	0.96229	0.97287	1.94×10^1

注：粗体表示为每个评估指标中的最高精度。AA 为平均精度；OAu 和 OAc 分别为未变化像元和变化像元总体精度；Kappa 为用于一致性检验评估指标。




图 10 各方法在农场高光谱遥感数据集上的变化检测效果

Fig. 10 Change detection effect of each method on farmland hyperspectral remote sensing dataset

3.6 像元属性模式的可分性分析

图 11 为河流与农场高光谱遥感数据集上 6 个变化检测方法与本文提出的 GCASD 与 SFDAPF 方法的变化像元和非变化像元检测统计范围对比结果。蓝色与红色分别为变化与非变化像元的检测统计范围, 其中, 蓝色矩形与红色矩形相距越远表示变化像元与非变化像元的可分离性越大。如图 11 (a) 所示, 河流数据集上, 传统方法整体表现为不同属性模式之间可分性较低 (即 CVA 与 IRMAD)、变化像元界定值范围波动较大 (即 PCVA)。对最新的检测方法而言, 除了 PTC D 方法以外, SALA 与 MMPs 方法均表现出良好的可分性。相比之下, 本文 GCASD 方法在非变化像元抑制方

面略有优势, 尤其是, 对 GCASD 方法进行显著性水平增强后的 SFDAPF 方法, 在属性模式可分性以及非变化属性模式抑制方面有着显著改善。此结果表明: 本文将梯度向光性光谱绝对距离与频域显著性水平进行融合, 有助于变化检测任务的精度提升。图 11 (b) 呈现了各方法在农场数据集上各方法检测统计结果, 由图 11 可知, 本文 SFDAPF 方法能够在梯度相关光谱绝对距离的基础上更好的抑制非变化像元的属性模式, 同时比传统的和最新的检测方法更具变化与非变化属性模式之间的可分性。因此, 河流与农场数据集上的检测统计结果进一步说明了本文 SFDAPF 方法在双时相高光谱遥感图像变化检测任务上的有效性和泛化性。




图 11 各变化检测方法在河流与农场高光谱遥感数据集上变化与非变化像元的归一化检测统计范围

Fig. 11 Normalized detection statistic range of changing and non-changing pixels by each method in hyperspectral remote sensing datasets of river and farmland

4 结 论

本文提出的光谱—频域属性模式融合的高光谱遥感图像变化检测 GCASD 方法充分考虑了光谱信息表征及邻域空间信息利用。光谱信息表征方面, 在光谱角权重绝对距离的基础上进行改进并设计了 GCASD 方法, 其新颖之处有两个方面: (1) 在计算梯度相关性光谱绝对距离之前使用图像分组与融合方法, 在几乎不影响检测精度的情况下极大地降低了检测过程的计算量; (2) 将 8 连通邻域像元与中心像元余弦相关性的平均梯度作为权重

缩放因子, 使像元属性模式从光谱信息表征方面得到了逐级量化。空间信息利用方面, 借助于傅里叶变换理论, 从频域特征表示中的高频信息与幅度特征关系中设计了 SE 方法, 该方法能够有效抑制非变化像元的属性模式, 从而使得 GCASD 与 SE 融合后的 SFDAPF 方法能够显著改善变化与非变化像元属性模式之间的可分性, 有效地提升了变化检测的精度。

然而, 本文 SFDAPF 方法在梯度相关性光谱绝对距离计算阶段仅考虑了像元的单窗口 8 连通邻域, 并未对像元的双窗口邻域光谱信息表征进行

深入探讨, 相比于单窗口, 双窗口在孤立变化像元及大面积变化区域可能具有更好的变化属性模式的鉴别能力。此外, SFDAPF方法在显著性增强阶段仅利用了频域表示特征中的幅度特征, 并未对相位特征在变化属性模式显著性增强方面的作用进行深入挖掘。因此, 未来的研究工作将在SFDAPF算法的基础上进一步探索双窗口光谱信息表征以及频域表示特征的相位信息对双时相高光谱遥感图像变化检测的作用及贡献。

参考文献 (References)

- Baisantray M, Negi D S and Manocha O P. 2012. Change vector analysis using enhanced PCA and inverse triangular function-based thresholding. *Defence Science Journal*, 62(4): 236-242 [DOI: 10.14429/dsj.62.1072]
- Bovolo F, Bruzzone L and Marconcini M. 2008. A novel approach to unsupervised change detection based on a semisupervised SVM and a similarity measure. *IEEE Transactions on Geoscience and Remote Sensing*, 46(7): 2070-2082 [DOI: 10.1109/TGRS.2008.916643]
- Carvalho Jr O A, Guimarães R F, Gillespie A R, Silva N C and Gomes R A T. 2011. A new approach to change vector analysis using distance and similarity measures. *Remote Sensing*, 3(11): 2473-2493 [DOI: 10.3390/rs3112473]
- Cong R M, Lei J J, Fu H Z, Cheng M M, Lin W S and Huang Q M. 2019. Review of visual saliency detection with comprehensive information. *IEEE Transactions on Circuits and Systems for Video Technology*, 29(10): 2941-2959 [DOI: 10.1109/TCSVT.2018.2870832]
- Demir B, Bovolo F and Bruzzone L. 2012. Detection of land-cover transitions in multitemporal remote sensing images with active-learning-based compound classification. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5): 1930-1941 [DOI: 10.1109/TGRS.2011.2168534]
- Du B, Ru L X, Wu C and Zhang L P. 2019. Unsupervised deep slow feature analysis for change detection in multi-temporal remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 57(12): 9976-9992 [DOI: 10.1109/TGRS.2019.2930682]
- Du P J, Liu S C, Gamba P, Tan K and Xia J S. 2012. Fusion of difference images for change detection over urban areas. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(4): 1076-1086 [DOI: 10.1109/JSTARS.2012.2200879]
- Gao F, Wang X, Dong J Y and Wang S K. 2018. Synthetic aperture radar image change detection based on frequency-domain analysis and random multigraphs. *Journal of Applied Remote Sensing*, 12(1): 016010 [DOI: 10.1117/1.JRS.12.016010].
- Hemati M, Hasanlou M, Mahdianpari M and Mohammadimanesh F. 2021. A systematic review of landsat data for change detection applications: 50 years of monitoring the earth. *Remote Sensing*, 13(15): 2869 [DOI: 10.3390/rs13152869]
- Hou X D and Zhang L Q. 2007. Saliency detection: a spectral residual approach//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Minneapolis: IEEE: 1-8 [DOI: 10.1109/CVPR.2007.383267]
- Hou Z F, Li W and Du Q. 2021. A patch tensor-based change detection method for hyperspectral images//*Proceedings of 2021 IEEE International Geoscience and Remote Sensing Symposium*. Belgium: IEEE: 4328-4331 [DOI: 10.1109/IGARSS47720.2021.9554630]
- Hou Z F, Li W, Li L, Tao R and Du Q. 2022. Hyperspectral change detection based on multiple morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5507312 [DOI: 10.1109/TGRS.2021.3090802]
- Hu M Q, Wu C, Du B and Zhang L P. 2023. Binary change guided hyperspectral multiclass change detection. *IEEE Transactions on Image Processing*, 32: 791-806 [DOI: 10.1109/TIP.2022.3233187]
- Jaemsiri J, Titijaroonroj T and Rungrattanaubol J. 2019. Modified scale-space analysis in frequency domain based on adaptive multi-scale Gaussian filter for saliency detection//*Proceedings of 2019 16th International Joint Conference on Computer Science and Software Engineering*. Chonburi: IEEE: 218-223 [DOI: 10.1109/JCSSE.2019.8864211]
- Koch C and Poggio T. 1999. Predicting the visual world: silence is golden. *Nature Neuroscience*, 2(1): 9-10 [DOI: 10.1038/4511]
- Kwan C. 2019. Methods and challenges using multispectral and hyperspectral images for practical change detection applications. *Information*, 10(11): 353 [DOI: 10.3390/info10110353]
- Li J, Levine M D, An X J, Xu X and He H G. 2013. Visual saliency based on scale-space analysis in the frequency domain. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(4): 996-1010 [DOI: 10.1109/TPAMI.2012.147]
- Li M K, Li M, Zhang P, Wu Y, Song W Y and An L. 2019. SAR image change detection using PCANet guided by saliency detection. *IEEE Geoscience and Remote Sensing Letters*, 16(3): 402-406 [DOI: 10.1109/LGRS.2018.2876616]
- Liu S C, Marinelli D, Bruzzone L and Bovolo F. 2019. A review of change detection in multitemporal hyperspectral images: current techniques, applications, and challenges. *IEEE Geoscience and Remote Sensing Magazine*, 7(2): 140-158 [DOI: 10.1109/MGRS.2019.2898520]
- Luo F L, Du B, Zhang L P, Zhang L F and Tao D C. 2019. Feature learning using spatial-spectral hypergraph discriminant analysis for hyperspectral image. *IEEE Transactions on Cybernetics*, 49(7): 2406-2419 [DOI: 10.1109/TCYB.2018.2810806]
- Marchesi S and Bruzzone L. 2009. ICA and kernel ICA for change detection in multispectral remote sensing images//*Proceedings of*

- 2009 IEEE International Geoscience and Remote Sensing Symposium. Cape Town: IEEE: II-980-II-983 [DOI: 10.1109/IGARSS.2009.5418265]
- Nielsen A A. 2007. The regularized iteratively reweighted MAD method for change detection in multi-and hyperspectral data. *IEEE Transactions on Image Processing*, 16(2): 463-478 [DOI: 10.1109/TIP.2006.888195]
- Ortiz-Rivera V, Véléz-Reyes M and Roysam B. 2006. Change detection in hyperspectral imagery using temporal principal components//*Proceedings Volume 6233, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XII*. Orlando: SPIE: 368-377 [DOI: 10.1117/12.667961]
- Ou X F, Liu L Z, Tu B, Zhang G Y and Xu Z. 2022. A CNN framework with slow-fast band selection and feature fusion grouping for hyperspectral image change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5524716 [DOI: 10.1109/TGRS.2022.3156041]
- Prasad S and Bruce L M. 2008. Limitations of principal components analysis for hyperspectral target recognition. *IEEE Geoscience and Remote Sensing Letters*, 5(4): 625-629 [DOI: 10.1109/LGRS.2008.2001282]
- Shang X D, Song M P, Wang Y L, Yu C Y, Yu H Y, Li F and Chang C I. 2021. Target-constrained interference-minimized band selection for hyperspectral target detection. *IEEE Transactions on Geoscience and Remote Sensing*, 59(7): 6044-6064 [DOI: 10.1109/TGRS.2020.3010826]
- Song A, Choi J, Han Y and Kim Y. 2018. Change detection in hyperspectral images using recurrent 3D fully convolutional networks. *Remote Sensing*, 10(11): 1827 [DOI: 10.3390/rs10111827]
- Srivastava A, Lee A B, Simoncelli E P and Zhu S C. 2003. On advances in statistical modeling of natural images. *Journal of Mathematical Imaging and Vision*, 18(1): 17-33 [DOI: 10.1023/A:1021889010444]
- Su H J. 2022. Dimensionality reduction for hyperspectral remote sensing: advances, challenges, and prospects. *National Remote Sensing Bulletin*, 26(8): 1504-1529. (苏红军. 2022. 高光谱遥感影像降维: 进展、挑战与展望. *遥感学报*, 26(8): 1504-1529) [DOI: 10.11834/jrs.20210354]
- Su H J, Wu Z Y, Zhang H H and Du Q. 2022. Hyperspectral anomaly detection: a survey. *IEEE Geoscience and Remote Sensing Magazine*, 10(1): 64-90 [DOI: 10.1109/MGRS.2021.3105440]
- Tu B, Zhou C L, Peng J, Zhang G Y and Peng Y S. 2021. Feature extraction via joint adaptive structure density for hyperspectral imagery classification. *IEEE Transactions on Instrumentation and Measurement*, 70: 5006916 [DOI: 10.1109/TIM.2020.3038557]
- Wang L G, Wang L F, Wang Q M and Bruzzone L. 2022. RSCNet: a residual self-calibrated network for hyperspectral image change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5529917 [DOI: 10.1109/TGRS.2022.3177478]
- Wang Q, Yuan Z H, Du Q and Li X L. 2019. GETNET: a general end-to-end 2-D CNN framework for hyperspectral image change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 57(1): 3-13 [DOI: 10.1109/TGRS.2018.2849692]
- Yousif O and Ban Y F. 2014. Improving SAR-based urban change detection by combining MAP-MRF classifier and nonlocal means similarity weights. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(10): 4288-4300 [DOI: 10.1109/JSTARS.2014.2347171]
- Zhan T M, Song B, Sun L, Jia X P, Wan M H, Yang G W and Wu Z B. 2021. TDSSC: a three-directions spectral-spatial convolution neural network for hyperspectral image change detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 377-388 [DOI: 10.1109/JSTARS.2020.3037070]
- Zhang B, Yang W, Gao L R and Chen D M. 2012. Real-time target detection in hyperspectral images based on spatial-spectral information extraction. *EURASIP Journal on Advances in Signal Processing*, 2012: 142 [DOI: 10.1186/1687-6180-2012-142]
- Zhang J F, Xie L L and Tao X X. 2003. Change detection of earthquake-damaged buildings on remote sensing image and its application in seismic disaster assessment//*Proceedings of 2003 IEEE International Geoscience and Remote Sensing Symposium*. Toulouse: IEEE: 2436-2438 [DOI: 10.1109/IGARSS.2003.1294467]
- Zhao C H, Cheng H and Feng S. 2022. A spectral - spatial change detection method based on simplified 3-D convolutional autoencoder for multitemporal hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 19: 5507705 [DOI: 10.1109/LGRS.2021.3096526]
- Zheng K, Gao L R, Liao W Z, Hong D F, Zhang B, Cui X M and Channussot J. 2021. Coupled convolutional neural network with adaptive response function learning for unsupervised hyperspectral super resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 59(3): 2487-2502 [DOI: 10.1109/TGRS.2020.3006534]
- Zhou C L, Tu B, Li N Y, He W and Plaza A. 2021. Structure-aware multikernel learning for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 9837-9854 [DOI: 10.1109/JSTARS.2021.3111740]
- Zhou C L, Tu B, Ren Q and Chen S Y. 2022. Spatial peak-aware collaborative representation for hyperspectral imagery classification. *IEEE Geoscience and Remote Sensing Letters*, 19: 5506805 [DOI: 10.1109/LGRS.2021.3083416]

Spectral–frequency domain attribute pattern fusion for hyperspectral image change detection

ZHOU Chengle^{1,2}, SHI Qian^{1,2}, LI Jun³, ZHANG Xinchang⁴

1. School of Geography and Planning, Sun Yat-Sen University, Guangzhou 510275, China;

2. Guangdong Provincial Key Laboratory for Urbanization and Geo-Simulation, Guangzhou 510275, China;

3. School of Computer Science, China University of Geosciences, Wuhan 430074, China;

4. School of Geography and Remote Sensing, Guangzhou University, Guangzhou 510006, China

Abstract: HyperSpectral Imagery (HSI) is a three-dimensional cube data that combines spatial imagery and spectral information, which introduces increased conveniences to the accurate interpretation of observation information of ground coverings. However, high-dimensional nonlinear data processing for the HSI Change Detection (HSI-CD) task encounters challenges. Therefore, an HSI-CD method based on Spectral-Frequency Domain Attribute Pattern Fusion (SFDAPF) is introduced to gradually quantify the spectral representation of pixel attribute patterns. Specifically, a Saliency Enhancement (SE) strategy for pixel attribute patterns based on Fourier transform theory is developed to improve the separability between pixel attribute patterns in the current work. The proposed SFDAPF method comprises four components as follows.

First, a gradient correlation-based spectral absolute distance (GCASD) is designed in this paper. Therefore, the attribute patterns of pixel pairs in bitemporal HSI can be gradually quantified from the aspect of spectral information representation. Then, an SE strategy of attribute patterns of pixel pairs is proposed in accordance with Fourier transform theory, which improves the separability of attribute patterns of changing and non-changing pixel pairs in terms of global spatial information utilization. Next, the saliency level and GCASD per pixel are fused to obtain the comprehensive discrimination value of change detection. Finally, the binarization results of the bitemporal HSI-CD are obtained in accordance with the false alarm threshold.

The proposed SFDAPF method is applied to two open-source bitemporal HSI datasets (i.e., River and Farmland datasets). Experimental results show that the proposed SFDAPF method can outperform the traditional and state-of-the-art HSI-CD methods. For the River dataset, compared with the traditional methods, the SFDAPF method in this paper introduces the local context information of the pixel in the calculation stage of the GCASD and adopts the global SE strategy, which is effective in reducing false alarms. Compared with the state-of-the-art methods, the SFDAPF method in this paper achieves the highest accuracy for most of the performance evaluation indicators. For the Farmland dataset, the AA, Kappa, F1, IoU, and OA indicators of the SFDAPF method in this paper have reached the highest accuracy, which is 0.01985, 0.05653, 0.01474, 0.02798, and 0.02187 higher than the second highest accuracy. In addition, the OAu (0.97500) and OAc (0.96766) indicators of the SFDAPF method did not achieve the highest accuracy. However, they were only 0.00673 and 0.01237 lower than the highest accuracy, which can be called slightly lower than the highest accuracy. Therefore, the experiments verified the effectiveness of the proposed SFDAPF method in the HSI-CD task.

The proposed SFDAPF method generally considers the representation of spectral information and the utilization of neighborhood spatial information, thus promoting the overall accuracy of HSI-CD. However, the proposed SFDAPF method only considers the single-window eight-connected neighborhood in the spectral characterization stage and the magnitude features represented in the frequency domain. Therefore, future research work should further explore the contribution of dual-window spectral information representation and phase information of frequency domain representation to HSI-CD task.

Key words: hyperspectral image, change detection, image fusion, feature extraction, saliency analysis, fourier transform

Supported by National Natural Science Foundation of China (No. 42222106, 61976234, T2225019)