

文章编号 1004-924X(2026)08-1283-15

融合对象级 KPCA-DSFA 的高分辨率 遥感影像无监督变化检测

官金杞^{1,2*}, 王宗晨¹, 王 铁¹, 周俊亦¹

(1. 南京工业大学 测绘科学与技术学院, 江苏 南京 211816;

2. 中国测绘科学研究院, 北京 100036)

摘要: 为了克服地表覆盖监测不全、判不准等难题, 兼顾完整性与实用性, 探索了一种融合对象级 KPCA-DSFA 的高分辨率遥感影像无监督变化检测方法。首先, 对两期影像进行相对辐射校正和影像融合, 采用简单非迭代聚类算法实现联合分割, 获取兼顾两期影像特征的匀质超像素块; 其次, 将 KPCA 卷积映射网络和 DSFA 耦合, 分别进行空间-光谱特征提取和深度语义分析, 并以超像素为基本单元, 融合构建对象级高维空间向量, 获取变化强度信息; 最后, 基于图割 Graph Cut 模型构建能量函数模型, 利用对象邻接关系和空间差异, 通过全局优化实现变化区域精准提取。实验结果表明: 检测的总体精度可达 90% 以上, 综合性能较高, 能够有效抑制椒盐噪声, 显著提升变化区域的查全率, 具有一定的优越性和鲁棒性。

关键词: 核主成分分析; 变化检测; 超像素; 深度特征提取; 图割模型

中图分类号: TP394.1; TH691.9 文献标识码: A

doi: 10.37188/OPE.20263408.1283 CSTR: 32169.14.OPE.20263408.1283

Unsupervised change detection from high-resolution remote sensing images with object-level KPCA-DSFA fusion

GONG Jinqi^{1,2*}, WANG Zongchen¹, WANG Tie¹, ZHOU Junyi¹

(1. School of Geomatics Science and Technology, Nanjing Tech University, Nanjing 211816, China;

2. Chinese Academy of Surveying and Mapping, Beijing 100036, China)

* Corresponding author, E-mail: jinqigong@njtech.edu.cn

Abstract: In order to address the challenges of incomplete identification and inaccurate judgment in land cover monitoring, while balancing integrity and practicality, a novel change detection method based on co-refinement of object-level fusion and graph cut with KPCA-DSFA was proposed, which used two registered high-resolution remote sensing images. Firstly, relative radiometric correction and band stacking fusion were performed on the two-phase images. A simple non-iterative clustering algorithm was adopted for joint segmentation to generate homogeneous blocks that preserved the feature consistency of both image phases. Then the kernel PCA convolutional mapping network and deep slow feature analysis were coupled

收稿日期: 2026-02-06; 修订日期: 2026-03-17.

基金项目: 湖北珞珈实验室开放基金资助项目 (No. 230100023); 江苏省研究生科研与实践创新计划项目 (No. SJCX25_0620)

together for spatial-spectral feature extraction and deep semantic parsing respectively. Taking super pixels as the basic processing units, object-level high-dimensional spatial vectors were constructed via feature fusion to obtain change confidence information. Finally, an energy function model was established based on the Graph Cut, which leveraged the adjacency relationships and spatial differences of super pixel objects to achieve precise extraction of change regions through global optimization. Experimental results demonstrate that the proposed method achieves an overall accuracy of over 90% with excellent comprehensive performance. It can effectively suppress "salt-and-pepper" noise, significantly improve the recall rate of change regions, and exhibit favorable superiority and robustness.

Key words: kernel convolution mapping; change detection; super pixels; deep feature analysis; graph cut model

1 引言

随着我国进入高质量发展阶段,“双碳”目标、国土空间规划“一张图”管理、自然资源精细化治理等国家战略的深入推进,对地表覆盖变化的精准、快速、全面监测提出了前所未有的高要求^[1-4]。高分辨率遥感技术的飞速发展,为变化检测提供了丰富的数据基础,蕴含的地物类型更丰富、空间结构更复杂,为精准识别小面积变化、狭长地物变化提供了可能^[5-6]。但在高分辨率影像中,单个地物往往由大量像素组成,基于像元的方法无法有效利用地物的形状、纹理、结构等空间特征,难以区分真实变化与辐射差异、阴影等伪变化,远不能满足自然资源精细化管理的需求^[7-8]。面向对象的变化检测能够有效抑制椒盐噪声,提升检测结果的空间连续性,其中分割参数的选择往往需要人工经验调整,不同地物类型对分割参数的适应性差异较大,普适性的最优参数组合较难获得^[9-11]。

近年来,随着人工智能技术的迅猛发展,机器学习方法凭借强大的特征学习与模式识别能力,成为变化检测领域的研究热点,推动检测精度实现了跨越式提升^[12-16]。然而,深度学习方法对标注样本高度依赖,需要专业人员结合实地调查完成,标注成本极高,在缺乏标注样本的场景中,模型泛化能力大幅下降^[17-20]。超像素作为面向对象方法的核心单元,通过聚类算法将具有相似特征的像素聚合为紧凑、匀质的像斑,既保留了地物的空间结构信息,又有效降低了数据维度,为后续特征提取和变化检测提供了高效的处理单元^[21-22]。卷积神经网络模型与深度

语义分析,为精准检测提供高质量的特征支撑,并适配非监督学习场景的无标注特性^[23-24]。图模型算法则通过构建能量函数模型,将变化检测转化为图的最小割问题,能够实现全局最优分割,保证变化区域的完整性和空间连续性。考虑到核主成分分析凭借非线性映射能力可有效提取遥感影像的空间-光谱特征,但对深层语义信息挖掘不足。深度慢特征分析能通过挖掘“慢特征”,强化地物本质语义表征,抑制光照、大气等冗余干扰,而在纹理复杂地物中易出现特征区分度不足的问题。由于单一模型在语义空间等方面的局限性,往往无法充分挖掘高分辨率遥感影像的多维特征信息。因此,本文融合超像素的面向对象优势、深度特征分析的信息增强能力与图割模型全局优化特性,探索了基于对象级KPCA-DSFA的无监督变化检测方法。实验证明本文方法应用于自然资源监测、违章用地普查等领域,显著抑制了椒盐噪声,在保证检测准确率的同时,有效提升了变化区域的查全率与综合检测性能,具有适应能力强、快速有效和鲁棒性高等特点。

2 对象级 KPCA-DSFA 无监督变化检测原理

2.1 融合对象级 KPCA-DSFA 变化检测流程

图 1 为融合对象级 KPCA-DSFA 的高分辨率遥感影像变化检测流程图。它主要由影像联合分割、变化强度信息获取以及图割协同变化检测等组成。影像联合分割通过相对辐射校正、影像联合和超像素分割构成。变化强度信息获取

包括KPCA空间-光谱特征提取、DSFA深度特征分析与对象相似性度量。图割协同变化检测分为图模型构建、Graph Cut优化以及检测结果获取。

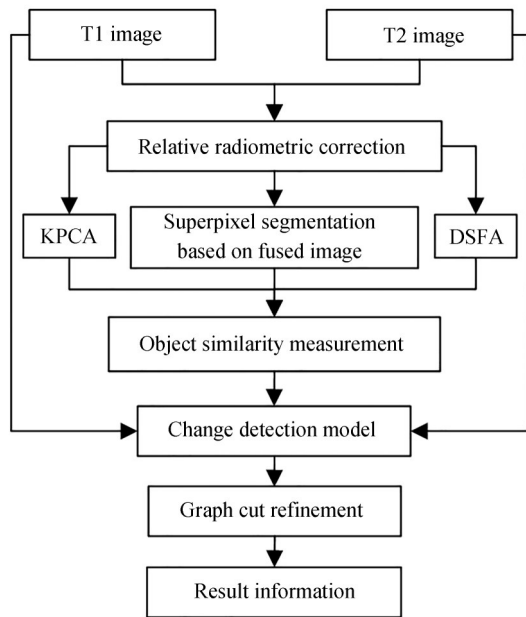


图1 超像素KPCA-DSFA变化检测流程

Fig.1 Flow chart of change detection with super pixels fusing KPCA-DSFA

2.2 对象级KPCA-DSFA变化检测原理

该方法的基本原理为:首先,通过快速傅里叶变换(Fast Fourier Transform, FFT)使影像间辐射特性保持一致,对两期图像进行联合处理,融合特征保留地物细节,采用简单非迭代聚类算法(Simple Non-Iterative Clustering, SNIC)生成匀质超像素块,为后续特征提取与差异计算提供统一的空间单元;然后,基于KPCA卷积映射网络提取空间-光谱特征,利用DSFA完成深度语义分析,并将其进行耦合,以超像素为基本单元构建对象级高维空间向量,通过余弦相似性度量获取变化强度信息;最后,基于对象变化强度、邻接关系和空间差异构建图模型,将变化检测转化为图的最小割问题,利用Graph Cut能量函数,通过全局优化实现变化区域精准提取,保证变化区域的完整性和空间连续性,进而完成变化检测结果获取。

3 对象级KPCA-DSFA变化检测算法

3.1 影像联合分割

3.1.1 相对辐射校正

相对辐射校正是遥感影像预处理的核心环节之一,其核心目标是消除同一区域不同时相、不同传感器或不同成像条件下影像的系统性辐射偏差,使影像间辐射特性保持一致,为后续分析任务奠定基础。FFT作为频域分析的核心工具,凭借其对信号的高效分解与重构能力,在相对辐射校正中展现出独特的技术优势。由此,对参考影像(辐射基准影像)和待校正影像分别执行二维FFT,将空域中的灰度信号转换为频域信号,得到频域复数矩阵;并通过频域平移将频域原点移至矩阵中心,以便后续频率分量的分离与处理。采用高斯低通滤波器对平移后的频域信号进行滤波处理,保留低频分量,滤除高频细节分量。同时,以参考影像的低频分量为基准,计算待校正影像低频分量与参考影像低频分量的比值,得到辐射校正系数矩阵;再将该系数矩阵作用于待校正影像的全频域信号,实现待校正影像辐射趋势与参考影像的对齐。对校正后的频域信号执行逆平移和逆FFT,将频域信号转回空域,得到辐射校正后的影像。通过频域信号分解与重构实现了系统性辐射偏差的精准消除与地物细节的完整保留,具有校正精度高、运算效率优、场景适应性强等优势。

3.1.2 联合影像超像素

影像联合的核心是保留两期影像的关键信息,为后续分割提供统一基础。主要是将前后两期遥感影像的各光谱波段(如RGB)分别拆离,计算对应波段像素灰度最大值,并重新叠加所有波段的最大值,形成融合两期影像特征的联合影像,既保留了两期影像的地物细节,又减少了辐射差异的影响。

传统超像素分割方法多依赖迭代优化机制,存在运算效率偏低、边界贴合度不足等问题,难以适配高分辨率遥感影像大规模、精细化处理的需求。SNIC作为一种高效非迭代超像素分割算法,凭借“网格初始化-局部范围匹配-非迭代分配”的核心设计,在分割精度、运算速度与边界保留能力上实现了良好平衡,成为遥感影像分析领

域的优选分割方案。考虑到 RGB 颜色空间的相关性较强,不利于颜色相似度的精准度量,将输入影像转换至 Lab 颜色空间,构建空间坐标和多波段颜色的多维特征向量,提升分割的区分度。同时,为避免全局搜索导致的效率低下,为每个初始中心限定局部搜索范围,仅对该范围内的像素进行距离计算与分配。对每个局部搜索范围内的像素,计算其与所有相邻初始中心的联合距离,将像素分配给距离最小的聚类中心。所有像素分配完成后,无需进行中心迭代更新,直接以每个聚类中心对应的像素集群作为最终超像素。分割过程中,以联合影像为基准,设置超像素尺寸、紧凑度等参数,生成匀质超像素块;根据超像素的空间位置,分别对原始前后两期影像进行分割,确保两期影像的超像素块一一对应,为后续特征提取与差异计算提供统一的空间单元。

3.2 变化强度信息获取

3.2.1 空间-光谱特征提取

传统非监督方法多依赖浅层特征或线性特征映射,难以适配高分辨率影像中复杂的非线性特征分布,导致分类精度与鲁棒性不足。KPCA 卷积映射网络作为一种融合核主成分分析与深度学习的新型非监督网络,将核主成分分析与卷积操作相结合,构建 KPCA 卷积层实现非线性特征的挖掘,通过特征提取与非线性映射的有机结合,突破了传统线性特征映射的局限性,显著提升了检测性能,整体架构如图 2 所示。

首先,通过核函数将输入数据映射至高维特

征空间,使原本线性不可分的特征转化为线性可分状态;然后,在高维空间中执行主成分分析,提取具有代表性的主成分特征;最后,基于卷积滑动窗口操作,将高维主成分特征转化为空间相关性强的特征图,同时保留数据的空间结构信息与细节特征。相较于传统卷积层,KPCA 卷积层无需通过反向传播优化权重,仅依赖数据自身特征完成卷积核的构建,适配非监督学习场景的无标注特性。给定输入影像 I^{t_1} 和 I^{t_2} ,通过两个孪生子网络 S_1 和 S_2 ,分别提取对应超像素 p 的空间-光谱特征 $f_{p,ss}^{t_1}$ 和 $f_{p,ss}^{t_2}$:

$$S_1(I^{t_1}) = \text{KCL}_1^L(\text{KCL}_1^{L-1} \cdots \text{KCL}_1^1(I^{t_1})), \quad (1)$$

$$S_2(I^{t_2}) = \text{KCL}_2^L(\text{KCL}_2^{L-1} \cdots \text{KCL}_2^1(I^{t_2})), \quad (2)$$

$$f_{p,ss}^{t_1} = \frac{1}{N_p} \sum_{i=1}^{N_p} S_1(I^{t_1})_{p,i}, \quad (3)$$

$$f_{p,ss}^{t_2} = \frac{1}{N_p} \sum_{i=1}^{N_p} S_2(I^{t_2})_{p,i}, \quad (4)$$

其中: L 为网络层数, KCL^j 表示第 j 个权重共享的 KPCA 卷积层, N_p 为超像素 p 中像素的数目, $S_1(I^{t_1})_{p,i}$ 和 $S_2(I^{t_2})_{p,i}$ 分别为两个子网络输出属于超像素 p 内的第 i 个特征。

KPCA 卷积映射网络具有空间-光谱非线性特征的强捕捉能力,可有效提取地物的表现特征,适配高分辨率遥感影像中地物光谱复杂、空间结构多样的特征分布特点。尽管它增强了处理非线性数据的能力,但对于影像中蕴含的更深层次语义信息提取能力受限,仍需结合其他模型或上下文分析。

3.2.2 深度语义分析

深度慢特征分析(Deep Slow Feature Analysis, DSFA)作为特征分析与深度学习的融合拓展方法,通过深度网络架构挖掘时序数据中变化缓慢的核心特征,在抑制冗余信息、强化本质特征判别性方面展现出独特优势,可与 KPCA 等非监督分类模型耦合,为遥感影像时序分析与精准检测提供高效的特征支撑。在多时态遥感影像等时序相关数据集中,冗余信息(如光照波动、大气干扰、传感器噪声)通常呈现快速变化特性,而地物本身的本质特征(如光谱属性、空间结构)则呈现相对稳定的“慢变化”特性。如图 3 所示,网络通过深度特征提取通道,将输入的时序数据映射至深度特征空间;随后引入慢特征损失函数,




图 2 核主成分分析映射网络空间-光谱特征提取示意图
Fig. 2 Framework of the kernel principal component analysis mapping network for spatial-spectral feature extraction




图3 深度语义分析示意图

Fig. 3 Framework of deep slow feature analysis

约束时序相邻数据的特征输出变化量最小化,即使得提取的特征在时序维度上呈现慢变化特性。该过程中,网络会自动抑制光照波动、噪声等快速变化的冗余信息,同时强化地物本质属性等慢变化特征的特征,实现本质特征与冗余干扰的有效分离;且无需人工标注样本参与,即可从时序数据中自动学习具有稳定性与判别性的深度特征,完全适配非监督学习场景。假设原始影像数据 I^{t_1} 和 I^{t_2} , 输入深度网络得到变换特征 X 和 Y , 根据加权协方差矩阵求解广义特征值和特征向量得到投影矩阵 w , 则对应超像素 p 的深度语义特征 $f_{p,ms}^{t_1}$ 和 $f_{p,ms}^{t_2}$ 为:

$$f_{p,ms}^{t_1} = \frac{1}{N_p} \sum_{i=1}^{N_p} w_{p,i} x_{p,i}, \quad (5)$$

$$f_{p,ms}^{t_2} = \frac{1}{N_p} \sum_{i=1}^{N_p} w_{p,i} y_{p,i}, \quad (6)$$

其中: $x_{p,i}$, $y_{p,i}$ 和 $w_{p,i}$ 分别表示 X , Y 和 w 中超像素 p 内第 i 个特征和对应权重。

DSFA对深度语义特征的挖掘能力更强,通过慢特征损失函数约束,可自动抑制冗余干扰,强化地物本质语义表征,无需人工标注样本即可学习具有稳定性与判别性的深度语义特征。然而,其在高分辨率遥感影像中地物的空间光谱精细特征捕捉能力较弱,易丢失细粒度变化的特征信息,难以精准区分同谱异物的地物变化与伪变化。

因此,基于KPCA-DSFA两类特征的互补融合,实现表观特征保细节、语义特征定本质的双重效果,突破单一方法的局限性,以便在特征鲁棒性与区分度上均表现出显著优势。

3.2.3 对象相似性度量

通过特征提取分别得到两期影像各超像素

的空间-光谱特征向量与深度语义特征向量。余弦相似度能够通过计算两个向量之间的余弦大小来判断相似性,不受两向量长度的影响,仅仅与向量间夹角相关:

$$\cos(\theta) = \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n (A_i)^2} \sqrt{\sum_{i=1}^n (B_i)^2}}, \quad (7)$$

其中: A 和 B 分别为两个特征向量, A_i , B_i 为向量分量, n 为特征维度,取值范围为 $[-1, 1]$ 。值越接近 1,表明两期特征越相似(地物未变化);值越接近 -1 ,表明特征差异越大(地物发生变化)。因此,分别对空间-光谱特征和深度语义特征采用余弦角相似性度量方法衡量对象间的距离差异,则有:

$$D_p^{ss} = \frac{2}{1 + e^{-4\theta_p}} - 1, \quad (8)$$

$$\theta_p = \arccos \frac{f_{p,ss}^{t_1} \cdot f_{p,ss}^{t_2}}{\|f_{p,ss}^{t_1}\| \|f_{p,ss}^{t_2}\|}, \quad (9)$$

其中: D_p^{ss} 即为空间-光谱特征距离,同理,由 $f_{p,ms}^{t_1}$ 和 $f_{p,ms}^{t_2}$ 得到深度语义差异 D_p^{ms} ,进而将其组合获取变化强度信息 CC_p :

$$CC_p = D_p^{ss} \cdot D_p^{ms} + (1 - D_p^{ss}) D_p^{ms}, \quad (10)$$

其中: CC_p 归一化到 $[0, 1]$: 变化强度值越接近 1,地物变化概率越高,对象间相似度越低;越接近 0,地物未变化概率越高,对象间相似度越高。

3.3 图割协同变化检测

3.3.1 模型构建

在图割协同变化检测中主要是采用 Graph Cut 算法构建能量函数模型,通过最小化能量函数实现变化区域与未变化区域的分割,将任务转化为图的最小割问题,图中节点代表超像素,边代表超像素间的关联关系,经由能量函数定义分割代价如下:

$$E(L) = \lambda E_{\text{data}}(L) + (1 - \lambda) E_{\text{smooth}}(L), \quad (11)$$

其中: $E_{\text{data}}(L)$ 描述数据项, $E_{\text{smooth}}(L)$ 为平滑项, L 表示分割结果, λ 是调节因子,用于平衡数据项与平滑项的权重。

3.3.2 图割优化

数据项 $E_{\text{data}}(L)$ 描述超像素被判定为前景或背景的代价,基于变化强度信息定义如下:

$$E_{\text{data}}(L) = \sum_{p \in P} D_p(l_p), \quad (12)$$

其中: $D_p(l_p)$ 描述超像素 p 分配 l_p 的代价,对于任意一个超像素 $p \in P, l_p \in \{\text{"obj"}, \text{"bkg"}\}$ 分别标定超像素 p 为变化区域(前景)或未变化区域(背景)。

在前背景代价的计算中,设置一个较低阈值 T_1 与一个较高阈值 T_2 ,以获取较好的检测效果,具体如下:

$$D_p(\text{"obj"}) = \begin{cases} \infty, & CC_p < T_1 \\ -\ln CC_p, & T_1 \leq CC_p \leq T_2, \\ 0, & CC_p > T_2 \end{cases} \quad (13)$$

$$D_p(\text{"bkg"}) = \begin{cases} 0, & CC_p < T_1 \\ -\ln(1 - CC_p), & T_1 \leq CC_p \leq T_2, \\ \infty, & CC_p > T_2 \end{cases} \quad (14)$$

其中:当 $CC_p > T_2$ 时,超像素大概率为变化区域,判定为前景的代价为0;当 $CC_p < T_1$ 时,超像素大概率为未变化区域,判定为背景的代价为0;当 $T_1 \leq CC_p \leq T_2$ 时,根据变化强度值计算分类代价。

平滑项 $E_{\text{smooth}}(L)$ 描述超像素间的空间关联性,保证分割结果的连续性,通过联合两个时相影像上超像素之间的对比度和距离决定,则有:

$$E_{\text{smooth}}(L) = \sum_{\{p,q\} \in \mathcal{N}} V_{\{p,q\}}(l_p, l_q), \quad (15)$$

$$V_{\{p,q\}}(l_p, l_q) = \exp(-\max(D_r^{t_1}(p, q), D_r^{t_2}(p, q))) + \exp(-D_s(p, q)), \quad (16)$$

$$D_r(p, q) =$$

$$\sum_{b=1}^{n_p} \sum_{d=1}^{n_q} f(c_{p,b}) f(c_{q,d}) D(c_{p,b}, c_{q,d}). \quad (17)$$

其中: \mathcal{N} 是所有超像素的邻域集合, $D_r^{t_1}(p, q)$, $D_r^{t_2}(p, q)$ 和 $D_s(p, q)$ 分别表示前后时期超像素 p 和 q 的对比度和空间距离,空间距离即为两个超像素中心的欧氏距离,对比度 $D_r(p, q)$ 由区域间颜色直方图分布决定,为了减少颜色数量,对每个波段进行量化成12个级别。 $f(c_{p,b})$ 表示超像素 p 中第 b 个颜色 $c_{p,b}$ 在其所有 n_p 种颜色出现的频率, $f(c_{q,d})$ 同理, $D(c_{p,b}, c_{q,d})$ 则是颜色差异。最终采用最小割最大流算法即可获得变化检测结果。

4 实验结果与分析

4.1 实验数据和评价指标

实验采用不同类型的高分辨率遥感影像数据,涵盖卫星影像与航空影像,地物类型包括建筑物、林地、道路、荒地等,具体信息如表1所示。数据均存在不同程度的地物变化,且包含辐射差异、阴影干扰等复杂因素,能有效验证方法的有效性和鲁棒性,如图4所示。

表1 实验数据详情

Tab. 1 Details of experimental data				
Study area	Image size	Resolution/m	Data source	Spectral bands
Data1	2 566 × 2 384	0.5	Aerial	RGB
Data2	4 820 × 2 952	0.8	Satellite	RGB




图4 高分辨率影像
Fig. 4 High-resolution Images on Data1 and Data2

为了检验算法的有效性,采用查准率(Precision)、查全率(Recall)、综合性能(F-score)以及总体精度(Accuracy)四个指标进行定量评价,计算公式如下:

$$Precision = \frac{TP}{TP + FP}, \quad (18)$$

$$Recall = \frac{TP}{TP + FN}, \quad (19)$$

$$Fscore = \frac{2Precision \times Recall}{Precision + Recall}, \quad (20)$$

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN}, \quad (21)$$

其中: TP 为正确检测的变化区域, FP 为误判为变化的未变化区域, FN 为漏检的变化区域, TN 为正确检测出的未变化区域。Precision 反映检测结果的准确性, Recall 表示检测结果的完整性, F-score 综合两者体现整体性能, Accuracy 代表全局判定的正确率。

4.2 结果比对分析

为验证相对辐射校正的有效性, 将后期影像作为参考, 对前期影像进行处理, 选取均值差异定量指标, 对比校正前后两期影像的辐射一致性, 如表 2 所示。经 FFT 校正后, 在 Data1 中 RGB 均值差异分别降至 6.84, 5.70, 7.68, 相较于校正前分别下降 83.10%, 84.54%, 80.93%; 在 Data2 中均值差异分别降至 2.59, 4.64, 5.69, 较校正前分别下降 83.58%, 81.22%, 81.18%, 表明校正后两期影像的辐射分布趋于一致, 系统

性辐射偏差被有效消除。同时, 绘制校正前后以及参考影像的灰度直方图, 直观反映辐射分布的变化, 如图 5 所示。校正前两期影像的灰度直方图峰值偏移明显、分布离散, 校正后直方图峰值重合度高、分布趋势一致, 直观验证了辐射校正方法在保留地物细节的同时, 实现了辐射特性的精准对齐, 且该方法运算效率优、场景适应性强, 适用于高分辨率遥感影像的辐射校正处理。在此基础上, 将校正完成的前期影像与后期参考影像融合, 如图 6 所示, 联合影像能够较好保留两期影像的地物细节。

表 2 相对辐射校正前后影像均值差异对比

Tab. 2 Comparison of mean difference between images

Band	Data1	Data2
R	40.56→6.84	15.77→2.59
G	36.88→5.70	24.71→4.64
B	40.28→7.68	30.28→5.69

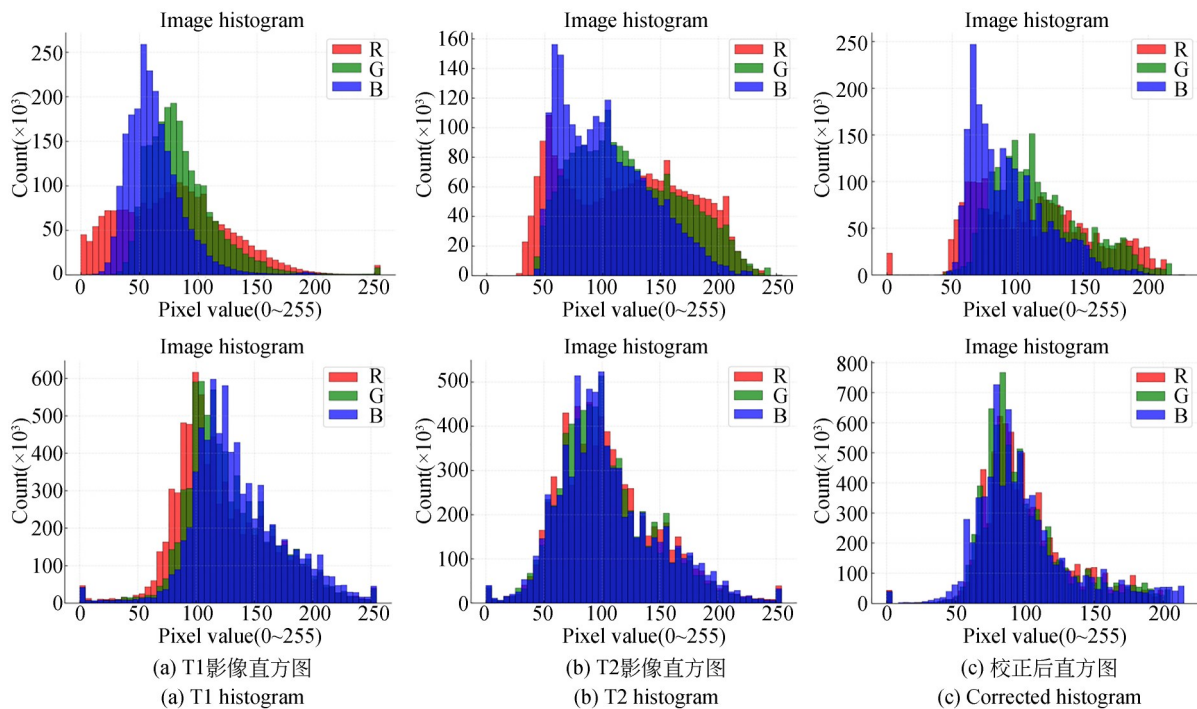


图 5 相对辐射校正前后影像直方图

Fig. 5 Image histogram before and after radiometric correction

在超像素分割中, 结合高分辨率影像分辨率, 选用 10 m 的超像素空间尺寸既保证地物空间结构的完整性, 又避免超像素过粗导致的细节

丢失; 同时, 紧凑度设为 20, 可较好兼顾超像素的形状规则性与地物边界贴合度, 总体分割效果如图 7 所示。




图 6 相对辐射校正与影像联合

Fig. 6 Relative radiometric correction and image fusion




图 7 超像素分割叠合影像

Fig. 7 Super pixels-segmented stacked images

变化强度信息获取阶段,结合网络参数设置经验^[22-23],KPCA 卷积映射网络设置 3 层权重共享的卷积层,在保证特征提取深度的同时,避免过深网络导致的无监督场景下特征退化;采用适配高分辨率影像中地物结构的 10 m 物理感受野卷积核,捕捉精细局部与空间特征;每层卷积核数量均为 8 个,充分挖掘地物的空间和光谱非线性特征,且不会造成计算量过度增加;选用径向基核函数使网络提取更具代表性的非线性特征,其扩展参数设为 5×10^{-4} ,实现特征的有效映射与区分。DSFA 网络深度特征提取通道由 2 个隐含层串联组成,每个隐含层含有 128 个节点,实现

地物特征的深度挖掘,适配语义信息的提取需求;正则化系数设为 10^{-4} ,避免系数较大破坏协方差矩阵固有特性;同时,优化器搭配 10^{-4} 的学习率,保障无监督场景下网络的快速、稳定收敛,以获得网络参数和 SFA 投影矩阵。

根据相似性测度,融合前后两期影像对应超像素空间-光谱特征和深度语义特征的距离差异,生成鲁棒的变化强度信息。如图 8 所示,高变化置信度区域 ($CC_p > 0.7$) 为白色,低变化置信度区域 ($CC_p < 0.3$) 为黑色,最终变化分布由 Graph Cut 图割模型结合超像素变化强度、对比度及空间距离优化得到。




图 8 双时相影像变化强度信息

Fig. 8 Change confidence between bi-temporal images

选取六种方法作为对比,分别为主成分差异法 (Principal Component Differential Analysis, PCDA)^[25]、迭代加权多元变化检测方法 (Iteratively Reweighted Multivariate Alteration Detection, IRMAD)^[26]、面向对象变化向量分析方法 (Object-based Change Vector Analysis, OCVA)^[27]、深度变化向量分析 (Deep Change Vector Analysis, DCVA)^[28]、KPCA^[23] 以及 DSFA^[24]。PCDA 利用降维思维将原有信息集中到少数互不相关的结果分量中,剔除了冗余数据,从而使有效信息集中;IRMAD 基于典型相关分析,引入迭代加权策略优化相关系数,通过波段差值运算提取变化信息;OCVA 通过遥感影像间像斑的向量大小表征相应的变化程度,进而确定地物变化和未变化的区域。DCVA 以高维、强判别性的深度变化向量,实现从像素级浅层特征差异提升至地物级

深度语义特征差异;KPCA融合核主成分分析与卷积神经网络,通过KPCA实现非线性特征映射,再经CNN强化局部空间特征;DSFA是基于慢特征分析的无监督学习方法,通过编解码网络强化未变化地物的“慢特征”与变化地物的“快特征”差异。

图9和图11依次给出了不同算法在每个研究区的检测效果,IRMAD和PCDA方法均存在严重的椒盐噪声,表现为检测结果中分散的孤立像素点干扰。其中,IRMAD对影像中高亮区域极为敏感,易将非变化的高亮像素误判为变化区域,造成明显的错误检测;PCDA方法受降维思想局限,在数据压缩过程中丢失了地物纹理变化信息,尤其对改造纹理渐变的变化区域无法有效捕捉,漏检率显著上升。OCVA方法虽通过面向对象分割抑制了部分噪声,检测结果的连续性优于像素级方法,但对复杂纹理区域的检测精度不足。在荒地开垦与自然植被波动共存的区域,由于两类场景的像斑光谱向量差异较小,OCVA仅依靠光谱向量模长无法区分“人为开垦的真实变化”与“季节更替导致的植被覆盖度波动”,导致

该区域出现误检与漏检交织的问题,检测结果与变化真值偏差较大。KPCA、DCVA和DSFA方法借助深度学习或机器学习模型能提取部分深层特征,局部场景表现较好,但稳定性仍然不足。其中,KPCA整体表现相对最优,在规则建筑群区域能较好捕捉建筑轮廓变化,但对边缘特征建模不足,存在轻微漏检和错检;DCVA方法对复杂纹理混合区域易出现节点特征混淆,导致局部误检与漏检发生;DSFA方法易出现过分割现象,将单一变化斑块分割为多个碎片化单元,影响变化区域的完整性检测。相比之下,本文方法通过超像素联合分割与图割优化,既有效抑制了椒盐噪声,又通过空间上下文建模强化了地物轮廓连续性,检测效果得到显著改善,黄色标记区域均被准确识别,贴合实际地物变化情况。

研究区1中大部分地物主要是建筑物,影像中间区域是规则密集的建筑群,相比于周围区域来说,检测较为容易;而右下角区域多为高层建筑物,并且由于传感器成像角度的原因,高建筑物存在更严重的阴影问题,使得该组数据针对地物变化检测存在一定的难度。

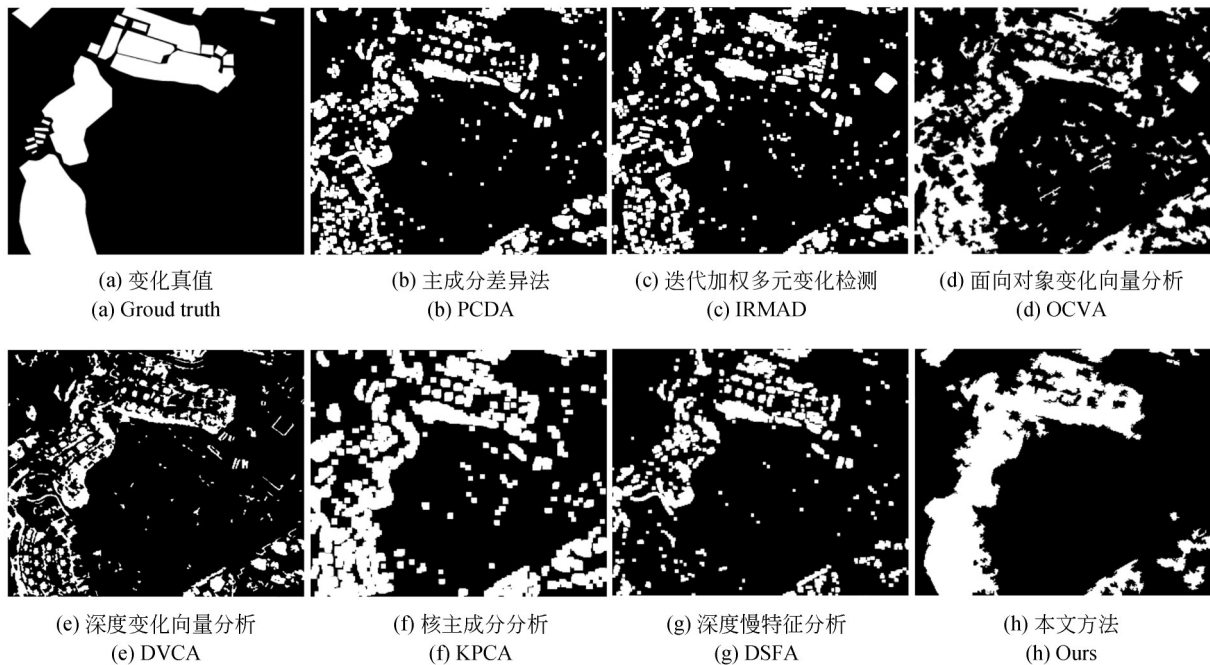


图9 研究区1变化检测算法比较

Fig. 9 Comparison of change detection algorithms on data1

从表3量化指标可以得知,就查全率而言,六种对比方法普遍低于50%,整体表现较优的OC-

VA最高仅为52.78%,本文算法高达90%,表明遗漏的变化地物较少,即漏检率较小。在查准率

方面,虽然本文算法比KPCA略低一点,但仅相差不足1%,同时由于足够高的查全率,其总体性能最优,总体精度明显提高,这说明本文方法能够将变化区域较全检测出来的同时,保证提取的准确性。

表 3 研究区 1 变化检测算法性能比较

Tab. 3 Performance evaluation of algorithms on data1

Method	Precision	Recall	F-score	Accuracy
PCDA	52.32	43.43	47.46	77.78
IRMAD	51.22	41.13	45.62	77.33
OCVA	49.79	<u>52.78</u>	51.24	86.77
DCVA	64.97	46.37	54.12	<u>88.60</u>
KPCA	65.71	48.40	<u>55.74</u>	85.88
DSFA	62.48	44.49	51.97	87.63
Ours	<u>65.10</u>	90.26	75.64	90.41

本研究区查准率略低主要原因是存在一定的错误检测,这一方面是由于右下角区域中高层建筑物投影差异导致,另一方面是因为变化区域较为集中,在基于超像素图割协同优化的过程中,空间上下文联系导致,如图 10 所示。

研究区 2 作为典型的复杂场景测试区,地物




图 10 研究区 1 误检

Fig. 10 False detection on data1

构成多元且干扰因素突出:不仅涵盖多种异质地物类型(如高密度居住区与零星独栋建筑、成片林地与零散植被斑块、主干道与窄幅乡村道路、裸地与低覆盖度植被区等),而且受卫星成像条件影响,影像存在明显辐射差异——不同地物间光谱特征易重叠,同一地物在不同区域的像素值波动较大,大幅增加了变化检测的难度。尽管如此,本文方法的变化检测目视效果仍表现优异,检测结果中地物边界清晰,无明显椒盐噪声,变化区域与未变化区域的划分贴合实际地物分布规律。

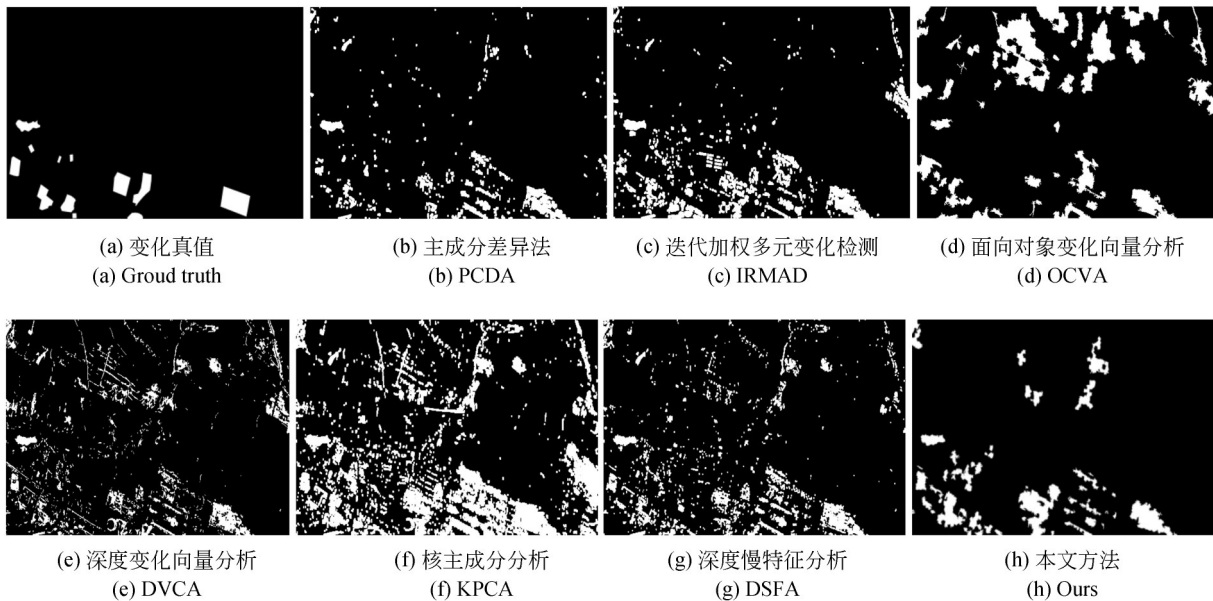


图 11 研究区 2 变化检测算法比较

Fig. 11 Comparison of change detection algorithms on data2

从表 4 量化指标来看,对于研究区 2 卫星影像,IRMAD,PCDA 和 OCVA 的 Recall 普遍处于 70% 左右,KPCA,DCVA 和 DSFA 整体提升可达 85% 以上,本文算法高达 91.05%,稳居所有对比方法首位,整体检测效果处于最优水平。在查准率方面,本文算法同样表现稳健,以 36.58% 的精度仅略低于 DSFA 算法(36.82%) 0.24%,差距较小;但得益于显著更高的查全率,其比 KPCA(88.68%) 高 2.37%,综合性能和总体精度分别达到 52.19% 和 94.81%,远超其他算法,充分验证了高覆盖和高准确的平衡优势。总体而言,本文方法在研究区 2 这类复杂场景中,既实现了较高的查全率,最大限度覆盖了各类主要变化区域,又保持了良好的查准率,充分体现了对多类型地物、辐射差异等复杂场景的强适应性。

表 4 研究区 2 变化检测算法性能比较

Tab. 4 Performance evaluation of algorithms on data2

Method	Precision	Recall	F-score	Accuracy
PCDA	33.05	70.33	44.97	86.69
IRMAD	35.55	72.97	47.81	89.04
OCVA	34.79	71.23	46.75	88.47
DCVA	32.77	85.40	47.36	90.74
KPCA	36.44	<u>88.68</u>	<u>51.65</u>	<u>92.53</u>
DSFA	<u>36.82</u>	86.28	51.61	91.92
Ours	<u>36.58</u>	<u>91.05</u>	<u>52.19</u>	<u>94.81</u>

检测结果存在少量漏检现象,具有明确的场景指向性。一是狭长地物,其空间占比小、边缘特征易被周边地物掩盖;二是路面铺装更新,光谱变化幅度小,易与辐射差异混淆;三是较小及局部改造的建筑物,变化特征不显著,难以与背景地物形成强区分度,如图 12 所示,图中清晰标注了窄幅道路扩建、小型建筑改造等未被完整捕捉的变化区域。

此外,虚检现象主要表现在:一方面是城市高层建筑物的投影差与阴影干扰——受传感器成像角度影响,高层建筑物会在周边区域

形成投影差和阴影,这些区域的光谱特征与部分变化地物高度相似,导致算法误判;另一方面是同物异谱现象,如不同季节的林地植被覆盖度差异、荒地与未改造裸地建筑的光谱重叠,使得部分未变化区域被误判为变化,如图 13 所示。

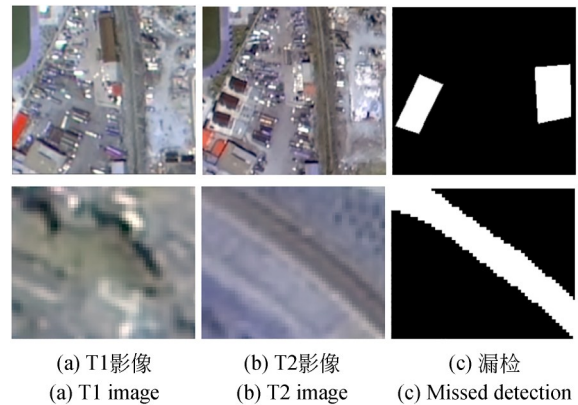


图 12 研究区 2 漏检

Fig. 12 Missed detection on data2




图 13 研究区 2 误检

Fig. 13 False detection on data2

本文方法在卫星影像和航空影像中均保持稳定表现,最大限度地覆盖了各类主要变化区域,又保持了良好的总体精度,其综合性能显著优于传统方法。与深度学习方法相比,本文方法无需依赖标注数据与参数调优,在 Recall 与 Precision 的平衡上也更具优势。从图 14 的局部细节可以直观看出,本文方法对人工构筑群体、林地改造边缘、道路修补区域的检测,无明显噪声干扰,变化区域的完整性与准确性较好,充分体现了对多类型地物、辐射差异、高分辨率细节等复杂场景的强适应性和鲁棒性。



图 14 变化检测细节效果

Fig. 14 Amplified details of change detection result

4.3 实验参数影响

在影像联合分割阶段,为探究超像素尺寸与紧凑度对分割效果的影响,分别在航空和卫星影像测试了不同超像素尺寸(7 m, 10 m, 15 m)与紧凑度(10, 20, 30)组合下的分割表现。如图 15 所示,上方为 0.5 m 航空影像,下方为 0.8 m 卫星影像,其在 10 m 超像素尺寸与 20 紧凑度的组合,均可精准贴合前后影像上地物实际轮廓,兼顾小尺度地物空间结构细节与区域匀质性,形状规则性与边界贴合度达到最优平衡,为后续提供优质的空间单元。超像素粒度过细,易造成地物轮廓碎片化分割,不仅大幅增加后续特征计算的维度与算力消耗,还易引入像素级噪声干扰,导致超像素单元无法有效表征地物整体特征。超像素粒度过粗,难以捕捉建筑边缘、窄幅道路等小尺度地物的精细特征,易出现不同地物的融合分割,丢失关键的空间结构细节,无法适配高分辨率遥感影像的精细化检测需求。紧凑度过低,超像素形状规则性差,易随地形或地物纹理发生畸变,分割结果边界贴合度不足,部分超像素单元出现拉伸、扭曲,破坏地物的空间完整性。紧凑度过高,超像素过度追求形状规则性,会强行平滑地

物的自然边界,导致轮廓贴合度大幅下降,尤其对不规则地物的分割偏差显著,无法准确反映地物的实际空间分布。




图 15 超像素分割参数设置效果对比

Fig. 15 Comparison of super-pixel segmentation parameters

变化检测算法主要涉及两种参数,一方面是能量函数模型中数据项的两个阈值 T_1 与 T_2 ,另一方面则是用于数据项与平滑项的调节因子 λ 。采用控制变量法进行参数调整,通过多次实验结果的对比与分析,确定最优的算法参数值。

图 16(a)展示了 $(T_2, \lambda) = (0.7, 0.6)$ 保持不变时, T_1 从 0.2 变化到 0.4 的检测效果。 $T_1 \in [0.2, 0.3]$ 时, Recall 总体保持平稳,随着 T_1 不断增大, Recall 呈现缓慢下降的趋势,而 Precision 有所上升。这主要是由于当 T_1 过大时,判定变化的阈值被提高,部分真实变化会因未达到阈值而被判定为未变化,导致查全率稍有下降。与此同时,虚检的非变化区域被过滤,检测准确性有所提升。图 16(b)展示了 $(T_1, \lambda) = (0.3, 0.6)$ 保持不变时, T_2 从 0.6 变化到 0.8 的检测效果。 $T_2 \in [0.6, 0.7]$ 时,随着 T_2 不断增大, Recall 呈现缓慢下降的趋势,而 Precision 有所提升,在 $T_2 > 0.7$ 后总体保持平稳。这主要是由于当 T_2 较小

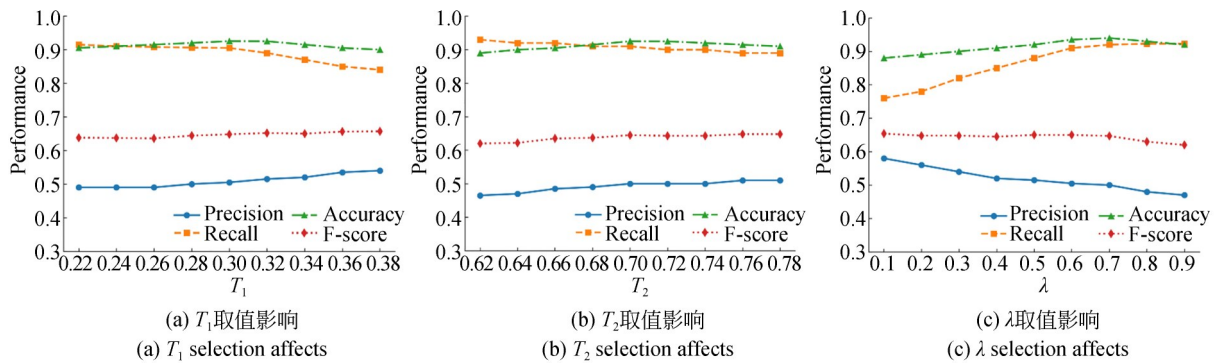


图 16 不同参数对检测性能的影响

Fig. 16 Effect of different parameters on the performance

时,较多区域被判为变化,从而导致误检增加、漏检降低,但当阈值超过临界值后,检测整体效果能够保持稳定。图 16(c)展示了 $(T_1, T_2) = (0.3, 0.7)$ 保持不变时, λ 从 0.1 变化到 0.9 的检测效果。当 λ 较小时,平滑项权重过强,变化区域被过度融合,细节丢失,查全率偏低;随着 λ 增大,数据项权重过高,分割细碎,查准率就会发生小幅回落;当 $\lambda \in [0.6, 0.7]$ 时,数据项与平滑项权重平衡,分割结果既保留了变化区域的细节,又保证了区域的连续性。因此,在本次变化检测中,参数分别取 $(T_1, T_2, \lambda) = (0.3, 0.7, 0.6)$ 。

5 结 论

本文利用配准好的两期高分辨率遥感影像,

提出了一种融合对象级 KPCA-DSFA 的无监督变化检测方法,并介绍了具体流程和工作原理,研究了空间-光谱特征提取和深度语义分析耦合的强度信息获取;给出了利用对象邻接关系和空间差异,基于图割的协同优化方法。实验结果表明:检测的总体精度可达 90% 以上,综合性能较高,能够有效抑制椒盐噪声,显著提升变化区域的查全率,具有一定的优越性和鲁棒性。

作者贡献声明:

宫金杞:变化检测方法提出,论文构思和撰写;

王宗晨:论文审核与编辑写作;

王铁:实验的设计实现及数据整理和分析;

周俊亦:实验数据分析。

参考文献:

- [1] 周维勋,刘京雷,彭代锋,等. MtSCCD: 面向深度学习的土地利用场景分类与变化检测数据集[J]. 遥感学报, 2024, 28(2): 321-333.
ZHOU W X, LIU J L, PENG D F, *et al.* MtSCCD: Land-use scene classification and change-detection dataset for deep learning[J]. *National Remote Sensing Bulletin*, 2024, 28(2): 321-333. (in Chinese)
- [2] 袁洲,郭海涛,卢俊,等. 融合 UNet++ 网络和注意力机制的高分辨率遥感影像变化检测算法[J]. 测绘科学技术学报, 2021, 38(2): 155-159.
YUAN Z, GUO H T, LU J, *et al.* High-resolution remote sensing image change detection technology based on UNet++ and attention mechanism [J].
- [3] 王松伦,马晓楠,潘子轩. 基于遥感影像的生产建设项目扰动图斑人机协同智能提取方法[J]. 测绘通报, 2023(11): 132-138.
WANG S L, MA X N, PAN Z X. Human-machine collaborative intelligent extraction method of production and construction project disturbed patches based on remote sensing image [J]. *Bulletin of Surveying and Mapping*, 2023(11): 132-138. (in Chinese)
- [4] PENG D F, BRUZZONE L, ZHANG Y J, *et al.* SemiCDNet: a semisupervised convolutional neural network for change detection in high resolution remote-sensing images [J]. *IEEE Transactions on*

Journal of Geomatics Science and Technology, 2021, 38(2): 155-159. (in Chinese)

- Geoscience and Remote Sensing*, 2021, 59 (7) : 5891-5906.
- [5] 张晶, 吕京国, 张济勇, 等. 边缘约束的遥感影像建筑物施工变化检测[J]. 测绘科学, 2023, 48 (12): 130-142.
ZHANG J, LYU J G, ZHANG J Y, *et al.* Construction change detection of buildings in remote sensing images with edge constraints[J]. *Science of Surveying and Mapping*, 2023, 48(12): 130-142. (in Chinese)
- [6] 张祖勋, 姜慧伟, 庞世燕, 等. 多时相遥感影像的变化检测研究现状与展望[J]. 测绘学报, 2022, 51 (7): 1091-1107.
ZHANG Z X, JIANG H W, PANG S Y, *et al.* Review and prospect in change detection of multi-temporal remote sensing images[J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51 (7) : 1091-1107. (in Chinese)
- [7] 罗卿莉, 蒋鑫涛, 张书缤, 等. 基于改进显著性检测的 SAR 影像变化检测[J]. 测绘科学, 2023, 48 (12): 172-187.
LUO Q L, JIANG X T, ZHANG S B, *et al.* SAR image change detection based on improved saliency detection [J]. *Science of Surveying and Mapping*, 2023, 48(12): 172-187. (in Chinese)
- [8] 赵元铭, 孙永华, 李小娟, 等. 面向城市土地利用的高分辨率遥感特征分析[J]. 测绘科学, 2022, 47 (3): 110-115, 121.
ZHAO Y M, SUN Y H, LI X J, *et al.* Analysis of high-resolution remote sensing features for urban land use [J]. *Science of Surveying and Mapping*, 2022, 47(3): 110-115, 121. (in Chinese)
- [9] 武锦沙, 杨树文, 李轶鲲, 等. 面向异源影像的 FCM-SBN-CVAPS 多尺度变化检测方法[J]. 测绘通报, 2023(12): 45-50.
WU J S, YANG S W, LI Y K, *et al.* FCM-SBN-CVAPS multi-scale target change detection based on multi-spectral heterologous remote sensing image [J]. *Bulletin of Surveying and Mapping*, 2023 (12): 45-50. (in Chinese)
- [10] 高雨, 胡召玲, 樊茹. 高分辨率影像融合算法对滨海湿地土地利用分类精度的影响[J]. 测绘通报, 2022(1): 116-120.
GAO Y, HU Z L, FAN R. Effect of high-resolution image fusion algorithm on the classification precision of land utilization in coastal wetland[J]. *Bulletin of Surveying and Mapping*, 2022 (1) : 116-120. (in Chinese)
- [11] 任若天, 赵理君, 赵旭阳, 等. 知识引导下的遥感影像智能解译方法综述[J]. 航空学报, 2025, 46 (23): 1-23.
REN R T, ZHAO L J, ZHAO X Y, *et al.* A review of knowledge-guided intelligent interpretation methods for remote sensing imagery [J]. *Acta Aeronautica et Astronautica Sinica*, 2025, 46 (23): 1-23. (in Chinese)
- [12] CHENG H Q, WU H Y, ZHENG J, *et al.* A hierarchical self-attention augmented Laplacian pyramid expanding network for change detection in high-resolution remote sensing images [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 182: 52-66.
- [13] YAN L, YANG J B, WANG J. Domain knowledge-guided self-supervised change detection for remote sensing images [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 4167-4179.
- [14] ZHANG X T, HUANG X, LI J Y. Joint self-training and rebalanced consistency learning for semi-supervised change detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5406613.
- [15] 周冬梅, 贾琴琴. 融合 Mamba 的多尺度遥感图像实例分割网络 [J]. 光学精密工程, 2025, 33 (24): 3940-3955.
ZHOU D M, JIA Q Q. Multi-scale remote sensing image instance segmentation network with mamba integration [J]. *Opt. Precision Eng.*, 2025, 33(24): 3940-3955. (in Chinese)
- [16] 潘梦洋, 杨航, 范祥晖. 基于 CNN-Transformer 结构的遥感影像变化检测 [J]. 液晶与显示, 2024, 39(10): 1361-1379.
PAN M Y, YANG H, FAN X H. Remote sensing image change detection based on CNN-Transformer structure [J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(10): 1361-1379. (in Chinese)
- [17] HAO M, CHEN S L, LIN H J, *et al.* A prior knowledge guided deep learning method for building extraction from high-resolution remote sensing images [J]. *Urban Informatics*, 2024, 3(1): 6.
- [18] ZHANG K, LI P J, WANG J Q. A review of deep learning-based remote sensing image caption: methods, models, comparisons and future direc-

- tions[J]. *Remote Sensing*, 2024, 16(21): 4113.
- [19] LIU Y F, XIONG Z T, YUAN Y, *et al.* Distilling knowledge from super-resolution for efficient remote sensing salient object detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5609116.
- [20] 熊晶,董婷,管宗胜. 双域差异和尺度选择增强的遥感影像变化检测[J]. *液晶与显示*, 2025, 40(11): 1661-1674.
XIONG J, DONG T, GUAN Z S. Dual-domain difference and scale selection enhancement for remote sensing image change detection [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(11): 1661-1674. (in Chinese)
- [21] 陈思睿,胡方敏,王洪亮,等. 全向矩形校准的高分辨率遥感影像细节分割[J]. *光学精密工程*, 2025, 33(19): 3121-3134.
CHEN S R, HU F M, WANG H L, *et al.* Detailed segmentation of high-resolution remote sensing images calibrated with omnidirectional rectangle [J]. *Opt. Precision Eng.*, 2025, 33(19): 3121-3134. (in Chinese)
- [22] 刘宇豪,吴福培,吴树壮,等. 基于插值超分辨率的双目三维重建方法[J]. *中国光学(中英文)*, 2024, 17(4): 862-874.
LIU Y H, WU F P, WU S Z, *et al.* Binocular 3D reconstruction method based on interpolation super-resolution [J]. *Chinese Optics*, 2024, 17(4): 862-874. (in Chinese)
- [23] WU C, CHEN H, DU B, *et al.* Unsupervised change detection in multitemporal VHR images based on deep kernel PCA convolutional mapping network [J]. *IEEE Transactions on Cybernetics*, 2022, 52(11): 12084-12098.
- [24] DU B, RU L X, WU C, *et al.* Unsupervised deep slow feature analysis for change detection in multitemporal remote sensing images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(12): 9976-9992.
- [25] ZHANG J X, ZHANG Y H. Remote sensing research issues of the national land use change program of China [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2007, 62(6): 461-472.
- [26] NIELSEN A A. The regularized iteratively reweighted MAD method for change detection in multi- and hyperspectral data [J]. *IEEE Transactions on Image Processing*, 2007, 16(2): 463-478.
- [27] DESCLÉE B, BOGAERT P, DEFOURNY P. Forest change detection by statistical object-based method [J]. *Remote Sensing of Environment*, 2006, 102(1/2): 1-11.
- [28] SAHA S, BOVOLO F, BRUZZONE L. Unsupervised deep change vector analysis for multiple-change detection in VHR images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(6): 3677-3693.

作者简介:



宫金杞(1989—),男,山东烟台人,博士,讲师,2015年于山东农业大学获得硕士学位,2019年于武汉大学获得博士学位,主要从事机器视觉及遥感图像智能解译方面的研究。E-mail: jin-qigong@njtech.edu.cn



王宗晨(2002—),男,山东枣庄人,硕士研究生,2024年于嘉兴大学获得学士学位,现就读于南京工业大学,主要从事三维点云和遥感影像信息提取的算法研究。E-mail: wangzongchen@njtech.edu.cn