

基于自适应非局部模式一致性的多模态遥感影像变化检测方法

韩特¹, 汤玉奇^{1,2}, 陈玉增¹, 张芳艳³, 杨欣¹, 邹滨^{1,2}, 冯微微^{1,2}

1. 中南大学 地球科学与信息物理学院, 长沙 410083;

2. 中南大学 有色金属矿产预测与地质环境监测教育部重点实验室, 长沙 410083;

3. 宁夏大学 前沿交叉学院, 中卫 755000

摘要: 亚热带地区环境复杂, 自然灾害频发。多模态遥感影像变化检测可在监测其环境变化与灾害现象中发挥重要作用, 已成为当下遥感影像处理的研究热点。针对现有方法存在的目标空间结构特征和影像变化信息利用不足的问题, 本文假设地物变化将导致对应影像区域的空间结构特征变化, 提出了一种基于自适应非局部模式一致性 ANLPC (Adaptive Non-local Pattern Consistency) 的多模态遥感影像变化检测方法。该方法通过度量多模态影像的空间结构变化提取影像变化信息。首先利用块相似性构建多模态影像的自适应非局部模式, 实现空间结构特征表达; 然后通过前/后向模式映射度量其与另一时相影像的空间结构差异; 最后融合前/后向变化强度图的频率域信息获取鲁棒的变化强度图, 并通过阈值分割得到二值变化检测图。本文采用4组多模态遥感影像数据集(两组光学—SAR (Synthetic Aperture Radar) 数据集, 两组光学—LiDAR 数据集)和两组单模态遥感影像数据集(一组光学影像数据集, 一组 SAR 影像数据集)验证了本文方法的有效性。相对于现有方法, 本文方法在6组数据集中的卡帕系数 KC 平均至少提升 17.28%。

关键词: 遥感, 多模态影像, 变化检测, 结构特征, 自适应非局部模式, 模式映射, 影像融合

中图分类号: P237/P2

引用格式: 韩特, 汤玉奇, 陈玉增, 张芳艳, 杨欣, 邹滨, 冯微微. 2024. 基于自适应非局部模式一致性的多模态遥感影像变化检测方法. 遥感学报, 28(12): 3197-3212

Han T, Tang Y Q, Chen Y Z, Zhang F Y, Yang X, Zou B and Feng H H. 2024. Change detection method based on adaptive nonlocal pattern consistency for multimodal remote sensing images. National Remote Sensing Bulletin, 28 (12): 3197-3212 [DOI: 10.11834/jrs.20233072]

1 引言

遥感影像变化检测是利用不同时相覆盖同一地区的遥感影像检测并分析地表变化的方法, 广泛应用于森林资源监测、防灾减灾工程和城市规划等领域 (Tang 和 Zhang, 2017; 眭海刚 等, 2018; Zhang 等, 2020; Zhu 等, 2024)。根据所用的遥感数据的不同, 变化检测可以分为单模态和多模态遥感影像变化检测。前者所用的遥感数据通常来自同一类型的卫星传感器 (如都是光学卫星), 后者则利用不同类型的卫星传感器的遥感数

据 (比如哨兵一号卫星和哨兵二号卫星)。利用单模态遥感卫星进行变化检测的方法由于受到卫星性能和自然环境的影响, 常面临数据质量差和数据缺失等问题。随着遥感卫星种类日益丰硕 (多光谱、高光谱和 SAR 卫星等), 协同多模态遥感影像变化检测可充分利用多模态卫星的信息获取优势 (如光学卫星可获取丰富的地物光谱和纹理信息, SAR 卫星可以全天时、全天候成像), 解决单模态影像变化检测的数据依赖问题, 已成为当下监测环境复杂的亚热带等区域地表变化的重要技术手段 (吴立新 等, 2022)。然而, 由于多模态卫

收稿日期: 2023-03-24; 预印本: 2023-08-15

基金项目: 国家自然科学基金 (编号: 41971313, 42271411); 湖南省研究生科研创新项目 (编号: CX20220169)

第一作者简介: 韩特, 研究方向为多模态/单模态遥感影像变化检测。E-mail: tchanrs@csu.edu.cn

通信作者简介: 汤玉奇, 研究方向为土地覆盖/利用目标识别、分类与变化分析, 多源遥感影像信息融合, 自然资源监测。E-mail: yqtang@csu.edu.cn

星的成像机制不同,多模态遥感影像的成像特征存在较大差异,无法通过直接对比提取变化信息,因此单模态影像变化检测方法无法适用于检测多模态遥感影像间的变化,亟需发展多模态影像变化检测新方法。

根据变化检测方法原理的不同,现有多模态遥感影像变化检测方法主要分为3类:影像空间转换法、特征空间映射法和相似性度量法。

影像空间转换法利用多模态影像间的像元统计关系,将其转换到对方的影像空间,通过对比转换后的影像和原始影像的差异提取变化信息。为利用多模态影像未变化像元之间的统计关系,Liu等(2018)利用先验知识选择未变化像元作为样本,并构建多模态影像的同质像元转换HPT(Homogeneous Pixel Transformation)模型以提取变化信息。为减少算法对先验知识的依赖,Luppino等(2019)通过亲和矩阵差异AMD(Affinity Matrices Difference)构建多模态像元的映射关系。Gong等(2016)和Sun等(2021b)分别利用迭代耦合字典学习ICDL(Iterative Coupled Dictionary Learning)和块相似性图矩阵PSGM(Patch Similarity Graph Matrix)进行多模态影像空间转换。一些学者也利用深度学习方法实现多模态影像的空间转换,如条件对抗网络CAN(Conditional Adversarial Network)(Niu等,2019),共同自编码器CA(Commonality Autoencoder)(Wu等,2022),深度稀疏残差模型DSRM(Deep Sparse Residual Model)(Touati等,2020a),分层极限学习机HELM(Hierarchical Extreme Learning Machine)(韩特等,2022)。这些方法需要构建训练或伪训练样本,以建立影像空间映射关系。在实际应用中,这些方法需要执行繁琐的步骤,因此效率不高。

特征空间映射法的目的是将多模态影像映射到近似的特征空间进行比较。在该特征空间中,多模态影像的相同地物具有近似的灰度特征,可直接对比提取变化信息。一些学者对多模态影像进行分类使其在同一类别特征空间,通过对比多模态影像的类别标签得到变化区域(Han等,2021;Wan等,2019a,2019b)。但是这些方法受制于多模态影像的分类精度,尤其SAR影像受到相干斑噪声的影响,对其进行精确分类比较困难。因此,为了将多模态影像映射到更高维和鲁棒的特征空间进行比较,Li等(2021)构建深度转换

变化检测网络DTCDN(Deep Translation Based Change Detection Network)将多模态影像映射到同一特征空间中,然后利用监督变化检测网络区分变化和未变化区域。Zhao等(2017)和Zhan等(2018b)分别提出了近似对称深度神经网络ASDNN(Approximately Symmetrical Deep Neural Network)和迭代特征映射网络IFMN(Iterative Feature Mapping Network)将多模态影像映射到近似的特征空间。为进一步优化多模态影像特征空间的相似性,Yang等(2022)构建了深度金字塔特征学习网络DPFL-Net(Deep Pyramid Feature Learning Network)以提高该特征空间的准确性。Zhan等(2018a)利用对数变换特征学习方法LTFL(Logarithmic Transformation Feature Learning)实现多模态影像近似特征空间映射。然而,这些方法容易受到影像分类精度和影像噪声的影响,尤其是SAR影像严重的噪声干扰,容易产生错检。

相似性度量法通过计算构造的多模态影像的可比特征提取变化信息,不依赖于训练样本或伪标签引导特征空间转换和映射。这类方法主要分为:(1)灰度特征相似性模型,如多维统计模型MSM(Multivariate Statistical Model)(Prendes等,2015)、多模态变化检测马尔可夫模型M3CD(Markov Model for Multi-modal Change Detection)(Touati等,2020b)和能量模型EBM(Energy-Based Model)(Touati和Mignotte,2018)。(2)结构特征相似性模型:排序直方图SH(Sorted Histogram)(Wan等,2018),图融合方法GBF(Graph-Based Fusion)(Jimenez-Sierra等,2020)、非局部块相似性矩阵NPSG(Nonlocal Patch Similarity based Graph)(Sun等,2021a)、结构图影像回归SGIR(Structured Graph Based Image Regression)(Sun等,2022)和稀疏约束的影像回归SCIR(Sparse-Constrained based Image Regression)(Sun等,2022)等。这些方法在多模态影像变化检测中取得了较好的结果,但还存在以下问题:(1)仅考虑固定尺度的结构特征,忽略了地物目标的尺度信息,且只依赖影像光谱特征构建结构图,未充分利用影像的空间信息,因此其结构图未能准确表达影像的结构特征;(2)未充分利用多模态影像的前/后向变化信息,导致部分像元的变化强度度量错误。

针对以上基于相似性度量的多模态影像变化检测的问题,本文假设多模态遥感影像未变化区

域具有相同的结构特征, 地表变化将导致对应影像区域的结构特征变化, 提出了一种基于自适应非局部模式一致性的多模态遥感影像变化检测方法 ANLPC (Adaptive Non-local Pattern Consistency), 为面向亚热带等区域的地表变化监测提供技术支持。该方法以目标块的行列空间为搜索空间, 顾及地物的尺度信息构建影像的自适应非局部模式。不同于传统的局部邻域特征, 该模式通过构建影像非局部空间结构关系, 表达了多模态影像空间结构特征; 进而通过自适应非局部模式映射实现多时相影像模式的交叉映射; 最后通过曲波变换 CT (Curvelet Transform) (Starck 等, 2002) 融合各向变化强度图的高/低频信息增强变化信息表达, 并通过阈值分割得到二值变化检测结果。本文方法的主要贡献是: (1) 提出了一种基于自适应非局部模式一致性 (ANLPC) 的多模态影像变化检测方法。该方法通过构建影像自适应非局部模式, 表征多模态影像的结构特征。该特征描述不受成像机制影响的影像空间上下文关系, 并通过模式映射获取多时相影像特征变化, 有效实现了不同成像机制下的多模态影像特征差异比较。(2) 提出了多模态影像非局部模式的自适应构建方法。该方法以目标块的行列邻域空间作为同质块搜索区域, 在顾及影像空间信息的同时保证了搜索效

率; 同时考虑地物目标的多尺度特征, 实现了目标块的自适应非局部模式构建, 提高了变化检测精度。(3) 利用 CT 变换进行前向/后向差异信息融合, 充分利用了各时相影像变化特征, 进一步增强了变化区域的显著性。本文方法在 4 组多模态遥感影像数据集上取得了最好的精度, 同时也用两组单模态数据集证明了其在单模态影像变化检测中的适用性。

2 本文方法

假设影像 $X = \{X(i, j, b_x) | 1 \leq i \leq H, 1 \leq j \leq W, 1 \leq b_x \leq B_x\}$ 和 $Y = \{Y(i, j, b_y) | 1 \leq i \leq H, 1 \leq j \leq W, 1 \leq b_y \leq B_y\}$ 是一对配准后的多模态遥感影像, 其覆盖同一地理区域且获取自不同时刻。其中, H 和 W 分别为影像 X 和 Y 的长和宽, B_x 和 B_y 分别为 X 和 Y 的波段数。为了准确表达影像的结构特征以度量多模态影像的变化信息, ANLPC 联合影像光谱和空间上下文信息, 考虑不同地物的尺度差异, 构建自适应非局部模式提取多模态影像的多尺度结构特征; 并通过度量该非局部模式在前/后时相中的差异提取多模态影像变化信息; 进而利用 CT 变换融合前/后向变化信息获取变化强度图。本文方法流程图如图 1 所示。




图 1 ANLPC 流程图

Fig. 1 Flow chart of the proposed ANLPC

2.1 自适应非局部模式构建

2.1.1 非局部模式

由于独立的像元作为基本处理单元容易受到影像噪声的影响, 因此本文将影像划分为重叠的

正方形的块, 并以块作为影像基本处理单元。给定影像 X 的一个块 $px_{(i,j)} = \{X(\delta_i^-: \delta_i^+, \delta_j^-: \delta_j^+, 1: C_x)\}$ 作为目标块, 式中 $\delta_i^- = i - p_s$, $\delta_i^+ = i + p_s$, $\delta_j^- = j - p_s$, $\delta_j^+ = j + p_s$, 其大小为 $(2p_s + 1)^2 \times C_x$, $p_s \in \mathbb{N}^*$,

(i, j) 是其中中心像元的坐标, C_x 表示影像 X 的波段数。为保证影像块中的地物类型的纯净性, 目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 的大小不宜过大, 本文在第 3.5 节中讨论了目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 的尺寸参数 p_s 的设置。

为了准确表达影像的结构特征, 目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 的非局部模式定义为

$$\mathbf{M}\mathbf{X}_{(i,j)} = \left\{ \mathbf{p}\mathbf{x}_{(i,j)}^{(k)} \mid (m, n) \in \Omega_{(m,n)}, k = 1, 2, \dots, K \right\} \quad (1)$$

式中, $\mathbf{p}\mathbf{x}_{(m,n)}^{(k)}$ 表示目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 的第 k 个同质块, 其与目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 具有高相似性, K 为同质块 $\mathbf{p}\mathbf{x}_{(m,n)}$ 的总数, $\Omega_{(m,n)}$ 表示所有同质块 $\mathbf{p}\mathbf{x}_{(m,n)}$ 的索引集合。为了在缩小同质块 $\mathbf{p}\mathbf{x}_{(m,n)}$ 搜索空间的同时顾及其空间分布信息, 本文定义同质块 $\mathbf{p}\mathbf{x}_{(m,n)}$ 的搜索空间为目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 的行列邻域:

$$\phi_{x_{(i,j)}} = X(\text{row} + \delta_{i,:}, :); X(:, \text{col} + \delta_{:,j}) \quad (2)$$

式中, $\text{row} \in \Omega_{\text{row}}$ 且 $\text{row} \neq i$, $\text{col} \in \Omega_{\text{col}}$ 且 $\text{col} \neq j$ 。 $\Omega_{\text{row}} = \{1, 2, \dots, H\}$, $\Omega_{\text{col}} = \{1, 2, \dots, W\}$ 。同理, 通过前向模式映射可以得到 $\mathbf{M}\mathbf{X}_{(i,j)}$ 在影像 Y 中的行列邻域模式:

$$\mathbf{M}\mathbf{Y}_{(i,j)}^{\text{map}} = \left\{ \mathbf{p}\mathbf{y}_{(i,j)}^{(k)}, \mathbf{p}\mathbf{y}_{(m,n)}^{(k)} \mid (m, n) \in \Omega_{(m,n)}, k = 1, 2, \dots, K \right\} \quad (3)$$

目标块的非局部模式反映了其多尺度结构特征, 可根据其在模式映射前后的差异提取影像变化信息。模式映射即保持一时相影像的非局部模式的空间位置不变, 得到该非局部模式在另一时相影像中的结构特征表达。图 2 展示了目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 的非局部模式映射的示意图, 其中红色和黄色的方形框分别表示目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 和 $\mathbf{p}\mathbf{y}_{(i,j)}$, 红色和黄色的圆形框分别表示目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 和 $\mathbf{p}\mathbf{y}_{(i,j)}$ 的同质块 $\mathbf{p}\mathbf{x}_{(m,n)}^{(k)}$ 和 $\mathbf{p}\mathbf{y}_{(m,n)}^{(k)}$, 白色矩形框表示目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 和 $\mathbf{p}\mathbf{y}_{(i,j)}$ 的行列邻域 (搜索空间)。在图 2 (a) 中, 目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 未发生变化, 通过其在影像 Y 中的非局部模式 $\mathbf{M}\mathbf{Y}_{(i,j)}^{\text{map}}$ 可以看出, 所有同质块 $\mathbf{p}\mathbf{y}_{(m,n)}$ 都与目标块 $\mathbf{p}\mathbf{y}_{(i,j)}$ 具有高相似性, 这说明行非局部模式 $\mathbf{M}\mathbf{X}_{(i,j)}$ 在模式映射后未发生变化, 即表明目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 未发生变化。在图 2 (b) 中, 目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 发生变化, 通过非局部模式 $\mathbf{M}\mathbf{Y}_{(i,j)}^{\text{map}}$ 可以看出, 同质块

$\mathbf{p}\mathbf{y}_{(m,n)}^{(1)}$ 、 $\mathbf{p}\mathbf{y}_{(m,n)}^{(2)}$ 、 $\mathbf{p}\mathbf{y}_{(m,n)}^{(4)}$ 、 $\mathbf{p}\mathbf{y}_{(m,n)}^{(5)}$ 和 $\mathbf{p}\mathbf{y}_{(m,n)}^{(6)}$ 与目标块 $\mathbf{p}\mathbf{y}_{(i,j)}$ 的相似性低, 这表明非局部模式 $\mathbf{M}\mathbf{X}_{(i,j)}$ 发生了变化, 即表明目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 发生了变化。

2.1.2 同质块选取

在非局部模式构建中, 如何选取目标块的同质块是关键步骤。本文提出了一种基于聚类分析的自适应同质块选择策略。该策略以行列邻域作为搜索空间, 主要分为两步:

(1) 计算行列邻域中的块 $\mathbf{p}\tilde{\mathbf{x}} = \{\mathbf{p}\tilde{\mathbf{x}}_{n^k} \mid \mathbf{p}\tilde{\mathbf{x}}_{n^k} \in \phi_{x_{(i,j)}}, n^k = 1, 2, \dots, N_x^k\}$ 与目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 的相似性, 式中, N_x^k 是搜索空间内的块总数。为了抑制多模态影像噪声的影响, 对于光学和 LiDAR 影像本文利用影像块 $\mathbf{p}\tilde{\mathbf{x}}$ 和目标 $\mathbf{p}\mathbf{x}_{(i,j)}$ 之间的平方欧氏距离度量相似性, 对于 SAR 影像则利用平方对数欧氏距离度量其相似性。距离越大则表示其相似性越低。相似性计算公式如下:

$$\text{dist}_{\text{Gau}}(\mathbf{p}\tilde{\mathbf{x}}, \mathbf{p}\mathbf{x}_{(i,j)}) = \frac{\sum_{t=1}^{(2p_s+1)^2 C_x} (\mathbf{p}\tilde{\mathbf{x}}(t) - \mathbf{p}\mathbf{x}_{(i,j)}(t))^2}{(2p_s+1)^2 C_x} \quad (4)$$

$$\text{dist}_{\text{Gam}}(\mathbf{p}\tilde{\mathbf{x}}, \mathbf{p}\mathbf{x}_{(i,j)}) = \frac{\sum_{t=1}^{(2p_s+1)^2 C_x} (\log \mathbf{p}\tilde{\mathbf{x}}(t) - \log \mathbf{p}\mathbf{x}_{(i,j)}(t))^2}{(2p_s+1)^2 C_x} \quad (5)$$

式中, $t = 1, 2, \dots, (2p_s+1)^2 C_x$ 。

(2) 自适应选取同质块。通过步骤 (1) 计算, 可以得到块 $\mathbf{p}\tilde{\mathbf{x}}$ 与目标块 $\mathbf{p}\mathbf{x}_{(i,j)}$ 的相似性向量 $\mathbf{S}\mathbf{X}_{(i,j)} = \{s_{x_{n^k}} \mid n^k = 1, 2, \dots, N_x^k\}$ 。本文将搜索空间内与目标块具有高相似性的块选取为同质块, 而合适的同质块选取数量是构建准确的自适应非局部模式的关键。对于大尺度地物对象, 如果搜索空间内与目标块具有高相似性的块数量较多, 为充分利用目标块的结构信息, 则应该选取的同质块数量也应较多; 反之, 则应该选取数量较少的同质块, 以避免引入多余低相似性块而导致目标块的结构信息不准确。本文利用 K-means++ 聚类方法 (Arthur 和 Vassilvitskii, 2007) 将相似性向量 $\mathbf{S}\mathbf{X}_{(i,j)}$ 划分为 3 个组, 并选择其中相似性值之和最高的一组块作为同质块。




图2 非局部模式映射示意图

Fig. 2 Diagram of non-local pattern mapping

2.2 模式映射与变化度量

目标块 $\mathbf{px}_{(i,j)}$ 的非局部模式 $\mathbf{MX}_{(i,j)}$ 表征了其结构信息。以前向映射为例, 本文将影像 X 的非局部模式 $\mathbf{MX}_{(i,j)}$ 映射到影像 Y 中, 则该非局部模式 $\mathbf{MY}_{(i,j)}^{\text{map}}$ 在影像 X 和 Y 中的变化程度即反映了该目标块的变化强度, 计算公式如下:

$$\text{dif}_{(i,j)}^X = \frac{1}{K} \sum_{k=1}^K \left(\text{dist} \left(\mathbf{py}_{(m,n)}^{(k)}, \mathbf{py}_{(i,j)} \right) \right) \quad (6)$$

式中, K 为同质块数量。如果 $\mathbf{px}_{(i,j)}$ 未发生变化,

$$\text{dif}_{(i,j)}^X = \frac{1}{K} \left| \sum_{k=1}^K \left(\text{dist} \left(\mathbf{py}_{(m,n)}^{(k)}, \mathbf{py}_{(i,j)} \right) \right) - \sum_{k=1}^K \left(\text{dist} \left(\mathbf{px}_{(m,n)}^{(k)}, \mathbf{px}_{(i,j)} \right) \right) \right| \quad (7)$$

式中, $|\cdot|$ 表示取绝对值运算。

通过上述计算, 可以得到所有中心块 $\mathbf{px}_{(i,j)}$ 的变化程度。本文定义所有覆盖影像 X 的像元 (i_c, j_c) ($1 \leq i_c \leq H$, $1 \leq j_c \leq W$) 的块的集合为 $\Omega_{(i,j)}^X$, 则前向变化强度图由下式计算:

$$\mathbf{DI}_{(i,j)}^{\text{fw}} = \frac{1}{|\Omega_{(i,j)}^X|} \sum_{\text{dif}_{(i,j)}^X \in \Omega_{(i,j)}^X} \text{dif}_{(i,j)}^X \quad (8)$$

则模式映射后 $\mathbf{MY}_{(i,j)}^{\text{map}}$ 中的大部分同质块 $\mathbf{py}_{(m,n)}$ 与目标块 $\mathbf{py}_{(i,j)}$ 具有高相似性, $\text{dif}_{(i,j)}^X$ 值较小; 反之, 如果 $\mathbf{px}_{(i,j)}$ 发生变化, 则大多数同质块 $\mathbf{py}_{(m,n)}$ 与目标块 $\mathbf{py}_{(i,j)}$ 的相似性较低, $\text{dif}_{(i,j)}^X$ 较大。

为了更准确地度量目标块 $\mathbf{px}_{(i,j)}$ 的变化程度, 本文移除非局部邻域模式 $\mathbf{MX}_{(i,j)}$ 构建产生的距离 $\text{dist}(\mathbf{px}_{(m,n)}^{(k)}, \mathbf{px}_{(i,j)})$, 将式 (6) 改写为

同理, 通过后向映射可得到后向变化强度图 $\mathbf{DI}^{\text{bw}}$ 。

2.3 变化强度图分析

由于前向变化强度图 $\mathbf{DI}^{\text{fw}}$ 和后向变化强度图 $\mathbf{DI}^{\text{bw}}$ 分别表示获取自影像 Y 域和 X 域的变化信息, 其变化程度可能不同。同时, 模式映射及其变化度量将引入部分误差, 导致变化错检和漏检。因

此, 为了充分考虑多时相影像域的变化信息, 保留主体变化区域的同时减少错检和漏检像元, 本文引入CT变换对前、后向变化强度图进行融合处理。

CT变换是一种多尺度几何分析方法, 在处理影像等离散数据时将其转换至频率域。其将原始信号分解成多个不同尺度的子带, 在每个尺度下, CT变换将信号进一步分解成不同方向的子带, 因此具有良好的纹理表示能力和方向特征。其离散Curvelet系数定义为

$$C_{j,\theta,k} = \sum_{\substack{1 \leq s \leq H \\ 1 \leq t \leq W}} f(s,t) \cdot \varphi_{j,\theta,k}(s,t) \quad (9)$$

式中, $f(s,t)$ 表示输入图像, j 表示尺度, θ 为方向, $k = (k_1, k_2)$ 为 Curvelet 的空间位置, $\varphi_{j,\theta,k}$ 是 Curvelet 基函数。

本文通过对变化强度图 DI^{fw} 和 DI^{bw} 进行 Curvelet 变换得到其对应的离散 Curvelet 系数 $C_{j,\theta,k}^{fw}$ 和 $C_{j,\theta,k}^{bw}$ 。一方面, 由于低频系数 (尺度 $j=1$) 反映了图像整体的信息, 因此, 为保留变化强度图 DI^{fw} 和 DI^{bw} 的整体信息, 本文对于低频分量采用平均融合策略:

$$C_{j,\theta,k}^{fusion} = (C_{j,\theta,k}^{fw} + C_{j,\theta,k}^{bw})/2 \quad (10)$$

另一方面, 高频系数 (尺度 $j \geq 2$) 反映了图像的边缘、纹理等细节信息。在变化强度图中, 变化区域可视为前景, 未变化区域视为背景。而信息融合的目的是增强变化信息的同时抑制未变化区域信息。因此对于高频分量, 本文采用加权融合策略, 以通过增强图像的细节信息抑制背景信息。

$$C_{j,\theta,k}^{fusion} = W^{fw} \times C_{j,\theta,k}^{fw} + W^{bw} \times C_{j,\theta,k}^{bw} \quad (11)$$

$$W^{fw} = \frac{\exp(|C_{j,\theta,k}^{fw}|)}{\exp(|C_{j,\theta,k}^{fw}|) + \exp(|C_{j,\theta,k}^{bw}|)} \quad (12)$$

$$W^{bw} = \frac{\exp(|C_{j,\theta,k}^{bw}|)}{\exp(|C_{j,\theta,k}^{fw}|) + \exp(|C_{j,\theta,k}^{bw}|)} \quad (13)$$

式中, $|\cdot|$ 表示取模运算。融合后的变化强度图可以通过曲波逆变换得到。


融合后的变化强度图反映了地物变化的概率分布。为了进一步确定变化和未变化区域, 变化检测图的生成可看作是对融合后的变化强度图进行二值分割的过程。模糊局部信息C均值聚类算法 FLICM (fuzzy local information C-Means) (Krinidis 和 Chatzis, 2010) 是一种经典的无监督聚类方法, 其利用目标像元和邻域像元的隶属度关系实现影像聚类, 能够保持类别边缘信息并具有较好的抗噪声能力。因此, 本文采用 FLICM 方法对变化强度图进行二值分割得到变化检测图。

3 实验与分析

3.1 实验数据

为验证本文方法在多模态影像变化检测中的有效性及单模态影像变化检测中的适用性, 本文利用4组多模态遥感数据 (光学—SAR 影像数据集 #1—#2, 光学 LiDAR 影像数据集 #3—#4), 2组单模态影像 (光学影像数据集 #5 和 SAR 影像数据集 #6) 进行验证。

6组数据集包含多种传感器影像, 时间跨度较广, 分布于不同区域 (数据集 #1、#2、#5 和 #6 为亚热带区域), 包含不同尺度的变化场景 (如城市建设, 河流扩张等) (图3)。本文数据集的变化参考图是通过利用专家知识以及参考其时间空间邻近的高分辨率影像进行目视解译得到。这6组数据集能充分证明算法的鲁棒性和有效性, 其详细信息如表1所示。






图3 影像数据集

Fig. 3 Image datasets

表1 实验数据集

Table 1 Experimental datasets

数据集	卫星	尺寸(像元)	获取日期	地理位置	事件(分辨率/m)
#1	Google Earth/哨兵一号	600×600×3(1)	1999-12—2017-11	中国,重庆	河流扩张(10)
#2	哨兵二号/哨兵一号	444×571×3(1)	2017-04—2020-10	中国,鄱阳湖	湖泊变化(10)
#3	QuickBird/LiDAR	700×700×4(1)	2007-11—2011-06	美国,旧金山	城市建设(0.5)
#4	QuickBird/LiDAR	700×700×4(1)	2007-11—2011-06	美国,旧金山	城市建设(0.5)
#5	QuickBird	1154×740×4	2009—2014	中国,武汉	地区建设(2.4)
#6	哨兵一号	700×516×1	2017-11—2018-05	中国,重庆	河流扩张(10)

3.2 精度评定指标

为了定量评价本文方法的有效性,本文采用总体误差 OE (Overall Errors)、整体精度 OA (Overall Accuracy) 和卡帕系数 KC (Kappa Coefficient) 作为精度评定指标,其计算公式如下:

$$OE = FP + FN \quad (14)$$

$$OA = (TP + TN) / (TP + TN + FP + FN) \quad (15)$$

$$KC = (OA - PRE) / (1 - PRE) \quad (16)$$

$$PRE = \frac{(TP + FN)(TP + FP) + (TN + FP)(TN + FN)}{(TP + TN + FP + FN)^2} \quad (17)$$

式中, TN 表示正确检测出的变化像元的数量(正检变化), TP 表示正确检测出的未变化像元的数量(正检未变化), FN 表示将变化像元错误检测为未变化像元的数量(漏检), FP 表示将未变化像元错误检测为变化像元的数量(错检)。

3.3 实验设置

为验证本文方法在多模态和单模态影像变化检测中的有效性,本文选择以下6种变化检测方法进行对比分析:

(1) rrR-EM (Zanetti 等, 2018): 瑞利组合最大期望法 rrR-EM 通过最大期望法和贝叶斯融合法描述差异影像的统计分布信息提取变化信息。

(2) LTFL (Zhan 等, 2018a): 对数变换特征学习法 LTFL 利用深度学习提取多模态影像高维特征,进而通过高维特征差异训练的变化分类器确定变化区域。

(3) CAN (Niu 等, 2019): 条件对抗网络法 CAN 基于生成对抗网络将多时相影像转换到对方的特征空间,从而直接对比转换影像得到变化信息。

(4) GBF (Jimenez-Sierra 等, 2020): 基于图

数据融合 GBF 的方法通过融合多时相影像图信息，提取图最小相似性以表征变化信息。

(5) NPSG (Sun 等, 2021a): 非局部块相似性图 NPSG 通过比较多模态影像的非局部相似性图度量多时相影像的变化程度。

(6) SGIR (Sun 等, 2022): 基于结构图回归的方法 SGIR 利用超像素结构图映射计算多时相回归影像，进而通过对比回归影像和原始影像得到变化区域。

(7) SCIR (Sun 等, 2022): 使用稀疏约束的影像回归 SCIR 构建结构一致图像的回归模型，利用变化强度图的先验知识突出显示变化区域。

同时，为了探究不同的邻域搜索空间对于本文方法的影响，本文分别将邻域搜索空间设置为行邻域、列邻域和八邻域坐标空间，对应的方法分别命名为 ANLPC-row、ANLPC-col 和 ANLPC-8。

本文方法使用 MATLAB 代码实现，运行平台为：AMD Ryzen 7 3800X 8-Core CPU (3.89 Hz)，64 GB RAM，Windows 10 (64 bit) 和 MATLAB 2020a。

3.4 实验结果

3.4.1 多模态数据集实验结果

(1) 光学—SAR 数据集实验结果。图 4 和图 5 分别展示了数据集#1 和#2 的实验结果，两个数据集都包含光学和 SAR 影像，反映了河流的变化。其难点在于多时相影像成像角度差异导致的阴影分布差异，且部分变化区域面积较小。在数据集#1 和#2 中，rrR-EM 检测到了变化的主体区域，但其在陆地部分存在较多“椒盐噪声”；LTFL 和 CAN 通过深度神经网络将多模态影像映射到近似特征空间进行对比，一定程度上减少了多模态影像特征差异，但依然受阴影影响，错检和漏检较多；GBF 通过图学习有效抑制了陆地区域的变化错检，但也产生了较多漏检；NPSG、SGIR 和 SCIR 利用影像结构信息检测变化，但 NPSG 采用固定尺度的结构信息难以准确构建目标多尺度结构特征，产生了一些错检，SGIR 和 SCIR 检测出主体变化区域，但漏检了河岸的细小部分变化。




图4 不同方法在数据集#1上的结果

Fig. 4 Results of the datasets #1 generated by different methods

为了定量评价不同方法的变化检测结果，表 2 展示了不同方法在数据集#1 和#2 上的检测精度。从表 2 中可以看出，ANLPC 在数据集#1 和#2 中都取得了最高的 KC 值，分别达到 0.7246 和 0.7950。

本文提出的 ANLPC 以行列邻域作为构建结构

模式的搜索空间，在减少邻域搜索范围的同时顾及影像空间分布信息，通过自适应构建不同尺度的行列邻域模式，融合前/后向变化信息，在抵抗影像阴影干扰的同时，能够准确检测出不同大小的地物变化。ANLPC-row 和 ANLPC-col 分别以行

和列邻域作为搜索空间，但由于仅利用到单列邻域信息导致产生一些错检。ANLPC-8采用八邻域作为搜索空间，取得了和ANLPC最为接近的效果，

但同时由于搜索空间过大，容易引入冗余信息造成一些错检。




图5 不同方法在数据集#2上的结果

Fig. 5 Results of the datasets #2 generated by different methods

表2 不同方法在多模态数据集的变化检测精度评定结果

Table 2 Quantitative performance evaluation of different methods on Multi-modal datasets

方法	数据集#1			数据集#2			数据集#3			数据集#4		
	OE	OA	KC	OE	OA	KC	OE	OA	KC	OE	OA	KC
rrR-EM	54803	0.8477	0.5713	48781	0.8075	0.3630	97071	0.8018	0.3737	41588	0.9151	0.4673
LTFL	28646	0.9204	0.7119	41355	0.8368	0.2951	37010	0.9244	0.5737	34858	0.9288	0.4650
CAN	31338	0.9129	0.5551	31753	0.8747	0.0016	187392	0.6175	0.0052	106494	0.7826	0.0707
GBF	36379	0.8989	0.5530	28926	0.8859	0.2019	79909	0.8369	0.0806	55125	0.8875	0.1570
NPSG	44433	0.8765	0.4942	29597	0.8832	0.4433	73876	0.8492	0.3398	73636	0.8497	0.3249
SGIR	44360	0.8767	0.3281	16292	0.9357	0.3575	33725	0.9311	0.4970	47031	0.9040	0.1521
SCIR	37620	0.8955	0.5069	11738	0.9537	0.6443	41258	0.9148	0.3929	25803	0.9473	0.4511
ANLPC-row	34480	0.9042	0.6301	9078	0.9641	0.7638	41198	0.9159	0.5331	31975	0.9347	0.5423
ANLPC-col	24312	0.9324	0.7093	10119	0.9600	0.7436	33492	0.9316	0.5634	27672	0.9435	0.5628
ANLPC-8	25141	0.9301	0.7052	10853	0.9571	0.7482	36870	0.9247	0.5731	22438	0.9542	0.5915
ANLPC	24930	0.9307	0.7246	8225	0.9675	0.7950	32077	0.9345	0.6349	19123	0.9609	0.6416

注:黑体表示所有方法在相同数据集和指标下的最高精度。OE为总体误差,OA为整体精度,KC为卡帕系数。

(2) 光学—LiDAR数据集实验结果图6和图7分别展示了不同方法在数据集#3和#4上的检测结果。该数据集地物类型复杂，且多时相影像光谱特征存在较大差异。从图6和图7可以看出，rrR-EM检测到较为完整的变化区域，但其以像元为处

理单元难以准确度量多模态影像的差异，因此造成很多错检；由于该数据集场景复杂，CAN难以将多模态影像映射到相同的特征空间，导致检测结果存在大量漏检和错检；相对于CAN，GBF和NPSG错检较少，但都存在很多漏检；LTFL较好地

将多模态影像映射到相同特征空间，检测出了主体变化区域；SGIR 的错检很少，但没有检测出数据集#3中影像底部的两个变化的建筑物。SCIR 虽

然错检很少，但是漏检很多。然而，得益于结构特征的提取和差异度量，ANLPC-row、ANLPC-col、ANLPC-8和ANLPC都检测出了变化主体区域。




图6 不同方法在数据集#3上的结果

Fig. 6 Results of the datasets #3 generated by different methods




图7 不同方法在数据集#4上的结果

Fig. 7 Results of the datasets #4 generated by different methods

从表2的精度评定结果可以看出，在数据集#3中，除了LTFL的KC值高于0.57，其余对比方法均未超过0.45。ANLPC-row、ANLPC-col、ANLPC-8和ANLPC的KC值均高于0.53，且ANLPC在所有方法中取得最高的KC值。在数据集#4中，本文方

法的KC值均达到0.54以上，其中ANLPC的KC值为0.6416，比方法提高了37.29%。说明本文方法ANLPC通过构建自适应非局部模式，度量多模态影像的空间结构差异，能够有效的突出变化区域。

3.4.2 单模态数据集实验结果

图8和图9分别展示了不同方法在数据集#5和#6上的检测结果。数据集#5场景较复杂, 包含建筑物、植被、农田和道路等地物, 数据集#6的难点在于其影像噪声严重。其中, rrR-EM、GBF和NPSG只检测出数据集#5中的部分变化区域, 存在大面积的错检区域; 相对于前3种方法, SGIR的错检更少, 但未检测出数据集#5右部分道路的变化。在数据集#6中, rrR-EM和GBF被影像噪声干

扰, 产生了很多错检; NPSG基于结构特征检测到了大部分变化区域, 但受限于尺度单一, 因此存在一些显著的错检; SGIR利用结构特征建立多时相影像的映射关系, 具有抑制影像噪声的能力, 但检测细小变化的能力不足, 产生很多漏检。SCIR的错检很少, 检测出了主体变化区域, 但是存在一些漏检。本文方法通过度量两时相影像的非局部模式的变化, 都较为完整的检测出变化区域。




图8 不同方法在数据集#5上的结果

Fig. 8 Results of the datasets #5 generated by different methods




图9 不同方法在数据集#6上的结果

Fig. 9 Results of the datasets #6 generated by different methods

表3展示了数据集#5和#6的精度评定结果。本文方法ANLPC在数据集#5和#6的KC值分别为

0.5546和0.7134, 比对比方法分别至少提高了14.09%和16.47%。得益于自适应构建影像的非局

部模式, 本文方法的错检和漏检都很少。其中 ANLPC-row 和 ANLPC-col 比 ANLPC 的错检更多, ANLPC-8 与 ANLPC 效果非常接近, 说明采用行列邻域作为搜索空间在缩小搜索范围的同时能够保证检测精度。

表3 不同方法在单模态数据集的变化检测精度评定结果
Table 3 Quantitative performance evaluation of different methods on single-modal datasets

方法	数据集#5			数据集#6		
	OE	OA	KC	OE	OA	KC
rrR-EM	206998	0.7576	0.3250	22339	0.9381	0.5892
GBF	191484	0.7757	0.2034	78528	0.7826	0.3789
NPSG	212526	0.7511	0.2998	22759	0.9369	0.6125
SGIR	99011	0.8840	0.3083	23359	0.9353	0.2858
SCIR	73111	0.9144	0.4861	17590	0.9513	0.5881
ANLPC-row	75352	0.9117	0.5537	16257	0.9549	0.6632
ANLPC-col	85570	0.8997	0.4942	14331	0.9603	0.6836
ANLPC-8	98437	0.8847	0.5054	14242	0.9605	0.6879
ANLPC	75720	0.9113	0.5546	13577	0.9624	0.7134

注: 黑体表示所有方法在相同数据集和指标下的最高精度。OE 为总体误差, OA 为整体精度, KC 为卡帕系数。

3.5 讨论

3.5.1 实验参数分析

块尺寸参数 p_s 和差异图融合尺度 j 是本文方法

主要参数。本文在固定参数 j 为 5 的基础上, 将参数 p_s 设置为 1—3 (步长为 1), 并固定参数 p_s 为 1 的同时将参数 j 设置为 2—8 (步长为 1), 以分别分析参数 p_s 和 j 对本文方法的影响。

(1) 参数 p_s 分析。图 10 (a) 展示了当 $j=5$ 时, p_s 变化对本文方法变化检测精度的影响。对于数据集#1、#2 和#4, 其变化检测精度随着 p_s 的增加逐渐降低, 在 p_s 设置为 1 时精度最高; 而在数据集#3、#5 和#6 上的检测精度则随着 p_s 的增加先增加后减小。这是因为数据集#1、#2 和#4 的变化区域较小, 选用影像块尺寸太大会导致检测结果缺乏细节信息; 而数据集#3、#5 和#6 的变化区域较大, 影像块太小则不能构建鲁棒的非局部模式, 对抵抗影像噪声影响的能力不足, 但影像块的尺寸太大又会导致引入冗余像元, 难以检测到细节变化信息。因此本文在数据集#1、#2 和#4 中将 p_s 设置为 1, 在数据集#3、#5 和#6 中将 p_s 设为 2。

(2) 参数 j 。参数 j 对算法结果的影响如图 10 (b) 所示。可以看出, 参数 j 对于算法精度的影响不明显, 各数据集在 j 设置为 4 或 5 时精度最高。 j 设置过小容易导致差异图中的显著变化信息提取不足, 而 j 过大则会导致差异图中引入较多噪声。因此本文建议将参数 j 设置为 4 或 5。




图10 参数 p_s 和 j 对算法结果的影响

Fig. 10 Effect of parameters p_s and j on the results of change detection

3.5.2 不同距离度量方法对算法的影响

为了探究不同距离度量方法对于本文方法的影响, 本文采用杰卡德距离 (Jaccard Distance)、切比雪夫距离 (Chebyshev Distance)、曼哈顿距离 (Manhattan Distance) 作为对比方法。给定影像块 $p\tilde{x}$ 和目标块 $p\mathbf{x}_{(i,j)}$, 这 3 种距离度量方法分别定义如下:

$$\text{dist}_{\text{Jaccard}}(p\tilde{x}, p\mathbf{x}_{(i,j)}) = 1 - \frac{(p\tilde{x} \cap p\mathbf{x}_{(i,j)})}{(p\tilde{x} \cup p\mathbf{x}_{(i,j)})} \quad (18)$$

$$\text{dist}_{\text{Chebyshev}}(p\tilde{x}, p\mathbf{x}_{(i,j)}) = \max \left(\left| p\tilde{x}(t) - p\mathbf{x}_{(i,j)}(t) \right| \right) \quad (19)$$

式中, $t = 1, 2, \dots, (2p_s + 1)^2 C_x$ 。

$$\text{dist}_{\text{Manhattan}}(p\tilde{x}, p\mathbf{x}_{(i,j)}) = \frac{\sum_{t=1}^{(2p_s+1)^2 C_x} |p\tilde{x}(t) - p\mathbf{x}_{(i,j)}(t)|}{(2p_s + 1)^2 C_x} \quad (20)$$

本文方法利用不同距离度量方法在 6 组数据集上的检测精度如表 4 所示, 杰卡德距离在所有数据集中的检测精度都是最低的。除了数据集#3 和#4, 曼哈顿距离的在其余数据集中的精度优于切比雪夫距离, 而本文的距离度量方法取得了最高的精度。这主要是由于本文所用的距离度量方法采用平方欧氏距离能够扩大不同影像块 $p\tilde{x}$ 和目标块 $p\mathbf{x}_{(i,j)}$ 之间的相似性差异, 从而可以使得变化信息更加显著。

表 4 不同距离度量方法对算法的影响

Table 4 The influence of different distance measurement methods on the proposed method

距离方法	数据集#1	数据集#2	数据集#3	数据集#4	数据集#5	数据集#6
	KC	KC	KC	KC	KC	KC
杰卡德距离	0.1703	0.3843	0.3513	0.0311	0.2273	0.1471
切比雪夫距离	0.6431	0.7034	0.5521	0.5235	0.4476	0.5470
曼哈顿距离	0.6504	0.7820	0.5409	0.3409	0.5204	0.6874
本文距离	0.7246	0.7950	0.6349	0.6416	0.5546	0.7134

注: 黑体表示所有方法在相同数据集和指标下的最高精度。KC 为卡帕系数。

4 结 论

针对现有多模态影像方法空间结构特征表达不足和变化信息利用不充分的问题, 本文提出了一种基于自适应非局部模式一致性 (ANLPC) 的多模态遥感影像变化检测方法。本文方法自适应构建的影像非局部模式构建地物空间结构尺度特征, 实现了不同成像机制下的多模态影像的特征一致性表达。相比传统方法中的空间局部邻域, 本文方法以目标块的行列邻域作为搜索区域, 能够突破局部邻域的限制, 实现更远距离的搜索。一般情况下, 在图幅较大的多时相遥感影像中, 当两时相影像获取时间相近或变化主要为人工构筑物和水体变化等时, 变化区域的面积通常远远小于未变化区域。因此, 即使选择的同质块位于变化区域, 其数量也远少于未变化区域的同质块, 从而不会对影像结构特征的构建造成显著影响。本文方法通过多时相非局部模式交叉映射, 在同一影像域度量影像变化, 并融合变化信息中的低频和高频信息获取变化强度图及变化检测图, 避

免了变化信息损失。

亚热带地区环境复杂, 多云多雨, 且自然灾害频发。由于受到卫星时间、辐射、空间分辨率等的限制, 单模态影像变化检测的数据依赖问题突出。而多模态影像变化检测则具有以下优势: (1) 突破单一卫星影像分辨率的限制, 能够综合多模态影像提高影像的时间分辨率; (2) 能够在短时间内获取灾区影像, 缩短灾害响应时间; (3) 能够结合多种卫星的优势, 为全天时全天候监测提供技术支撑。

本文方法通过对比多模态影像地物空间结构尺度特征提取地表变化信息。在实验验证中, 数据集#1、#2 和#6 反映了亚热带地区流域变化, 数据集#5 展示了亚热带地区构筑物建设导致的地表变化。本文方法在这些数据集上的 KC 值分别达到 0.7146、0.7950、0.7134 和 0.5546, 分别对比方法至少提高了 1.78%、23.39%、16.47% 和 14.09%。这说明本文方法在多/单模态影像变化检测中的有效性, 能够在亚热带区域的自然灾害监测、城市规划和环境监测等领域发挥重要作用。

本文中使用的数据集类型需要进一步扩充,以提高算法在更多多模态影像变化检测中的有效性。本文所提出的方法包括结构图构建、变化度量和变化强度图分析等步骤,但未能实现多模态影像的端到端检测。在6个数据集上,本研究展示了最佳性能,但在场景复杂的变化区域(例如数据集#5)的精度仍有进一步提升的空间。未来的研究将聚焦于扩充数据集并探索多模态影像的端到端变化检测算法,研究影像块参数自适应学习等,以进一步提高算法在复杂场景中的检测能力。同时,我们还将研究多模态影像的自动配准算法,以更好地服务于亚热带等区域的地表变化监测。

参考文献(References)

- Arthur D and Vassilvitskii S. 2007. k-means++: the advantages of careful seeding//Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms. New Orleans: Society for Industrial and Applied Mathematics: 1027-1035
- Gong M G, Zhang P Z, Su L Z and Liu J. 2016. Coupled dictionary learning for change detection from multisource data. *IEEE Transactions on Geoscience and Remote Sensing*, 54(12): 7077-7091 [DOI: 10.1109/TGRS.2016.2594952]
- Han T, Tang Y Q, Yang X, Lin Z F, Zou B and Feng H H. 2021. Change detection for heterogeneous remote sensing images with improved training of hierarchical extreme learning machine (HELM). *Remote Sensing*, 13(23): 4918 [DOI: 10.3390/rs13234918]
- Han T, Tang Y Q, Zou B, Feng H H and Zhang F Y. 2022. Heterogeneous images change detection method based on hierarchical extreme learning machine image transformation. *Journal of Geo-information Science*, 24(11): 2212-2224 (韩特, 汤玉奇, 邹滨, 冯徽徽, 张芳艳. 2022. 基于分层极限学习机影像转换的多源影像变化检测方法. *地球信息科学学报*, 24(11): 2212-2224) [DOI: 10.12082/dqxxkx.2022.220089]
- Jimenez-Sierra D A, Benítez-Restrepo H D, Vargas-Cardona H D and Chanussot J. 2020. Graph-based data fusion applied to: change detection and biomass estimation in rice crops. *Remote Sensing*, 12(17): 2683 [DOI: 10.3390/rs12172683]
- Krinidis S and Chatzis V. 2010. A robust fuzzy local information c-means clustering algorithm. *IEEE Transactions on Image Processing*, 19(5): 1328-1337 [DOI: 10.1109/TIP.2010.2040763]
- Li X H, Du Z S, Huang Y Y and Tan Z Y. 2021. A deep translation (GAN) based change detection network for optical and SAR remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 179: 14-34 [DOI: 10.1016/j.isprsjprs.2021.07.007]
- Liu Z G, Li G, Mercier G, He Y and Pan Q. 2018. Change detection in heterogenous remote sensing images via homogeneous pixel transformation. *IEEE Transactions on Image Processing*, 27(4): 1822-1834 [DOI: 10.1109/TIP.2017.2784560]
- Luppino L T, Bianchi F M, Moser G and Anfinsen S N. 2019. Unsupervised image regression for heterogeneous change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 57(12): 9960-9975 [DOI: 10.1109/TGRS.2019.2930348]
- Niu X D, Gong M G, Zhan T and Yang Y L. 2019. A conditional adversarial network for change detection in heterogeneous images. *IEEE Geoscience and Remote Sensing Letters*, 16(1): 45-49 [DOI: 10.1109/LGRS.2018.2868704]
- Prendes J, Chabert M, Pascal F, Giros A and Tourneret J Y. 2015. A new multivariate statistical model for change detection in images acquired by homogeneous and heterogeneous sensors. *IEEE Transactions on Image Processing*, 24(3): 799-812 [DOI: 10.1109/TIP.2014.2387013]
- Starck J L, Candes E J and Donoho D L. 2002. The curvelet transform for image denoising. *IEEE Transactions on Image Processing*, 11(6): 670-684 [DOI: 10.1109/TIP.2002.1014998]
- Sui H G, Feng W Q, Li W Z, Sun K M and Xu C. 2018. Review of change detection methods for multi-temporal remote sensing imagery. *Geomatics and Information Science of Wuhan University*, 43(12): 1885-1898 (眭海刚, 冯文卿, 李文卓, 孙开敏, 徐川. 2018. 多时相遥感影像变化检测方法综述. *武汉大学学报(信息科学版)*, 43(12): 1885-1898) [DOI: 10.13203/j.whugis20180251]
- Sun Y L, Lei L, Li X, Sun H and Kuang G Y. 2021a. Nonlocal patch similarity based heterogeneous remote sensing change detection. *Pattern Recognition*, 109: 107598 [DOI: 10.1016/j.patcog.2020.107598]
- Sun Y L, Lei L, Li X, Tan X and Kuang G Y. 2021b. Patch similarity graph matrix-based unsupervised remote sensing change detection with homogeneous and heterogeneous sensors. *IEEE Transactions on Geoscience and Remote Sensing*, 59(6): 4841-4861 [DOI: 10.1109/TGRS.2020.3013673]
- Sun Y L, Lei L, Tan X, Guan D D, Wu J Z and Kuang G Y. 2022. Structured graph based image regression for unsupervised multimodal change detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, 185: 16-31 [DOI: 10.1016/j.isprsjprs.2022.01.004]
- Tang Y Q and Zhang L P. 2017. Urban change analysis with multi-sensor multispectral imagery. *Remote Sensing*, 9(3): 252 [DOI: 10.3390/rs9030252]
- Touati R and Mignotte M. 2018. An energy-based model encoding nonlocal pairwise pixel interactions for multisensor change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 56(2): 1046-1058 [DOI: 10.1109/TGRS.2017.2758359]
- Touati R, Mignotte M and Dahmane M. 2020a. Anomaly feature learning for unsupervised change detection in heterogeneous images: a deep sparse residual model. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 588-600 [DOI: 10.1109/JSTARS.2020.2964409]
- Touati R, Mignotte M and Dahmane M. 2020b. Multimodal change detection in remote sensing images using an unsupervised pixel pairwise-based Markov random field model. *IEEE Transactions on Image Processing*, 29: 757-767 [DOI: 10.1109/TIP.2019.2933747]
- Wan L, Xiang Y M and You H J. 2019a. A post-classification compari-

- son method for SAR and optical images change detection. IEEE Geoscience and Remote Sensing Letters, 16(7): 1026-1030 [DOI: 10.1109/LGRS.2019.2892432]
- Wan L, Xiang Y M and You H J. 2019b. An object-based hierarchical compound classification method for change detection in heterogeneous optical and SAR Images. IEEE Transactions on Geoscience and Remote Sensing, 57(12): 9941-9959 [DOI: 10.1109/TGRS.2019.2930322]
- Wan L, Zhang T and You H J. 2018. Multi-sensor remote sensing image change detection based on sorted histograms. International Journal of Remote Sensing, 39(11): 3753-3775 [DOI: 10.1080/01431161.2018.1448481]
- Wu L X, Sun G Y, Miao Z L, Zhang A Z, Feng H H, Hu J, Yang Z F, Wang W, Chen B Y and Tang Y Q. 2022. On subtropical remote sensing in China: research status, key tasks and innovative development approaches. National Remote Sensing Bulletin, 26(8): 1483-1503 (吴立新, 孙根云, 苗则朗, 张爱竹, 冯微微, 胡俊, 杨泽发, 王威, 陈必焰, 汤玉奇. 2022. 浅论中国亚热带遥感现状、任务与创新途径. 遥感学报, 26(8): 1483-1503) [DOI: 10.11834/jrs.20222173]
- Wu Y, Li J H, Yuan Y Z, Qin A K, Miao Q G and Gong M G. 2022. Commonality autoencoder: learning common features for change detection from heterogeneous images. IEEE Transactions on Neural Networks and Learning Systems, 33(9): 4257-4270 [DOI: 10.1109/TNNLS.2021.3056238]
- Yang M J, Jiao L C, Liu F, Hou B, Yang S Y and Jian M. 2022. DPFL-Nets: deep pyramid feature learning networks for multiscale change detection. IEEE Transactions on Neural Networks and Learning Systems, 33(11): 6402-6416 [DOI: 10.1109/TNNLS.2021.3079627]
- Zhan T, Gong M G, Jiang X M and Li S W. 2018a. Log-based transformation feature learning for change detection in heterogeneous images. IEEE Geoscience and Remote Sensing Letters, 15(9): 1352-1356 [DOI: 10.1109/LGRS.2018.2843385]
- Zhan T, Gong M G, Liu J and Zhang P Z. 2018b. Iterative feature mapping network for detecting multiple changes in multi-source remote sensing images. ISPRS Journal of Photogrammetry and Remote Sensing, 146: 38-51 [DOI: 10.1016/j.isprsjprs.2018.09.002]
- Zhang M and Shi W Z. 2020. A feature difference convolutional neural network-based change detection method. IEEE Transactions on Geoscience and Remote Sensing, 58(10): 7232-7246 [DOI: 10.1109/TGRS.2020.2981051]
- Zhao W, Wang Z R, Gong M G and Liu J. 2017. Discriminative feature learning for unsupervised change detection in heterogeneous images based on a coupled neural network. IEEE Transactions on Geoscience and Remote Sensing, 55(12): 7066-7080 [DOI: 10.1109/TGRS.2017.2739800]
- Zhu Q Q, Guo X, Li Z Q and Li D R. 2024. A review of multi-class change detection for satellite remote sensing imagery. Geo-spatial Information Science, 27(1): 1-15 [DOI: 10.1080/10095020.2022.2128902]
- Zanetti M and Bruzzone L. 2018. A Theoretical Framework for Change Detection Based on a Compound Multiclass Statistical Model of the Difference Image. IEEE Transactions on Geoscience and Remote Sensing, 56(2): 1129-1143 [DOI: 10.1109/TGRS.2017.2759663]

Change detection method based on adaptive nonlocal pattern consistency for multimodal remote sensing images

HAN Te¹, TANG Yuqi^{1,2}, CHEN Yuzeng¹, ZHANG Fangyan³, YANG Xin¹,
ZOU Bin^{1,2}, FENG Huihui^{1,2}

1. School of Geosciences and Info-physics, Central South University, Changsha 410083, China;

2. Key Laboratory of Metallogenic Prediction of Nonferrous Metals and Geological Environment Monitoring (Central South University), Ministry of Education, Changsha 410083, China;

3. School of Advanced Interdisciplinary Studies, Ningxia University, Zhongwei 755000, China

Abstract: Multimodal remote sensing image change detection is an active research area in the field of remote sensing image processing and plays a crucial role in disaster monitoring, urban planning, natural resource monitoring, and other domains. To address the problem of insufficient utilization of target spatial structure features and image change information in existing methods, this study proposes that the spatial structure features of unchanged regions in multimodal images are consistent, whereas the spatial structure features of changed regions differ. Therefore, change information can be extracted by measuring the difference in the spatial structure of multimodal images. This study proposes a change detection method based on Adaptive Nonlocal Pattern Consistency (ANLPC) for multimodal remote sensing images.

In this study, the basic processing unit for the images is made up of patches that overlap with one another. The target patch is defined as the construction pattern's reference patch, and the other patches are viewed as homogeneous. The nonlocal mode of the image is constructed adaptively via the homogeneous patch automated selection approach and by using the rank coordinate space of the target patch as the search space to consider the spatial information of the image and narrow the search area. Cross mapping of two temporal image patterns (forward and backward mapping) is achieved by adaptive nonlocal pattern mapping to precisely assess the variation between multimodal images.

With forward mapping as an example, ANLPC maps the nonlocal pattern of the first temporal image into the second temporal image domain, and the difference information of the pattern in the second temporal image domain represents the change information of the multimodal image. Similarly, backward change information is acquired from backward mapping. The final difference map is produced by combining the forward and backward difference information via curvelet transform, and the binary change detection results are produced using threshold segmentation.

Four multimodal remote sensing image datasets (two optical Synthetic Aperture Radar [SAR] datasets and two optical LiDAR datasets) and two single-modal remote sensing image datasets (one optical image dataset and one SAR image dataset) are used to verify the effectiveness of the proposed method. The average improvement of the kappa coefficient of the proposed method in the six datasets is 17.28% compared with the kappa coefficients of existing methods.

To address the problem of insufficient utilization of target spatial structure features and image change information in existing methods, this study uses an adaptive nonlocal pattern to characterize the structural information of the image. The changed regions are measured in the same image domain by cross mapping the nonlocal pattern to circumvent the imaging differences of multimodal images. Meanwhile, difference image fusion and threshold segmentation are employed to obtain a robust change map. The proposed method has higher accuracy than the compared methods on single-modal and multimodal datasets, a result that demonstrates the proposed method's effectiveness and robustness.

Key words: remote sensing, multimodal images, change detection, structural features, adaptive non-local patterns, pattern mapping, image fusion

Supported by National Natural Science Foundation of China (No. 41971313, 42271411); Scientific Research Innovation Project for Graduate Students in Hunan Province (No. CX20220169)